



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



YÜKSEK LİSANS TEZİ

**PERAKENDE SEKTÖRÜNDE DİNAMİK FİYATLANDIRMA ile
GELİR YÖNETİMİ OPTİMİZASYONU**

Sinem BATMACA

**DANIŞMAN
Dr. Öğr. Üyesi Sinem BÜYÜKSAATÇI KİRİŞ**

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

İSTANBUL-2021

Bu çalışma, [17.02.2021] tarihinde aşağıdaki jüri tarafından [Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı]nda [Yüksek Lisans tezi] olarak kabul edilmiştir.

Tez Jürisi

[Dr. Öğr. Üyesi] [Sinem BÜYÜKSAATÇI KIRIŞ] (Danışman)
[İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi]

[Doç. Dr.] [Ersin NAMLI]
[İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi]

[Dr. Öğr. Üyesi] [Murat Taha BİLİŞİK]
[İstanbul Kültür Üniversitesi]
[İktisadi ve İdari Bilimler Fakültesi]

[
[
[
[

[
[
[
[



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa’nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır. |

ÖNSÖZ

[Tez konumun belirlenmesinden başlayarak tüm çalışma sürecim boyunca bana gösterdiği tüm destek ve yönlendirmeler için değerli danışmanım Dr. Öğr. Üyesi Sinem BÜYÜKSAATÇI KİRİŞ'e;

Gerek kurumsal gerek akademik hayatımda, destekleri ve anlayışları ile yüksek lisans sürecimde yanımda olmuş olan herkese,

Ve çok değerli aileme; aldığım her kararda, attığım her adımda yanımda oldukları için çok teşekkürlerimle. |

Şubat 2021

[Sinem BATMACA]

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ.....	xi
SİMGE VE KISALTMA LİSTESİ	xiii
ÖZET	xv
SUMMARY	xvii
GİRİŞ.....	1
2. GENEL KISIMLAR	4
2.1. GELİR YÖNETİMİ	4
2.2. FİYATLANDIRMA STRATEJİLERİ.....	5
2.2.1. Yüksek veya Düşük Fiyat Stratejisi	5
2.2.2. Pazar Segmentasyonu Stratejisi.....	6
2.2.3. İndirimli Satış Stratejisi	7
2.2.4. Fiyat Kayması (Price Skimming) Stratejisi	7
2.2.5. Pazara Giriş Fiyatlandırması Stratejisi	7
2.2.6. Dinamik Fiyatlandırma Stratejisi	7
2.2.6.1. Talep Bazlı Fiyatlandırma	8
2.2.6.2. Zamana Dayalı Fiyatlandırma	8
2.2.6.3. Rekabete Dayalı Fiyatlandırma.....	8
2.3. PERAKENDE SEKTÖRÜNDE DİNAMİK FİYATLANDIRMA	9
2.3.1. Dinamik Fiyatlandırma Stratejilerine E-ticaret Sitelerinin Katkısı	9
2.3.1.1. Müşterilerin Satın Alma Davranışları Hakkında Bilginin Toplanması Özelliği	10
2.3.1.2. Kişiselleştirme Fiyatlandırma Özelliği.....	11
2.3.2. Perakende Sektöründe Dinamik Fiyatlandırma İle İlgili Literatür Analizi	11
2.3.2.1. Perakende Sektöründe Dinamik Fiyatlandırma İle İlgili Genel Literatür Çalışmaları	11
2.3.2.2. E-ticaret Sitelerinde Dinamik Fiyatlandırma Çalışmaları.....	13
2.3.2.3. Tek Ürün için Dinamik Fiyatlandırma Çalışmaları	15

2.3.2.4. Çoklu Ürün için Dinamik Fiyatlandırma Çalışmaları	17
2.3.2.5. Envanterin Kısıtlı Olduğu Durumda Dinamik Fiyatlandırma Çalışmaları	19
2.3.2.6. Rekabetin Dikkate Alındığı Dinamik Fiyatlandırma Çalışmaları	20
2.3.2.7. Davranış Dinamiklerinin Dikkate Alındığı Dinamik Fiyatlandırma Çalışmaları	25
2.3.2.8. Talep Hakkında Kısıtlı Bilginin Olduğu Durumlarda Dinamik Fiyatlandırma Çalışmaları	26
2.3.2.9. İndirim Optimizasyonu Dinamik Fiyatlandırma Çalışmaları	27
2.3.2.10. Talebin Öğrenilmesine Dayalı Dinamik Fiyatlandırma Çalışmaları.....	31
2.3.2.11. Bozulabilir Ürünler İçin Dinamik Fiyatlandırma Çalışmaları	33
2.3.2.12. Gıda Perakendesinde Dinamik Fiyatlandırma Çalışmaları.....	34
2.4. TAHMİNLEME ALGORİTMALARI.....	35
2.4.1. Makine Öğrenmesi	35
2.4.1.1. Denetimli Öğrenme.....	36
2.4.1.2. Denetimsiz Öğrenme.....	37
2.4.1.3. Yarı Denetimli Öğrenme.....	37
2.4.1.4. Pekiştirmeli Öğrenme	37
2.4.2. Regresyon Ağaçları	38
2.4.2.1. Sınıflandırma ve Regresyon Ağaçları	39
2.4.2.2. Regresyon Ağacı Oluşturma	40
2.4.2.3. Regresyon Ağacı Budama.....	40
2.4.2.4. Karar Ağacı Algoritmalarının Avantajları	41
2.4.3. Torbalama Yöntemi.....	42
2.4.4. Rassal Orman Algoritması	42
2.4.4.1. Rassal Orman Algoritması Adımları	43
2.4.4.2. Rassal Orman Algoritması Öğrenme Stratejisi	44
2.4.4.3. Rassal Orman Algoritmasının Özellikleri	45
2.4.5. Artırım Yöntemi	49
2.4.6. Gradyan Artırım Makinesi	50
2.4.6.1. Gradyan Artırım Makinesi Algoritması Adımları.....	51
2.4.6.2. Gradyan Artırım Makinesi Algoritması Öğrenme Stratejisi	52
2.4.6.3. Gradyan Artırım Makinesi Algoritmasının Parametreleri	53
2.5. TAHMİNLEME MODELLERİNDE İŞLEMLER	54
2.5.1. Çapraz Geçerlilik.....	54

2.5.2. Hiperparametre Ayarlama	55
2.5.2.1. Izgara Arama	55
2.5.2.2. Rassal Arama.....	56
2.5.3. Regresyon Problemlerinde Kullanılan Değerlendirme Ölçütleri	56
2.5.3.1. Ortalama Mutlak Hata	56
2.5.3.2. Ortalama Mutlak Yüzde Hata	57
2.5.3.3. Kök Ortalama Kare Hata	57
2.5.3.4. R² Değeri	57
2.5.3.5. Modelin Hesaplama Süresi.....	58
2.6. OPTİMİZASYON	58
2.7. WEB KAZIMA	64
3. MALZEME VE YÖNTEM	65
3.1. ÇALIŞMADA KULLANILAN YAZILIMLAR	65
3.1.1. R Programlama Dili.....	65
3.1.2. H2O Derin Öğrenme Platformu	66
3.1.3. UiPath Robotik Süreç Otomasyonu Platformu.....	66
3.2. ÇALIŞMADA KULLANILAN VERİ SETİ	68
3.3. ÇALIŞMADA KULLANILAN TAHMİN ALGORİTMALARI.....	70
3.3.1. Dağıtık Rassal Orman Algoritması	70
3.3.1.1. Dağıtık Rassal Orman Algoritmasının Özellikleri	71
3.3.2. H2O Gradyan Artırım Makinesi.....	72
3.3.3. Ekstrem Gradyan Artırımlı Ağaçlar	72
3.4. ÇALIŞMADA KULLANILAN OPTİMİZASYON ALGORİTMALARI.....	73
3.4.1. Parçacık Sürü Optimizasyonu	73
3.4.2. Tavlama Benzetimi Algoritması.....	77
4. BULGULAR	80
4.1. VERİ ÖN İŞLEME SÜRECİ	81
4.1.1. Veri Temizleme İşlemleri.....	83
4.1.2. Özellik Mühendisliği	84
4.2. VERİ KAZIMA SÜRECİ	85
4.3. TALEP TAHMİNİ MODÜLÜ	89
4.3.1. H2O Dağıtık Rassal Orman Algoritması ile Talep Tahmin Modeli.....	90
4.3.2. H2O Gradyan Artırım Makinesi ile Talep Tahmin Modeli.....	94
4.3.3. Ekstrem Gradyan Artırımlı Ağaçlar Algoritması ile Talep Tahmini	97

4.3.4. Talep Tahmini Sonuçlarının Karşılaştırılması.....	99
4.4. OPTİMİZASYON MODÜLÜ	100
TARTIŞMA VE SONUÇ	104
KAYNAKLAR.....	107
EKLER	115
ÖZGEÇMİŞ	126

|



ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1 : Özyinelemeli ikili bölünmeler ve sınıflandırma ve regresyon ağaçları algoritmasının gösterimi.....	39
Şekil 2.2 : Rassal orman algoritması sözde kodu.....	43
Şekil 2.3 : Her bir ağacın derinliğinin aşırı uyum riskine etkisi.	46
Şekil 2.4 : Topluluğu oluşturan ağaçların sayısının tahmin doğruluğuna etkisi.	47
Şekil 2.5 : Gradyan artırım makinesi algoritması sözde kodu	51
Şekil 2.6 : 10 katlamalı çapraz geçerlilik yöntemi.....	55
Şekil 2.7 : Optimizasyon problemlerinin sınıflandırılması.....	60
Şekil 2.8 : Optimizasyon algoritmalarının sınıflandırılması.....	62
Şekil 2.9 : Metasezgisel algoritmaların detaylı sınıflandırılması.....	63
Şekil 3.1 : R Studio arayüzü.....	65
Şekil 3.2 : H2O.ai Flow arayüzü.....	66
Şekil 3.3 : UiPath Studio arayüzü.	67
Şekil 3.4 : Ürün hiyerarşisi grafiği.....	68
Şekil 3.5 : Parçacık sürü optimizasyonu algoritması akış şeması.....	74
Şekil 3.6 : Parçacık sürü optimizasyonu algoritması sözde kodu.	76
Şekil 3.7 : Tavlama benzetimi algoritması akış şeması	78
Şekil 3.8 : Tavlama benzetimi algoritması sözde kodu.....	79
Şekil 4.1 : Dinamik fiyatlandırma karar destek sistemi şeması.	81
Şekil 4.2 : Toplam satış değerlerinin zaman serisi grafiği.....	81
Şekil 4.3 : Toplam satış değerlerinin histogram grafiği.....	81
Şekil 4.4 : Logaritmik dönüşüm sonucu toplam satış değerlerinin histogram grafiği	81

Şekil 4.5 : Toplam satış değişkeni kutu grafiği.....	82
Şekil 4.6 : Veri kazıma ile rakip fiyatlarının çekilme süreci mimari üst seviye tasarım şeması.	83
Şekil 4.7: Veri kazıma işlemi ile fiyat verilerinin çekilmesi süreci	85
Şekil 4.8 : Tahmin modülü iş akışı grafiği.....	86
Şekil 4.9 : Ağaç sayısının artışına bağlı olarak torba dışı (OOB) hata oranı azalması.	92
Şekil 4.10 : Dağıtık rassal orman algoritması ile elde edilen önem dereceleri sıralaması.	94
Şekil 4.11 : Ağaç sayısının artışına bağlı olarak eğitim ve test veri setinin hata oranının azalması.	95
Şekil 4.12 : Gradyan artırım makinesi algoritması ile elde edilen önem dereceleri sıralaması.....	97
Şekil 4.13: Ekstrem gradyan artırımli ağaçlar algoritması ile elde edilen önem dereceleri sıralaması.....	100

TABLO LİSTESİ

Sayfa No

Tablo 2.1 : Perakende sektöründe dinamik fiyatlandırma ile ilgili genel literatür çalışmaları.....	13
Tablo 2.2 : E-ticaret sitelerinde dinamik fiyatlandırma çalışmaları.	15
Tablo 2.3 : Tek ürün için dinamik fiyatlandırma çalışmaları	17
Tablo 2.4 : Çoklu ürün için dinamik fiyatlandırma çalışmaları.....	19
Tablo 2.5 : Envanterin kısıtlı olduğu durumda dinamik fiyatlandırma çalışmaları.....	20
Tablo 2.6 : Rekabetin dikkate alındığı dinamik fiyatlandırma çalışmaları.	24
Tablo 2.7 : Davranış dinamiklerinin dikkate alındığı dinamik fiyatlandırma çalışmaları.	26
Tablo 2.8 : Talep hakkında kısıtlı bilginin olduğu durumlarda dinamik fiyatlandırma çalışmaları.....	27
Tablo 2.9 : İndirim optimizasyonu dinamik fiyatlandırma çalışmaları.	30
Tablo 2.10 : Talebin öğrenilmesine dayalı dinamik fiyatlandırma çalışmaları.	33
Tablo 2.11 : Bozulabilir ürünler için dinamik fiyatlandırma çalışmaları.	34
Tablo 2.12 : Gıda perakendesinde dinamik fiyatlandırma çalışmaları.	35
Tablo 4.1 : Toplam satış değişkeni özeti.	84
Tablo 4.2 : Veri ön işleme ve veri kazıma işlemleri sonrası elde edilen veri setinin yapısı.....	88
Tablo 4.3 : Yeni eklenen değişkenlere göre kurulan modellerin hata değerleri ve hesaplama süreleri.	91
Tablo 4.4 : Kurulan modellerin parametre ve hata değerleri.....	93
Tablo 4.5 : En iyi dağıtık rassal orman algoritması modelinin özeti.....	93
Tablo 4.6 : Kurulan modellerin parametre ve hata değerleri.....	96
Tablo 4.7 : En iyi gradyan artırım makinesi modelinin özeti.	96
Tablo 4.8 : Ekstrem gradyan artırımı ağaçlar algoritması ile kurulan modellerin parametre ve hata değerleri.	98

Tablo 4.9 : En iyi ekstrem gradyan artırımı ağaçlar algoritması modelinin özeti	98
Tablo 4.10 : Kurulan modellerin değerlendirme ölçütlerine göre karşılaştırılması.	99
Tablo 4.11 : Parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi algoritmaları için kullanılan parametreler.	102
Tablo 4.12: Kurulan optimizasyon modellerinin karşılaştırılması.	102



SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
y_L^*	: Sol düğüm için y değerlerinin ortalaması
y_R^*	: Sağ düğüm için y değerlerinin ortalaması
N	: Gözlem sayısı
R_m	: m düğüm sayılı bölge
$OOBHata$	: Torba dışı hata değeri
v	: Öğrenme katsayısı
R^2	: Determinasyon katsayısı
$SS_{kalıntılar}$	: Artıkların toplam kareler toplamı
SS_{toplam}	: Toplam kareler toplamı
v_i^t	: i parçacığının t anındaki hızı
x_i^t	: i parçacığının t anındaki konumu
$c1$	: Bireysel en iyi konum için öğrenme katsayısı
$c2$	: Global en iyi konum için öğrenme katsayısı
$rand$	: Rassal sayı
x_i^t	: Bireysel en iyi çözüm değeri
g^*	: Global en iyi çözüm değeri
w	: Atalet ağırlığı
$f(x)$	: Amaç fonksiyonu
T	: Sıcaklık

Kısaltmalar	Açıklama
Covid-19	: Yeni Koronavirüs Hastalığı-2019
CART	: Classification and Regression Trees (Sınıflandırma ve Regresyon Ağaçları)
RSS	: Residual Sum of Squares (Artık Kareler Toplamı)
RF	: Random Forest (Rassal Orman)

OOB	: Out Of Bag (Torba dışı)
MDI	: Mean Decrease Impurity (Ortalama Safsızlığın Azaltılması)
MDA	: Mean Decrease Accuracy (Ortalama Doğruluğun Azaltılması)
PI	: Permutation Importance (Permütasyon Önemi)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
RMSE	: Root Mean Square Error (Kök Ortalama Kare Hata)
DRF	: Distrubuted Random Forest (Dağıtık Rassal Orman)
GBM	: Gradient Boosting Machine (Gradyan Artırım Makinesi)
XGBoost	: Extreme Gradient Boosting Trees (Ekstrem Gradyan Artırımlı Ağaçlar)
HTML	: Hyper Text Markup Language (Hiper Metin İşaret Dili)
API	: Application Programming Interface (Uygulama Programlama Arayüzü)
SOAP	: Simple Object Access Protocol (Basit Nesne Erişim Protokolü)
REST	: Representational State Transfer (Temsili Durum Transferi)
GenSA	: Genelleştirilmiş Tavlama Benzetimi
PSO	: Parçacık Sürü Optimizasyonu

ÖZET

[YÜKSEK LİSANS TEZİ]

[PERAKENDE SEKTÖRÜNDE DİNAMİK FİYATLANDIRMA ile GELİR OPTİMİZASYONU UYGULAMASI]

[Sinem BATMACA]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

[Endüstri Mühendisliği Anabilim Dalı]

[Danışman : Dr. Öğr. Üyesi Sinem BÜYÜKSAATÇI KİRİŞ]

Perakendeciler tarafından uzun yıllardır kullanılmaya devam eden; geleneksel, statik ve kural bazlı fiyatlandırma sistemleri, dijitalleşmenin getirdiği yeniliklere ve tüketici davranışlarındaki değişikliklere uyum sağlama konusunda ne yazık ki eksik kalmaktadır. Bu nedenle günümüzde; kârlılık ve ciro artışının sağlanması ve rekabet avantajı elde etmek amacı ile, veriye dayalı dinamik fiyatlandırma karar destek sistemlerinin kullanılması kaçınılmazdır.

Bu yüksek lisans tez çalışmasında; vaka çalışmasının gerçekleştirildiği gıda perakendesi firmasında, gelir optimizasyonunu sağlamak amacı ile dinamik fiyatlandırma karar destek sistemi geliştirilmiştir. Geliştirilen karar destek sistemi; veri ön işleme, veri kazıma, talep tahmini modülü ve optimizasyon modülü olmak üzere dört aşamadan oluşmaktadır. Veri ön işleme aşamasında perakende firmasından elde edilen ham veri, veri temizleme ve özellik mühendisliği işlemlerinden geçirilerek, talep tahmini algoritmalarında kullanılabilir hale getirilmiştir. Veri kazıma işlemi ile, ele alınan ürünlere ait rakip firmaların fiyat verileri web sitelerinden çekilerek, veri setine aktarılmıştır. Talep tahmini modülünde; doğruluğu yüksek

talep tahmini gerçekleştirebilmek amacı ile son teknoloji ağaç tabanlı makine öğrenmesi algoritmalarından olan dağıtık rassal orman, gradyan artırım makinesi ve ekstrem gradyan artırımı ağaçlar algoritmaları ile modeller oluşturulmuş ve modellerin sonuçları çeşitli performans ölçütlerine göre karşılaştırılmıştır. Karşılaştırma sonuçlarına göre; en iyi performans, ekstrem gradyan artırımı ağaçlar algoritması modeli ile elde edilmiş ve dolayısıyla talep tahmini bu algoritma ile gerçekleştirilmiştir. Optimizasyon modülünde ise; kârı maksimize etmek amacı ile, parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi olmak üzere iki farklı metasezgisel algoritma kullanılarak ve bir önceki modülde hesaplanan en iyi talep tahmin değerleri dikkate alınarak optimizasyon modelleri kurulmuş ve modellerin sonuçları karşılaştırılmıştır. En iyi performansın elde edildiği genelleştirilmiş tavlama benzetimi algoritması modeli ile perakende firması için toplam kâr ve her bir ürün için optimum fiyat verileri elde edilmiştir.

Önerilen dinamik fiyatlandırma karar destek sistemi Türkçe literatürde ilktir ve bu yönüyle önem taşımaktadır. Her ne kadar Türkçe literatürde moda endüstrisine ait indirim optimizasyonu çalışmalarında talep tahmini ve optimizasyondan oluşan karar yapıları mevcut olsa da, dinamik fiyatlandırma konusunda Türkçe literatürde bu içerikte bir çalışmaya rastlanmamıştır. Uluslararası literatürde ise sadece García-Calderón Chávez (2017)'in çalışmasında bir bira firması için dinamik fiyatlandırma aracı geliştirilmiş, ürün portföyü için fiyatın bir fonksiyonu olarak talep öğrenme algoritması ile kârı maksimize etmek amacıyla ürünler için en uygun fiyatlar belirlenmiştir. Ancak bu tez çalışmasında; daha kapsamlı bir karar destek sistemi önerilerek, UiPath ile veri kazıma işlemi gerçekleştirilmiş ve rakip perakende firmalarının fiyat verileri de karar destek sistemine dahil edilmiştir. Ayrıca yine bu çalışmada, farklı tahminleme ve optimizasyon algoritmaları sistem içinde çalıştırılmıştır.

Tüm bu yönleri ile tez çalışmasının hem akademik hem de sektörel anlamda katkı sağlayacağı düşünülmektedir.

Şubat 2021, [131] sayfa.

Anahtar kelimeler: [Dinamik Fiyatlandırma, Veri Kazıma, Ağaç Tabanlı Makine Öğrenmesi Algoritmaları, Parçacık Sürü Optimizasyonu, Genelleştirilmiş Tavlama Benzetimi]

SUMMARY

[M.Sc. THESIS]

**[REVENUE OPTIMIZATION APPLICATION with DYNAMIC PRICING in
RETAIL INDUSTRY]**

[Sinem BATMACA]

Istanbul University-Cerrahpasa

Institute of Graduate Studies

[Department of Industrial Engineering]

Supervisor : [Assist. Prof. Dr.] [Sinem BÜYÜKSAATÇI KİRİŞ]

Traditional, static and rule-based pricing systems, which have been used by retailers for many years, fall short of adapting to the innovations brought by digitalization and changes in consumer behavior. Therefore, it is inevitable to use data-driven dynamic pricing decision support systems today in order to increase profitability and revenue and gain a competitive advantage.

In this master thesis, a dynamic pricing decision support system has been developed in order to obtain revenue optimization in the grocery retail company where the case study was conducted. The developed decision support system consists of four stages: data pre-processing, data scraping, demand forecasting module and optimization module. During the data pre-processing phase, the raw data obtained from the retail company was made available for demand prediction algorithms by passing through data cleaning and feature engineering processes. With the data scraping process, the price data of the competitors for the considered products were taken from

their websites and transferred to the data set. In the demand forecasting module, in order to achieve high-accuracy demand forecasting; models were created with the distributed random forest, gradient boosting machine and extreme gradient boosting trees algorithms, which are among the state-of-the-art tree based machine learning algorithms. Model results were compared according to various performance metrics. According to the comparison results, the best performance was obtained with the extreme gradient incremental trees algorithm model and therefore the demand estimation was performed with this algorithm. In the optimization module, in order to maximize profit, two different metaheuristic algorithms that are particle swarm optimization and generalized simulated annealing, were used and optimization models were established by considering the best demand estimation values calculated in the previous module and the results of models were compared. The total profit and optimum price data were obtained for the retail company with the generalized simulated annealing algorithm model with the best performance.

The proposed dynamic pricing decision support system is the first in the Turkish literature and is important in this respect. Although there are decision systems consisting of demand forecasting and optimization in the markdown optimization studies of the fashion industry in the Turkish literature, there is no study on dynamic pricing content. In the international literature, only García-Calderón Chávez (2017) developed a dynamic pricing tool for a brewery company, and the most favorable prices for the products were determined with the demand learning algorithm as a function of the price for the product portfolio, in order to maximize profit. However in this thesis, a more comprehensive decision support system was proposed by performing data scraping with UiPath and including price data of rival retail companies into the decision support system.. Also, different estimation and optimization algorithms were run in the decision support system.

With all these aspects, it is thought that this thesis have both academic and sectoral contribution.

February 2021, [131] pages.

Keywords: Dynamic Pricing, Data Scraping, Tree Based Machine Learning Algorithms, Particle Swarm Optimization, Generalized Simulating Annealing

1. GİRİŞ

Dünya sürekli değişmekte, yaşadığımız bilgi çağında teknolojinin hızla gelişmesi ile dijitalleşme artış göstermektedir. Dijitalleşmenin artışı hızlandıran bir diğer faktör de tarihte yaşanan büyük olaylardır. Yakın zamanda geçirdiğimiz Covid-19 kaynaklı pandemi sürecinin ve süreçle ilişkili olarak Mart 2020’den itibaren Türkiye’de alınan “Evde Kal” gibi tedbirlerin, ciddi sosyal ve ekonomik kısıtlamalara ve online ticarete keskin bir artışa yol açtığı aşîkardır. Firmaların e-ticaret ciroları bu dönemde rekor seviyelere ulaşmıştır (Deloitte, 2020). Salgın, online gıda perakendelerinden alışverişte ani bir artışa neden olmuştur (Dannenberg ve diğ., 2020).

Pandemi süreci, tüketici davranışlarında da değişikliklere yol açmıştır. Sürecin ilk aşamasında müşteriler tarafından temel ihtiyaç ve temizlik ürünleri kategorilerine ilişkin stoklama yapıldığı; fiziksel ve online mağazalarda bu kategorilerdeki ürünlere yönelik stok bulunurluğunda sıkıntılar yaşandığı gözlenmiştir. Bu durum da tüketicilerin muadil ürünlere daha açık hale gelmesine neden olmuştur (Deloitte, 2020). Ayrıca Covid-19 süreci ile ilgili yapılan araştırmalarda tüketiciler, pandemi sonrası süreçte temel ihtiyaç ve temizlik ürünleri kategorilerinde online alışverişe devam edeceklerini belirtmişlerdir (Dal, 2020).

Tüm bu gelişmelere bağılı olarak; perakende firmalarının etkin talep yönetimine daha fazla odaklanmaları zorunlu hale gelmiştir. Perakendeciler tarafından uzun yıllardır kullanılan geleneksel, statik, kural bazlı fiyatlandırma sistemleri; piyasaya yeni bir ürün girdiğinde, bu ürünün ve diğler ürünlerin değışen taleplerinin fiyat üzerindeki etkisinin doğru bir şekilde tahmin edilmesi noktasında eksik kalmaktadır (Elmaghraby ve Keskinocak, 2003; Talluri ve Van Ryzin, 2006). Dolayısıyla bu durum; yok satmaya düşmemek, tahmin doğruluğı yüksek talep tahminlerini yapmak, kârlılık ve ciro artışını sağlamak ve rekabet avantajı elde etmek için, fiyat optimizasyonunun yapıldığı dinamik fiyatlandırma sistemlerinin ve sonuç olarak veriye dayalı karar destek sistemlerinin kullanılmasını kaçınılmaz kılmaktadır.

Dinamik Fiyatlandırma; sınırlı bir planlama dönemi içerisinde, eldeki önceden belirlenmiş stok düzeyi tükenirken, beklenen gelir akışını maksimize edecek satış fiyatlarının dinamik olarak ayarlanması olarak tanımlanmaktadır. Uygulamalar açısından dinamik fiyatlandırma çalışmaları; özellikle yüksek başlangıç maliyeti, tükenir nitelikte kapasite, kısa satış dönemi ve

fiyata duyarlı talep yapısına sahip endüstrilerde iyi sonuç vermektedir (Capocchi ve diğ., 2019). Dolayısıyla dinamik fiyatlandırma sistemi; tahmin doğruluğu yüksek algoritmanın geliştirilmesi nedeniyle stok maliyetlerinin düşürülmesini sağlaması, satış kayıplarını önlemesi, fiyat optimizasyonu ile kârlılık ve ciro artışını sağlaması nedeniyle perakendeciler için hayati önem taşımaktadır (Talluri ve Van Ryzin, 2006).

Bu bağlamda bu tez çalışmasında; bir gıda perakendesi firmasında, gelir optimizasyonunu sağlamak amacı ile dinamik fiyatlandırma karar destek sistemi modeli geliştirilmektedir. Geliştirilen karar destek sistemi; veri ön işleme, veri kazıma, talep tahmini modülü ve optimizasyon modülü olmak üzere dört aşamadan oluşmaktadır.

Veri ön işleme aşamasında perakende firmasından elde edilen ham veri, veri temizleme ve özellik mühendisliği işlemlerinden geçirilerek, talep tahmini algoritmalarında kullanılabilir hale getirilmektedir. Veri kazıma işlemi ile rakip firmaların ele alınan ürünlere ait fiyat verileri web sitelerinden çekilerek, veri setine aktarılmaktadır. Talep tahmini aşamasında; doğruluğu yüksek talep tahmini gerçekleştirebilmek amacı ile, son teknoloji ağaç tabanlı makine öğrenmesi algoritmalarından yararlanılmaktadır. Optimizasyon aşamasında ise; metasezgisel algoritmalarından yararlanılarak, kârı maksimize etmek için en iyi tahmin yöntemine dayalı fiyat en iyilemesini baz alan optimizasyon sistemi yapılandırılmaktadır.

Tez çalışmasının genel akışı şu şekildedir. Genel kısımlar bölümünde; öncelikle gelir yönetimi kavramı ve tarihsel gelişimi anlatılarak, gelir yönetiminin fiyatlandırma ile olan bağlantısı açıklanmaktadır. Ardından literatürde yer alan popüler fiyatlandırma stratejileri detaylı aktararak, bu tez çalışmasında kullanılacak dinamik fiyatlandırma stratejilerine açıklık getirilmektedir. Daha sonrasında, literatürde yer alan perakende sektöründeki dinamik fiyatlandırma çalışmaları detaylı bir şekilde analiz edilmektedir. Ayrıca, tez çalışması kapsamında kullanılacak tahminleme ve optimizasyon algoritmalarının genel bir tanıtımı yine bu bölümde yapılmaktadır.

Malzeme ve yöntem bölümünde; kullanılacak veri setinin nasıl elde edildiği açıklandıktan sonra, veri setinin analizi yapılarak, çalışmada kullanılan yazılımlar, yöntem olarak seçilen dağıtık rassal orman algoritması, gradyan artırım makinesi, ekstrem gradyan artırım ağaçları algoritması, parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi algoritmaları detaylı bir şekilde ele alınmaktadır.

Bulgular kısmında; öncelikle veri ön işleme ve veri kazıma süreçleri gerçekleştirilmektedir. Ardından; dağıtık rassal orman, gradyan artırım makinesi, ekstrem gradyan artırım ağaçları algoritmaları ile talep tahmini modelleri kurularak modellerin sonuçları çeşitli performans ölçütleri açısından karşılaştırılmaktadır. En iyi performansın elde edildiği algoritma ile talep tahmini yapılarak optimizasyon aşamasına geçilmektedir. Optimizasyon modülünde; kârı maksimize etmek amacı ile parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi metasezgisel algoritmaları ile optimizasyon modelleri kurularak, iki modelin sonuçları paylaşılmaktadır. Burada, en iyi performansın elde edildiği genelleştirilmiş tavlama benzetimi algoritması modeli ile her bir ürün optimum fiyat verileri ve perakende firmasının toplam kârı elde edilmektedir.

Tartışma ve Sonuç kısmında ise bulgular doğrultusunda genel bir değerlendirme yapılarak, gelecekteki çalışmalar için önerilere yer verilmektedir.

2. GENEL KISIMLAR

Bu bölümde, gelir yönetimi kavramı ve tarihsel gelişimi anlatılarak, gelir yönetiminin fiyatlandırma ile olan bağlantısı açıklanacaktır. Ardından; literatürde yer alan popüler fiyatlandırma stratejileri detaylı aktararak, bu tez çalışmasında kullanılacak dinamik fiyatlandırma stratejilerine açıklık getirilecektir. Daha sonra, literatürde yer alan perakende sektöründeki dinamik fiyatlandırma çalışmaları detaylı bir şekilde analiz edilecektir. Ayrıca yine bu bölümde, tez çalışmasında kullanılacak tahminleme ve optimizasyon algoritmalarının genel bir tanıtımı yapılacaktır.

2.1. GELİR YÖNETİMİ

Bir ürün veya hizmetin her bir satıcısı, çok sayıda temel karar verme problemi ile karşı karşıya kalmaktadır. Bir emlakçı, bir evi ne zaman satışa vereceğine, liste fiyatını ne kadar belirleyeceğine, hangi fiyat teklifini kabul edeceğine ve liste fiyatını ne zaman ve ne kadar düşüreceğine karar vermelidir. Benzer şekilde otel endüstrisinde, maksimum kârı elde edebilmek için oteldeki hangi odanın, hangi müşteri grubuna, ne zaman ve hangi fiyata satılacağına kararının verilmesi gerekmektedir. Belirtilen bu problemleri daha geniş ölçekte incelemek gerekirse, bir firmanın karşılaştığı problemleri aşağıdaki gibi sıralamak mümkündür:

- Bir firma, farklı satın alma davranışları gösteren ve alım gücü olan müşterilerini segmentlere nasıl ayırmalıdır?
- Bir firma, müşterilerini segmentlere ayırdıktan sonra, her segment için hangi fiyatları talep etmelidir?
- Firma farklı kanallarda satış gerçekleştiriyorsa, her kanalda aynı fiyatı kullanmalı mıdır?
- Fiyatlar, mevsimsel faktörlere ve her bir ürün için bugüne kadar gözlenen talebe bağlı olarak nasıl ayarlanmalıdır?
- Bir firma, tamamlayıcı ürünler (bağımlı iki havayolu uçuşundaki koltuklar) veya ikame ürünler için fiyatlandırma ve alokasyon kararlarını nasıl yönetmelidir?

Bu bağlamda “gelir yönetimi”, yukarıda sıralanan talep yönetimi kararları ve bu kararları vermek için gerekli olan sistem ve metodolojiler ile ilgilenmektedir. Gelir yönetimi talep

yönetiminde yer alan çok çeşitli teknikleri, kararları, yöntemleri, süreçleri ve teknolojileri belirtmek için kullanılan standart bir terimdir (Talluri ve Van Ryzin, 2006). Gelir yönetimi ayrıca, üretim ve teslimat maliyetini düşürmek amacı ile bir firmanın tedarik kararlarını ve süreçlerini ele alan tedarik zinciri yönetiminin tamamlayıcısı olarak düşünülebilmektedir.

Gelir yönetimi çalışmaları 1970'lerin sonunda havayolu endüstrisi ile ilgi görmeye başlamış ve bu tarihten itibaren otel, yolcu gemileri, kiralık araba endüstrisi, perakende gibi birçok sektörde başarıyla uygulanmıştır. Gelir yönetiminin en temel amacı, geliri en üst düzeye çıkarmak için müşterilerin ve rakiplerin davranışlarını tahmin etmektir. Gelir yönetimini kullanan firmalar, olayların müşteri ve rakip davranışları üzerindeki etkilerini analiz etmek için periyodik olarak geçmişteki durumları gözden geçirmekte ve fiyatlandırma kararlarını ayarlayabilmek için gelecekteki olayları da dikkate almaktadırlar.

Fiyat, bir firmanın gelirinde önemli derecede etkisi olan bir parametredir. Ayrıca fiyat parametresi, doğrudan ve güçlü bir şekilde kâr marjını ve pazar payını etkilemektedir. Fiyatın %1 oranında değiştirilmesinin günlük tüketimde en az %10'luk bir değişikliğe yol açtığı Dolgui ve Proth (2010) tarafından gösterilmiştir. Dolayısıyla kârın bir ayarlama parametresi olan fiyat, rekabeti artırmanın en kolay ve hızlı yoludur. Bu nedenle sektörde kullanılan ve literatürde de incelenen birçok fiyatlandırma stratejisi mevcuttur.

2.2. FİYATLANDIRMA STRATEJİLERİ

Bu bölümde, literatürde en popüler olan fiyatlandırma stratejileri incelenecektir.

2.2.1. Yüksek veya Düşük Fiyat Stratejisi

Yüksek fiyat stratejisi; müşteriler tarafından ürünün algılanan fiyat değeri yüksek olduğu durumda önerilmekte, aksi takdirde böyle bir strateji ticari başarısızlıkla sonuçlanabilmektedir. Yüksek fiyat stratejisine bir örnek olarak, organik gıda perakendesini vermek mümkündür. Tüketiciler, düşük fiyatları düşük kaliteli organik gıda ile ilişkilendirdiklerinden; bu durum, yüksek fiyatları tüketiciler tarafından kabul edilebilir kılmaktadır (Grunert ve Aachmann, 2016; Wu ve diğ., 2019). Lüks kozmetik ve moda endüstrilerinde de bu stratejinin çok sayıda örneği bulunmaktadır. Lüks ürün endüstrisinde yüksek fiyat, dezavantajdan çok satış tekniğidir (Dolgui ve Proth, 2010).

Ürün piyasada yeni olduğu durumda talep üzerinde fiyat önemli bir rol oynamasına rağmen her zaman belirleyici değildir. Buna bir örnek olarak Apple'ın MP3 pazarındaki stratejisini vermek mümkündür. I-Pod, pazardaki benzer ürünler arasında en pahalısı olmasına rağmen kalitesi ve estetiği ile alanında lider konuma gelmiştir. Sonuç olarak I-Pod'un yüksek fiyatı, MP3 pazarında lider olmasını engellememiştir.

Bununla birlikte, düşük fiyatlandırma stratejisinin de gıda perakendeciliği sektöründe ticari başarıya ulaştığı önemli örnekler vardır (Levy ve diğ., 2012). Avrupa'da Lidl, Aldi, Leader Price; Türkiye'de A101, Bim gibi düşük fiyatlı perakendeciler ciddi ticari başarılar elde etmişlerdir. Düşük fiyat stratejisinin başarısı, düşük fiyatlı ürünün çektiği müşteri sayısının artışına bağlı olarak daha yüksek miktarda ürün satılmasında yatmaktadır.

Amazon.com da, fiyatlarını bazen % 40-50 oranında azaltarak ve daha fazla seçenek sunarak kitap pazarında önemli bir pay almıştır. Firma, ürünlerini müşterilerine doğrudan İnternet aracılığıyla dağıtması ile maliyetlerde düşüş elde etmiş ve bu durum fiyatları büyük ölçüde düşürmüştür. Böylelikle Amazon.com rekabetçiliğin artmasını sağlamıştır.

Yukarıda belirtilen avantajlarına rağmen yüksek veya düşük fiyat stratejisi, bazı dezavantajları da beraberinde getirmektedir. Firma tarafından satılan ürünün fiyatının sabit tutulması, karar verme sisteminin esnekliğini azaltabilmektedir. Bir ülkenin genel olarak yoksullaşması gibi faktörler, lüks ürün satışı yapan firmaları önemli derecede etkileyebilmektedir. Ayrıca bu stratejiler, kurumsal imajdan en iyi şekilde yararlanarak müşteri çekmeye odaklandığından, dondurulmuş stratejiler olarak tanımlanabilmektedirler (Dolgui ve Proth, 2010).

2.2.2. Pazar Segmentasyonu Stratejisi

Pazar segmentasyonu stratejisi; bir ürün veya hizmet tarafından sunulan çeşitli fayda ve özelliklere, farklı müşteri gruplarının farklı önem vermelerine dayanan bir planın geliştirilmesidir. Örneğin; aynı araba modelinin farklı sürümleri, farklı bir müşteri türünü çekebilmektedir. Bu fiyatlandırma stratejisi, pazarı segmentlerine ayırarak müşterilerin her bir segmentteki ürünü satın almak için az ya da çok ödeme yapma istekliliğine bağlı olarak, müşterilerden farklı bir fiyat talep edilmesine dayanmaktadır (Levy ve diğ., 2012).

2.2.3. İndirimli Satış Stratejisi

İndirimli satış stratejisi; belirli bir ürün grubunun sınırlı bir süre için, indirimli bir fiyata satılmasına dayanmaktadır. Bu indirim, gelirdeki azalmayı telafi etmek için yeterli ek satışları beraberinde getirmelidir. Ancak bu durumun nadiren olduğu ve çok az şirketin indirim maliyetini fark ettiği savunulmaktadır (Levy ve diğ., 2012).

2.2.4. Fiyat Kayması (Price Skimming) Stratejisi

Bu stratejide ilk önce nispeten yüksek bir fiyat belirlenmekte ve zaman içinde bu fiyat düşürülmektedir (Levy ve diğ., 2012). Bu strateji, pazar segmentasyonu stratejisinden zaman faktörü ile farklılaşmaktadır. Fiyat kayması, araştırma ve geliştirme için harcanan dev yatırımların geri dönüşünün alınması noktasında önemlidir. Fiyat kayması genellikle, müşterilerin görece fiyat duyarlılığının düşük olduğu ya da bazı inovasyonların müşterileri heyecanlandığı durumlarda (özellikle elektronik ürünler) gerçekleşmektedir. Ancak yüksek bir fiyat, ürünün orijinallğine dayanarak tek bir pozisyonda olması durumu dışında, gerçekte uzun süre korunamaz.

2.2.5. Pazara Giriş Fiyatlandırması Stratejisi

Pazara giriş fiyatlandırması (Penetrasyon fiyatlandırması) stratejisi, ilk fiyatın piyasa fiyatından daha düşük belirlenmesi stratejisidir (Levy ve diğ., 2012). Buradaki motivasyon; fiyatın, müşterilerin satın alma alışkanlıklarını değiştirecek düzeyde düşük tutulmasına bağlı olarak daha büyük bir pazar payı elde etmektir. Bu strateji, zaman faktörü ile zenginleştirilmiş düşük fiyatlandırma stratejisi olarak da tanımlanabilmektedir. Strateji, maliyet düşürücü baskıya neden olmakta ve rakiplerin pazara girişini engellemektedir (Dolgui ve Proth, 2010).

2.2.6. Dinamik Fiyatlandırma Stratejisi

Bir firma için, tüketicilerin ödemeye razı olduğu fiyatlara göre ürün veya hizmetin fiyatını değiştirebilmesi önemlidir. Dinamik fiyatlandırma, ürün ya da hizmetin değerinin zaman veya talebe bağlı olarak belirlendiği bir stratejidir (García-Calderón Chávez, 2017).

Dinamik fiyatlandırma, ticaretin kendisi kadar eski bir terim olmasına rağmen; talep tahminindeki, optimizasyon algoritmalarındaki ve yazılımdaki gelişmeler ile son 20 yılda popülerlik kazanmış bir terimdir. Dinamik fiyatlandırma birçok sektörde uygulanmasına rağmen, havayolları ve otel işletmeleri ile tanınmış ve ilişkilendirilmiştir (Talluri ve Van Ryzin,

2006). Bu sektörlerde, talebin yüksek olduğu sezonlarda mümkün olan en yüksek verimi elde etmek için dinamik fiyatlandırma teknikleri kullanılmaktadır. Talep arttıkça fiyatlar artırılarak, yılın düşük sezonları telafi edilmektedir.

Talep bazlı fiyatlandırma, zamana dayalı fiyatlandırma ve rakipleri baz alan fiyatlandırma olmak üzere birden fazla dinamik fiyatlandırma stratejisi literatürde yer almaktadır.

2.2.6.1. Talep Bazlı Fiyatlandırma

Talep bazlı fiyatlandırma; müşterilerin, farklı fiyat seviyelerine olan duyarlılığına odaklanmaktadır (Brassington ve Petitt, 2005; Faith ve Agwu, 2018). Fiyatlandırma, talep ve piyasa göz önünde bulundurularak belirlenmektedir. Bu fiyatlandırma stratejisinde belirlenen fiyat, müşterinin ürün algısına uygun olmadığı durumda çok yüksek veya çok düşük fiyat olarak algılanmaktadır (Faith ve Agwu, 2018).

Talep bazlı fiyatlandırmaya örnek olarak Uber'ın fiyatlandırma algoritmasını incelemek mümkündür. Uber'ın temel fiyatlandırma algoritması; gelişmiş büyük veri teknolojisi ve müşteri görüşlerinden yararlanarak, fiyat elastikiyeti ve coğrafya gibi değişkenler ile arz ve talebi tahminlemektedir. Bu bilgilerden yararlanarak Uber; günün, haftanın ve ayın farklı zamanlarında optimum fiyatı üretmektedir. Örneğin sağanak yağışlar, şehirdeki büyük çapta etkinlik ve festivaller, iş çıkışı saatleri gibi zamanlarda, artan talebe bağlı olarak fiyatlarda muhtemel artış gerçekleşmektedir (Philips, 2019).

2.2.6.2. Zamana Dayalı Fiyatlandırma

Birçok sektör, günün saatine veya mevsime bağlı olarak fiyatlarını değiştirmektedir. Satın alma davranışını etkileyen faktörler arasında ilk akla gelenler coğrafya ve hava durumudur. Dış mekan ekipmanları satan bir perakendeci, hava soğukluğuna bağlı olarak fiyatlarını düşürebilmekte veya yükseltebilmektedir. Yağışlı havalarda caddelerde satılan şemsiye fiyatlarının normalden daha fazla olduğu görülmektedir. Benzer şekilde Kara Cuma, Bekarlar Günü, okula dönüş sezonu gibi zamanlar, daha fazla insanın alışveriş yapmasını sağlamaktadır.

2.2.6.3. Rekabete Dayalı Fiyatlandırma

Rakipleri baz alan fiyatlandırma; ürün veya hizmetlerin başlangıç fiyatını belirlemek için, rakiplerin öngörülen veya gözlemlenen fiyatlarını birincil kaynak olarak kullanmaktadır (Hinterhuber 2008, Faith ve Agwu, 2018).

Fiyat; rakiplerden daha düşük ya da daha yüksek tutulmaya çalışılmaktadır. Çünkü fiyat ile talep arasında katı bir ilişki aranmamaktadır (Kerin ve Hartley, 2015; Faith ve Agwu, 2018). Birçok e-ticaret firması, rakipleri baz alan fiyatlandırma stratejisini kullanmaktadır. Bu stratejinin güçlü noktası, fiyat verisinin hazır olmasıdır. Stratejinin zayıf noktaları ise; rakiplerin fiyatlandırmasında hata olabileceğinin ve tüketicinin dikkate alınmamasıdır (Faith ve Agwu, 2018).

2.3. PERAKENDE SEKTÖRÜNDE DİNAMİK FİYATLANDIRMA

Perakendecilik, tüketicilere kişisel veya aile kullanımları için satılan ürün ve hizmetlere değer katan bir dizi ticari faaliyet olarak tanımlanmaktadır. Bu katma değerli faaliyetler arasında ürün çeşitliliği, toplu satış, envanter tutma ve servis hizmeti sağlama yer almaktadır. Perakendecilik, küresel ekonomide önemli bir rol oynayan ileri teknoloji endüstrisidir. Perakendeciler ürün ve hizmetlerini; mağaza, internet ve katalog gibi birden fazla kanal üzerinden satmaktadırlar. Kuru temizleme, otomobil tamiri gibi tüketicilere hizmet veren firmalar da perakendeci kategorisindedir (Levy ve diğ., 2012).

Perakende sektöründe gelir yönetimi alanında uzmanlaşmış birçok yazılım firması, indirim optimizasyonuna yönelik çalışmalar gerçekleştirmektedir. Özellikle hazır giyim ve diğer mevsimlik ürün perakendecileri, kârın maksimizasyonuna yönelik fiyatlandırma kararlarının önemine dayanan bilimsel yazılımların geliştirilmesinde ön plana çıkmaktadırlar (Talluri ve Van Ryzin, 2006).

Geçmiş satış verilerini ve mevcut envanteri kullanarak oluşturulan talep modelleri, indirim optimizasyonu kararlarının zamanlamasını ve büyüklüğünü tahminleyen en iyileme modellerinin girdisi niteliğindedir. Bu fiyatlandırma yazılım sistemlerini kullanan birçok firma, gelir artışı elde ettiklerini belirtmişlerdir (Talluri ve Van Ryzin, 2006; Caro ve Gallien, 2012).

2.3.1. Dinamik Fiyatlandırma Stratejilerine E-ticaret Sitelerinin Katkısı

Elektronik ticaret veya internet ticareti olarak da bilinen E-ticaret, interneti kullanarak mal veya hizmet alım satımını ve bu işlemleri gerçekleştirmek için para ve veri transferini içinde barındırmaktadır. E-ticaret genellikle fiziksel ürünlerin çevrimiçi satışına atıfta bulunmak için kullanılmaktadır; ancak aynı zamanda internet aracılığıyla kolaylaştırılan her türlü ticari işlemi de tanımlamaktadır (Levy ve diğ., 2012).

E-ticaret, müşteri verilerinin analiz edilmesi ile karmaşık fiyatlandırma stratejilerini geliştirerek ve satıcıların zaman içinde fiyatlarını hızlı ve masrafsız bir şekilde değiştirmelerini sağlayarak, perakendecilerin fiyat stratejilerini etkileme potansiyeline sahiptir. E-ticaretin sunduğu birçok fırsat, yalnızca çevrimiçi (online) mağazalar ile sınırlı kalmamakta, fiziksel mağazalara da uygulanabilmektedir. Elektronik raf etiketleme sistemlerinin ortaya çıkması, fiziksel mağazaların da hızlı bir şekilde fiyatlarını değiştirmesine izin vermektedir.

Satış noktası (Point of Sale) verilerinin mevcudiyeti, satışlar hakkında veri sağlamak ve sadakat programlarının uygulanması, fiziksel mağazaların, müşterilerinin zaman içerisindeki satın alımlarını izlemelerini sağlamaktadır. Modelleme açısından bakıldığında online ve fiziksel mağazalar, fiyatlandırma sorunları ve kararları gibi birçok yönden birbirine benzerdir (Elmaghraby ve Keskinocak, 2003). Bununla birlikte; online satış ortamını fiziksel mağaza ortamından farklı kılan, yeni ve ilgi çekici araştırma sorularını ortaya çıkaran bazı özellikleri söz konusudur.

Aşağıda bu özelliklerden, müşterilerin tarama ve seçim sürecini gözlemleme ve kişiselleştirilmiş fiyatlandırma/promosyon/envanter politikalarını gerçek zamanlı olarak uygulama yeteneği olmak üzere iki özelliğe odaklanılmaktadır.

2.3.1.1. Müşterilerin Satın Alma Davranışları Hakkında Bilginin Toplanması Özelliği

Fiziksel mağazalardan toplanan veriler, online mağazalara kıyasla sınırlıdır. Birçok e-ticaret sitesinde satın alma işlemi öncesinde “kaydolmak” için müşterinin temel kişisel bilgilerini (isim, adres, yaş, meslek) girmesi gerekmektedir. Bu bilgiler, müşterinin satın alma geçmişi ile birleştirilerek; müşterileri belirli pazar segmentlerine ayırmada ve böylelikle her segmentin talebinin daha doğru bir şekilde tahmin edilmesinde kullanılmaktadır. Dolayısıyla online satış ortamı, bir satıcının bir müşterinin satın alma davranışını gerçek zamanlı olarak gözlemlemesini ve analiz etmesini sağlayarak büyük avantaj sunmaktadır.

Müşterilerin satın alma davranışlarını inceleyen çok sayıda İşletmeden Tüketicie (Business to Consumer) firma bulunmaktadır ve bu firmalar, müşterilerin hangi ürünlere bakıp satın almadığını ve neden satın almadığını analiz etmektedirler. Bunun için makine öğrenmesine dayanan analitik fiyatlandırma yazılımları kullanılmaktadır.

Bununla birlikte; fiziksel mağazalarda perakendeci, belirli bir müşterinin satın alma kararını (hangi ürünlere baktığı ancak satın almadığı gibi) sistematik olarak gözlemleyememektedir.

Ancak son yıllarda sadakat programları ile müşterilerin satın alma geçmişleri takip edilerek, firmalar tarafından kişiselleştirilmiş promosyonlar yapılmaktadır.

2.3.1.2. Kişiselleştirme Fiyatlandırma Özelliği

Müşterilerin satın alma davranışları hakkında detaylı bilgi toplamayı sağlayan yazılımlar; yalnızca talebi daha iyi anlamayı değil, aynı zamanda satın alma deneyimini her bireysel alıcı için kişiselleştirilmeyi de sağlamaktadır. Perakendeciler görüntülenen online mağazayı (web sayfasını), farklı ürün ve fiyat çeşitliliği sağlayarak her bir müşteri için özelleştirebilmektedirler. Örneğin e-ticaret devi Amazon.com, her bir müşterinin satın alma geçmişini ve sitede taradığı ürünleri göz önünde bulundurarak müşterilerine ürün önermektedir.

Bununla birlikte kişiselleştirilmiş fiyatlandırma; yaş, maddi durum, coğrafi konum gibi nitelikleri dikkate alarak; firmanın, oluşturduğu her bir müşteri türüne farklı bir fiyat teklif etmesidir. Kişiselleştirilmiş fiyatlandırma çalışmaları 1920'lerin başlarına dayanmaktadır ve satıcının kârını artırmanın etkili bir aracıdır (Elmaghraby ve Keskinocak, 2003). Online perakendeciliğin artan bilgi yeteneklerinden büyük ölçüde faydalanmayı amaçlayan kişiselleştirilmiş fiyatlandırmanın bir biçimi, müşterilerin alışveriş yaparkenki davranışlarına göre farklı fiyatlar belirleyen “davranışsal” fiyat ayrımcılığıdır. Bu fiyatlandırma stratejisi; müşterilerin hangi web sitelerini, hangi sıra ile ziyaret ettiklerini; satın alma işlemini hangi durumda, ne zaman gerçekleştirdiklerini ya da gerçekleştirmediklerini incelemektedir.

2.3.2. Perakende Sektöründe Dinamik Fiyatlandırma İle İlgili Literatür Analizi

Dinamik fiyatlandırma uygulamalarındaki sayısız başarı öyküsü, literatürdeki çeşitli dinamik fiyatlandırma problemlerine hızla artan bir araştırma motivasyonu olmuştur. Bu bölümde, literatürde yer alan perakende sektöründeki dinamik fiyatlandırma çalışmaları farklı başlıklar altında detaylı bir şekilde analiz edilmektedir.

2.3.2.1. Perakende Sektöründe Dinamik Fiyatlandırma İle İlgili Genel Literatür Çalışmaları

Elmaghraby ve Keskinocak (2003), dinamik fiyatlandırma ile ilgili güncel uygulamaları ve literatürü incelemişlerdir. Pazarda uygulanabilirliğini ve pratikte artan kullanımını göz önünde bulundurarak, envanter bulunurluğuna dayalı dinamik fiyatlandırma üzerine odaklanmışlardır.

Bitran ve Caldentey (2003), dinamik fiyatlandırma politikalarının araştırmalarını, sonuçlarını ve bunların gelir yönetimi ile olan ilişkilerini incelemişlerdir. Çalışma; bozulabilir ve

yenilenemeyen bir kaynak kümesinin, sınırlı bir süre zarfında stokastik fiyat duyarlı talep süreçlerini karşıladığı genel bir gelir yönetimi sorununa dayanmaktadır. Bu problem sınıfında bu kaynakların sahibi (veya satıcısı), bunları son müşterilere nihai kaynaklardan oluşan bir menü üretmek ve sunmak için kullanmıştır. Bu bağlamda Bitran ve Caldentey, satıcının karşılaştığı stokastik kapasite kontrol problemini formüle etmişlerdir. Problemin kapsamı, satış ufkü üzerinde toplam geliri en üst düzeye çıkarmak için menü ve ürün miktarını ve bunlara karşılık gelen fiyatları dinamik olarak ayarlamaktır.

Bilişik ve Gürgen (2012), perakende sektöründe dinamik fiyatlandırma uygulamaları ile ilgili kapsamlı bir literatür taraması gerçekleştirmişlerdir. Perakendecilik sektöründe dinamik fiyatlandırma ile ilgili yapılan çalışmaları çeşitli özelliklerine göre sınıflandırmışlardır. Ayrıca, literatürdeki çalışmaların eksikliklerini ve gelecekteki araştırmalar için olası araştırma konularını irdelemişlerdir.

Chen ve Chen (2015), dinamik fiyatlandırma araştırmalarındaki yeni eğilimleri incelemişlerdir. Çoklu ürünler, rekabet ve sınırlı talep bilgisi ile ilgili sorunlar üzerine mevcut araştırmaları gözden geçirmişlerdir. Bu çalışmada ayrıca, gelecekteki araştırmalar için olası araştırma konuları önermişlerdir.

Den Boer (2015), fiyatlandırma ve talep tahmini konularındaki nicel araştırmaların tarihsel kökenine kısa bir giriş yaparak, dinamik fiyatlandırma ile ilgili literatür taraması gerçekleştirmiştir. Bu çalışmada Den Boer, yöneylem ve yönetim bilimleri literatürüne odaklanmış; ancak pazarlama, ekonomi, ekonometri ve bilgisayar bilimlerinin katkılarını da tartışmıştır. Ayrıca Den Boer, gelecek çalışmalar için araştırma yönlerini irdelemiştir.

Faith ve Agwu (2018), fiyatlandırma stratejilerinin tüketim mallarının satın alımına etkisini incelemişlerdir. Çalışmalarında, e-ticareti ve rakiplerin fiyatlarının tüketicilerin satın alma kararına olan etkisi üzerinde yoğunlaşmışlardır. Fiyatlandırma stratejileri ve satın alma karar süreci ile ilgili detaylı bilgi sağlayarak literatüre katkıda bulunmuşlardır.

Tablo 2.1’de perakende sektöründe dinamik fiyatlandırma ile ilgili incelenen genel literatür çalışmaları özetlenmektedir.

Tablo 2.1 : Perakende sektöründe dinamik fiyatlandırma ile ilgili genel literatür çalışmaları.

<i>Yayın</i>	<i>İçerik</i>
Elmaghraby ve Keskinocak (2003)	Envanter bulunurluğuna dayalı dinamik fiyatlandırma üzerine odaklanarak, dinamik fiyatlandırma literatürünü incelemişlerdir.
Bitran ve Caldentey (2003)	Dinamik fiyatlandırma politikalarının araştırmalarını ve sonuçlarını ve bunların gelir yönetimi ile olan ilişkilerini incelemişlerdir.
Bilişik ve Gürgen (2012)	Perakende sektöründe dinamik fiyatlandırma uygulamaları ile ilgili kapsamlı bir literatür taraması gerçekleştirmişlerdir.
Chen ve Chen (2015)	Çoklu ürünler, rekabet ve sınırlı talep bilgisi ile ilgili sorunlar üzerine mevcut araştırmaları gözden geçirmişlerdir.
Den Boer (2015)	Dinamik fiyatlandırma ile ilgili literatür taraması yapmıştır.
Faith ve Agwu (2018)	Fiyatlandırma stratejilerinin tüketim mallarının satın alımına etkisini incelemişlerdir.

2.3.2.2. E-ticaret Sitelerinde Dinamik Fiyatlandırma Çalışmaları

Anjos ve diğerleri (2005), optimum fiyatlandırma stratejisinin doğrudan tanımlanabileceği sürekli fiyatlandırma fonksiyonu ailesi sunmuşlardır. Bu fiyatlandırma fonksiyonlarının; internetin artan rolüne bağlı olarak ürün ve hizmetleri pazarlamak için uygun olan genel fiyatlandırma metodolojisinin temeli olduğunu ifade etmişlerdir. Belirtilen genel metodoloji, tek yönlü fiyatlandırma altında en uygun uçak bileti fiyatını bulmak için büyük bir İngiliz havayolu şirketi tarafından uyarlanmıştır. Anjos ve diğ. (2005) aynı zamanda; belirli bir zamanda belirli bir ürün ve servisin potansiyel müşteri sayısını modellemeye imkan tanıyan bu metodolojiye, rakiplerin fiyatlandırma stratejileri hakkında bilinen herhangi bir bilgiyi gerçek zamanlı olarak dahil etmenin mümkün olduğunu ifade etmişlerdir.

Ferreira ve diğ. (2015); bir perakendecinin fiyatlandırma kararlarını günlük olarak optimize etmek için, veri zenginliğinin nasıl kullanılabileceğini göstermek adına Rue La La online perakendesini incelemişlerdir. Perakendecinin yaşadığı temel zorluklardan biri, satış ve gelirin çoğunluğunu oluşturan, daha önceden hiç satılmayan ürünlere olan talebi ve fiyatı belirlemektir. Bu zorluğun üstesinden gelmek için, geçmiş satış kaybını ve gelecek ürünlerin talebini tahmin etmek amacı ile makine öğrenme tekniklerini kullanmışlardır. Parametrik olmayan talep tahmini modellerinde, bir ürünün talebinin rakip ürünlerin fiyatına olan bağımlılığı, talep tahminlerinin fiyat politikasına dönüştürülmesinde yeni zorluklar oluşturmaktadır. Ferreira ve diğerleri çalışmalarında; referans fiyat etkilerini içeren çoklu ürün fiyat optimizasyonunu etkin bir şekilde çözmek için bir algoritma geliştirmişlerdir ve bu algoritmayı Rue La La'nın günlük

kullanımı için bir fiyatlandırma karar destek aracı haline getirmişlerdir. Yapılan denemede, uygulanan karar destek aracı ile orta ve yüksek fiyatlı ürünlerde fiyat artışının satışları düşürmediğini kanıtlamışlardır. % 90' lık güven aralığında, test grubunun gelirindeki yaklaşık % 9,7' lik bir artışı tahmin etmişlerdir.

Zhang ve diğ. (2017); müşterilerin alışveriş sepetindeki ürünlerine indirim uygulanması (promosyon) stratejisinin, kısa ve uzun dönemde müşteri davranışını nasıl etkilediğini incelemişlerdir. Bu amaçla, Alibaba e-ticaret platformunda, 100 milyondan fazla müşteri ve 11 bin perakendeciyi içeren bir deney gerçekleştirmişler ve fiyat promosyonlarının, tüketici etkileşimi ve stratejik davranışı üzerindeki uzun vadeli etkilerini araştırmışlardır. Buna göre; kısa vadede, promosyon uygulanan ürünlerde satışların iki katına çıktığı ve uzun vadede bu promosyon programının olumlu ve olumsuz yönlerinin olduğu sonucuna ulaşılmıştır. Zhang ve diğerleri bu promosyon stratejisinin; müşteri katılımını, müşterilerin günlük gördüğü ürün sayısını ve satın alma oranlarını artırarak olumlu katkıda bulunduğunu belirtmişlerdir. Promosyon stratejinin olumsuz yönleri ise; müşterilerin ileride daha düşük fiyata alabilme olasılığı ile satın almayı ertelemeleri ve alışveriş sepeti indirimlerinden daha fazla yararlanabilme niyeti ile alışveriş sepetine eklenen ürünlerin oranını artırmaları olarak sunulmuştur.

Fisher ve diğ. (2017); fiyatların talep şokları ile ilişkili olması nedeniyle, rassal fiyatlara sahip bir saha deneyi gerçekleştirmişlerdir. Rakiplerin belirli bir ürüne ait fiyatları ve bulunurluk bilgisi, rakip web sitelerini inceleyerek elde edilebilecek bir veri iken; rakiplerin satış bilgilerinin olmaması, kapsamlı bir tüketici tercih modelinin oluşturulmasında sorun teşkil etmektedir. Bu soruna çözüm olarak Fisher ve diğerleri; perakendecinin kendi ve rakiplerinin stokta bulunmama durumunu, rakiplerin fiyatları ile birlikte dikkate alan tüketici tercih modelini önermişlerdir. Önerilen model; tahminleri baz alarak, dikkatli bir şekilde kontrol edilen ve beş hafta süren canlı bir deney ile test edilmiştir. Deney sonuçları, %11'lik bir gelir artışı olduğunu ve perakendeci tarafından belirlenen hedefin üstünde bir marjın sağlandığını göstermiştir. Rakip fiyat değişikliklerine doğru tepki verme noktasında ise; perakendecilerin, tüketici ile olan etkileşiminin ve tüketicinin katılımının kritik olduğu sonucuna ulaşılmıştır.

Tablo 2.2'de e-ticaret sitelerinde dinamik fiyatlandırma çalışmalarına yönelik bilgiler özetlenmektedir.

Tablo 2.2 : E-ticaret sitelerinde dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Anjos ve diğ. (2005)	İnternet'in ürün ve hizmetleri pazarlamak adına bir araç olarak artan rolünü modellemek için uygun olacağını savunan, optimum fiyatlandırma stratejisinin doğrudan tanımlanabileceği sürekli fiyatlandırma fonksiyonu ailesi sunmuşlardır.	Sürekli fiyatlandırma fonksiyonu modelleri
Ferreira ve diğ. (2015)	Fiyatlandırma kararlarını günlük olarak optimize etmek için veri zenginliğinin nasıl kullanılabileceğini göstermişlerdir.	Regresyon modelleri & Tam sayılı programlama
Fisher ve diğ. (2017)	Perakendecinin kendi ve rakiplerinin stokta bulunmama durumunu, rakiplerin fiyatları ile birlikte dikkate alarak tüketici tercih modeli oluşturup saha deneyi gerçekleştirmişlerdir.	Tüketici Tercih Modeli
Zhang ve diğ. (2017)	Fiyat promosyonlarının tüketici etkileşimi ve stratejik davranışı üzerindeki kısa ve uzun vadeli etkilerini incelenmişlerdir.	Teorik arama modeli

2.3.2.3. Tek Ürün için Dinamik Fiyatlandırma Çalışmaları

Gallego ve Van Ryzin (1994); talebin fiyata duyarlı ve stokastik olduğu durumlar için, firmanın beklenen gelirlerini en üst düzeye çıkarmak amacı ile ürün stoklarının dinamik olarak fiyatlandırılması sorununu araştırmışlardır. Bu sorunu, yoğunluk kontrolü kullanarak formülize etmişler ve stok seviyesinin ve ufkun uzunluğunun bir fonksiyonu olarak en uygun yoğunluk için yapısal monotonik sonuçlar hesaplamışlardır. Belirli bir üstel talep fonksiyonları ailesi için, en uygun fiyat politikasını kapalı biçimde bulmuşlardır. Çalışmalarında Gallego ve Van Ryzin, genel talep işlevleri için; problemin deterministik versiyonunun analizine dayanarak beklenen gelir üzerinde bir üst sınır tespit etmişler ve bu üst sınırı; basit, sabit fiyat politikalarının beklenen satış hacminin sonsuzluğa eğilim göstermesi gibi asimptotik olarak optimal olduğunu kanıtlamak için kullanmışlardır. Gallego ve Van Ryzin sonuçları; sadece sınırlı sayıda fiyat girilebilir, talep oranı zamana göre değişir, işletme maliyetleri tahakkuk ettirilir şeklinde talebin Poisson bileşiği olduğu durumlara genişletmişlerdir.

Bitran ve Wadhwa (1996) mevsimsel ürün fiyatlandırma problemini; sınırlı bir satış süresi ve sabit bir ürün stoğu altında bir perakende ürünü için dinamik optimum fiyatlandırma politikasını belirleme olarak tanımlamışlardır. Bu çalışmada Bitran ve Wadhwa, sorunun yapısı hakkında dört varsayım önermişlerdir. İlk üç varsayım; en uygun fiyatın, stok seviyesinin artışına bağlı olarak artmadığı, talep seviyesinin artışına bağlı olarak azalmadığı ve marjinal gelir fonksiyonun, envanter seviyesindeki artışa bağlı olarak artmadığıdır. Dördüncü varsayım ise; ürün talebinin zaman içinde azalacağını bilindiği durumda, perakendecinin gelecek

dönemlere yönelik ürün stoklamasının fayda sağlamayacağını belirtmektedir. Bitran ve Wadhwa problemin hem deterministik hem de stokastik talep versiyonlarını değerlendirmişlerdir. Farklı talep ve envanter koşulları altında en uygun perakende fiyatlandırma davranışı hakkında bazı ekonomik bakış açıları sunmayı amaçlamışlardır.

Zhao ve Zheng (2000), belirli bir bozulabilir ürün stoğunun sınırlı bir zamanda satılabilmesi için dinamik fiyatlandırma modeli sunmuşlardır. Çalışmada; herhangi bir zamandaki optimum fiyatın, envanter miktarındaki azalmaya bağlı olarak azaldığını göstermişlerdir. Bu durum, zaman ilerledikçe bir müşterinin ürün için yüksek (premium) fiyat ödemeye razı olmadığı koşulunu varsaymaktadır. Zhao ve Zheng kurulan modelin; hem sürekli hem de ayrık fiyat setleri için geçerli olduğunu savunmuşlar ve ayrık fiyat setleri için hesaplamalar üzerinde daha fazla durmuşlardır. Çalışmalarındaki fiyatlandırma modelleri, moda perakendeciliği ve seyahat hizmetleri gibi sektörler için verim yönetiminin neden önemli olduğunu ortaya koymuştur. Ayrıca Zhao ve Zheng mevcut modele rekabeti dahil etmediklerinden; rekabetin dahil olmasının, havayollarının verim yönetimi gibi birçok pratik uygulama için modeli daha kullanışlı hale getireceğini ifade etmişlerdir.

Aydin ve Ziya (2008), promosyon ürünü olarak adlandırdıkları bir ürünün, fiyatlandırma ve indirim problemini incelemişlerdir. İndirim kararlarının; envanter düzeylerine, zamana, kullanılan fiyatlandırma politikasının türüne ve müşterilerin promosyon ürünü rezervasyon fiyatları ile pozitif veya negatif korelasyonlu diğer ürünler arasındaki ilişkiye nasıl bağlı olduğunu araştırmışlardır. Buna göre; firmanın fiyatları ve indirimleri dinamik olarak ayarladığı ve müşterilerin promosyon ürünü için rezervasyon fiyatlarının, satın aldıkları ürün için rezervasyon fiyatları ile negatif bir şekilde ilişkili olduğu tespit edildiği durumda, stok seviyesine ve zamana bakılmaksızın müşterilere her zaman indirim yapıldığı sonucuna ulaşmışlardır. Çalışmanın sayısal sonuçları; statik bir fiyatlandırma sistemi kullanan bir firmanın indirim kararlarını dinamik olarak belirlemesi halinde, müşteri satın alma bilgilerinin kullanılmasının önemli derecede firma yararına olacağını göstermektedir.

Tablo 2.3’de, incelenen tek ürün için dinamik fiyatlandırma çalışmaları özetlenmektedir.

Tablo 2.3 : Tek ürün için dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Gallego ve Van Ryzin (1994)	Talebin fiyata duyarlı ve stokastik olduğu durumlar için, firmanın beklenen gelirlerini en üst düzeye çıkarmak amacı ile ürün stoklarını dinamik olarak fiyatlandırma sorununu araştırmışlardır.	Yoğunluk Kontrolü
Bitran ve Wadhwa (1996)	Mevsimsel ürün fiyatlandırma problemini, sınırlı bir satış süresi ve sabit bir ürün stoğu altında bir perakende ürünü için incelemiştir.	Olasılıklı Talep Modeli & Stokastik Dinamik Programlama
Zhao ve Zheng (2000)	Belirli bir bozulabilir ürün stoğunun sınırlı bir zamanda satılabilmesi için dinamik fiyatlandırma modeli sunmuşlardır.	Homojen talep modeli ve özel durumlar için homojen olmayan talep modeli & Markov Karar Süreci
Aydin ve Ziya (2008)	Promosyon ürünü olarak adlandırdıkları bir ürünün fiyatlandırma ve indirim problemini incelemiştir.	Müşteri satış bilgisinin denkleme ilave edildiği müşteri modeli

2.3.2.4. Çoklu Ürün için Dinamik Fiyatlandırma Çalışmaları

Liu ve Milner (2006); firmalar arasında sözleşmeler doğrultusunda ortak bir fiyat belirlenmesi gerektiğinde, birden fazla ürünün dinamik olarak nasıl fiyatlandırılması gerektiğini incelemiştir. Problemin tanımını ve problemin optimal politikasının yapısını en genel biçimde sunmuşlardır. Problemin, n-segmentli bir fiyatlandırma politikası olan deterministik versiyonuna en uygun politikayı geliştirmişlerdir. Fiyatın önceden belirlendiğini varsayarak, stokastik sorunlar için tek bir fiyat değişikliğine izin verilen bir vakayı ele almışlardır. Bu çalışma, en uygun çözümün genel stokastik probleminin ve problemi etkili bir şekilde çözebilecek buluşsal yöntemlerin oluşturulmasını sağlamıştır.

Aydin ve Ziya (2009); firmaların fiyatlarını belirlerken kullanabilecekleri zaman ve envanter seviyelerine ek olarak, firmaların bireysel müşteri düzeyinde sahip oldukları bilgileri üçüncü bir boyut olarak ele almışlardır. Çalışmalarında tam kişiselleştirme ve kısmi kişiselleştirme olmak üzere 2 model geliştirmişlerdir. Tam kişiselleştirme modelinde, müşteri sinyal verdiğinde firmanın istediği fiyattan ücret alabildiğini; kısmi kişiselleştirme modelinde ise, firmanın iki fiyattan birini talep edebileceğini belirtmişlerdir. Aydin ve Ziya; sinyaller ile müşterilerin ödeme istekliliği arasındaki korelasyonun, sinyal ile optimum fiyatlar arasındaki sezgisel ilişkileri sağlamak için yeterli olmadığını göstermişlerdir. Ayrıca kısmi kişiselleştirme modeli için en uygun fiyatlandırma politikasının, eşik tipi olduğunu ve eşğin envanter seviyesi ve zamana bağlı monotonik olduğunu sunmuşlardır.

Koenig ve Meissner (2010); sınırlı bir periyot boyunca birden fazla ürün satan bir firma için, dinamik fiyatlandırma politikası ile liste fiyatı kapasite kontrol politikası arasındaki farkı analiz etmişlerdir. Çalışmalarında tek bir kaynak olduğunu ve kaynağın miktarının sabit olduğunu varsaymışlar ve birkaç sayısal deney yürütmüşlerdir. Deney sonucunda; fiyatlandırma politikaları arasında beklenen geliri, standart sapmayı ve risk altındaki koşullu değeri karşılaştırmışlardır. Buna göre; dinamik fiyatlandırma politikasının her adımda fiyatlandırma problemini çözüme ulaştırdığını; liste fiyatlandırma politikasının ise fiyatları bir kez statik olarak belirlediğini ve kapasiteyi kontrol ettiğini gözlemlemişlerdir. Dolayısıyla dinamik fiyatlandırmanın maliyetli olduğu ve pratik olmadığı durumda, liste fiyatlandırmasının yararlı bir strateji olabileceği sonucuna varmışlardır.

Akçay ve diğ. (2010), sınırlı bir satış ufku üzerinde birden çok ikame edilebilir ve bozulabilir ürünü satan bir firmanın karşılaştığı dinamik fiyatlandırma problemini ele almışlardır. Ürünler ikame edilebilir olduğundan, bireysel ürün talepleri tüketici seçimleri ile bağlantılıdır. Bu nedenle de Akçay ve diğerleri, satıcının dinamik fiyatlandırma modeline tüketici davranışlarını dahil etmesi gerektiğini ileri sürmüşlerdir. Doğrusal rastgele tüketici programlarına dayanan bütünleyici bir tüketici seçim modeli için, bu çok ürünlü dinamik fiyatlandırma problemini stokastik bir dinamik program olarak modelleyerek, optimum fiyatları analiz etmişlerdir. Akçay ve diğerleri; tüketici seçim modelinin, ürün farklılaştırması ile tüketici seçimi arasındaki bağlantıyı yakalamaya olanak tanıdığını ve dikey ve yatay olarak farklılaştırılmış ürün asortilerinde uzmanlaşmayı kolaylaştırdığını savunmuşlardır. Sonuç olarak; yatay olarak farklılaştırılmış bir ürün asortisi için, kâr fonksiyonunun fiyatlar için monotonik olduğu; bununla birlikte dikey olarak farklılaştırılmış ürün asortisi için, monotonik olmadığı sonucuna varmışlardır.

Tablo 2.4’de, çoklu ürün için dinamik fiyatlandırma ile ilgili literatürde yer alan çalışmalar özetlenmektedir.

Tablo 2.4 : Çoklu ürün için dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Liu ve Milner (2006)	Birden fazla ürünü dinamik olarak nasıl fiyatlandırılması gerektiğini incelemiştir.	Stokastik talebin sürekli zamanda fiyatlandırılması: 4 sezgisel model kullanılmıştır
Aydin ve Ziya (2009)	Firmaların fiyatlarını belirlerken kullanabilecekleri zaman ve envanter seviyelerine ek olarak, üçüncü bir boyut olarak firmaların bireysel müşteri düzeyinde sahip olduğu bilgileri ele alarak literatüre katkıda bulunmuşlardır.	Çapraz satış modeli
Koenig ve Meissner (2010)	Sınırlı bir periyot boyunca birden fazla ürün satan firma için dinamik fiyatlandırma politikası ile liste fiyatı kapasite kontrol politikası arasındaki farkı analiz etmişlerdir.	Dinamik fiyatlandırma modeli ve liste fiyatlandırma modeli
Akçay ve diğ. (2010)	Sınırlı bir satış ufkü üzerinde birden çok ikame edilebilir ve bozulabilir ürünü satan bir firmanın karşılaştığı dinamik fiyatlandırma problemini incelemiştir.	Talep modeli: Tüketici seçiminin dikkate alındığı Poisson talep modeli & Optimizasyon modeli: Stokastik dinamik programlama

2.3.2.5. Envanterin Kısıtlı Olduğu Durumda Dinamik Fiyatlandırma Çalışmaları

Maglaras ve Meissner (2006), literatürde çok çalışılmış gelir yönetimi problemlerine genel bir formülasyon sunmak amacıyla; ilgili optimizasyon problemlerinin kontrol boyutunun azaltılması ile algoritmayı basitleştirme yoluna gitmişlerdir. İlişkili deterministik formülasyonlar bağlamında azaltılma durumunun, optimal kontrollerinin kapalı form karakterizasyonuna yol açtığını savunmuşlar ve birkaç statik ve dinamik fiyatlandırma sezgiseli önermişlerdir. Bu yöntemleri asimptotik olarak ve kapsamlı bir sayısal çalışma ile analiz etmişlerdir.

Şen (2013), sonlu bir satış döneminde sabit envanter kapasitesi satma problemini incelemiştir. Satış periyodunda kalan envanter ve süreye göre fiyatları sürekli güncelleyen iki basit dinamik sezgisel yöntemi önermişlerdir. İlk sezgisel yöntem, beklenen en optimum gelir fonksiyonuna, ikinci sezgisel yöntem ise sorunun deterministik versiyonunun çözümüne dayanmaktadır. Sayısal bir çalışma ile sabit fiyatlandırma yerine dinamik fiyatlandırma sezgisel yöntemlerinin kullanılmasının gelir artışı üzerinde önemli etkisinin olabileceğini göstermişlerdir.

Tablo 2.5’de, envanterin kısıtlı olduğu durumda dinamik fiyatlandırma ile ilgili literatürden incelenen çalışmalar özetlenmektedir.

Tablo 2.5 : Envanterin kısıtlı olduğu durumda dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Maglaras ve Meissner (2006)	Literatürde çok çalışılmış gelir yönetimi problemlerine genel bir formülasyon sunmayı amaçlamışlardır	Akışkan model dinamik ve statik sezgisel gelir maksimizasyonu modelleri
Şen (2013)	Satış periyodunda kalan envanter ve süreye göre fiyatları sürekli güncelleyen iki basit dinamik sezgisel yöntem önermişlerdir.	Gelir yaklaşımı sezgiseli ve Dinamik salınım oranı sezgiseli

2.3.2.6. Rekabetin Dikkate Alındığı Dinamik Fiyatlandırma Çalışmaları

Perakis ve Sood (2006); sabit envantere sahip tek bir bozulabilir ürün için, çok periyotlu oligopolistik pazarda fiyatlandırma çalışması yapmışlardır. Robust optimizasyon ve varyasyonel eşitsizlikleri kullanarak, talebin belirsizliği ile birlikte problemin rekabetçi yönünü ele almayı amaçlamışlardır. Bu çalışma; rekabet altında, dinamik fiyatlandırma için robust optimizasyonun kullanıldığı ilk çalışma olması nedeni ile literatüre katkıda bulunmuştur. Satıcılar arasında işbirliğinin bulunmadığı Nash denge politikalarını incelemişlerdir. Bu tür bir yapının; otelcilik, havayolu endüstrisi, telekomünikasyon gibi birçok sektörde kullanılabileceğini ileri sürmüşlerdir.

Kachani ve diğ. (2007); oligopolistik bir pazarda, dinamik fiyatlandırma ve talep öğrenimi için geçici bir model önermişlerdir. Bu modelde her firma, kendisinin ve rakiplerinin fiyat-talep ilişkisini öğrenerek ve rakiplerinin bir sonraki hamlesini göz önünde bulundurarak, optimal fiyatı belirlemeyi hedeflemektedir. Problemin geçici yönünü yakalamak amacı ile, zaman içinde elde edilen verileri kullanarak fiyatlandırma kararlarını dinamik olarak güncelleyen kapalı döngü yaklaşımını kullanmışlardır. Her firmanın karşılaştığı problemi, her firmanın denge kısıtlı bir matematiksel programı olarak formüle etmişlerdir. Problemin oyun teoriksel yönünü yakalamak için varyasyonel eşitsizlikler kullanmışlardır. Model hakkında bilgi sağlayan ve bu modelin çıktılarını oluşturan fiyatlandırma politikalarını gösteren hesaplama sonuçlarını sunmuşlardır.

Aviv ve Pazgal (2008); stratejik müşterilerin mevcut olduğu durumda, moda gibi mevsimsel ürünlerin sınırlı bir miktarının optimum fiyatlandırmasını incelemişlerdir. Koşullu ve duyurulan sabit indirim olmak üzere fiyatlandırma stratejilerini iki sınıfa ayırmışlardır. Her iki fiyatlandırma stratejisi için de, satıcının Stackelberg lideri olarak hareket ederek fiyatlandırma

stratejisini duyurduğunu ve tüketicilerin de satıcının stratejisini verildiği şekilde kabul ettiğini, takip ettiğini ve satın alma davranışına bu doğrultuda karar verdiğini varsaymışlardır. Her iki strateji için müşterilerin miyopik davrandığı durumu kıyaslama modeli olarak belirlemişlerdir. Stratejik tüketici davranışının fiyatlandırma politikaları ve beklenen gelir performansı üzerindeki etkisini araştırmak için kapsamlı bir sayısal çalışma yürütmüşlerdir. Çalışmanın neticesinde Aviv ve Pazgal; satıcının, stratejik müşterilerin satın alma kararlarını yanlışlıkla miyop olarak değerlendiği durumun, yaklaşık %20 potansiyel gelir kaybı gibi oldukça pahalı sonuçlarının olabileceğini belirtmişlerdir.

Levin ve diğ. (2008); bozulabilir hizmetlerin veya ürünlerin optimum dinamik fiyatlandırma problemi için, toplam gelirin minimum kabul edilebilir seviyesinin altına düşme olasılığının kontrolüne izin veren ve basit bir risk ölçümü içeren yeni bir model sunmuşlardır. Modeli sürekli zamanlı optimal kontrol problemi olarak formüle etmişler, problemin çözümünün yapısal özelliklerini incelemişlerdir. Ayrıca model, talebin fiyata bağlı homojen olmayan Poisson sürecini izlediğini varsaymaktadır.

Aviv ve diğ. (2009); dinamik fiyatlandırma sistemlerini uygulayan perakendecilerin, stratejik müşterilerinin satın alımlarını, bu müşterilerin gelecekteki indirim beklentilerini dikkate alarak zamanlamaları gerektiğini savunmuşlardır. Bu tür stratejik tüketici davranışlarının, perakendecilerin gelirleri ve kârlılığı üzerinde önemli sonuçlara yol açabileceğini savunmuşlardır. Literatürdeki çalışmalarda, bu fenomenin olumsuz etkilerini hafifletmek için fiyat ve kapasite taahhütlerinin yapılması, kapasitenin rasyonelleştirilmesi ve envanter bilgilerinin sınırlandırılması gibi çeşitli yaklaşımların araştırıldığını belirtmişlerdir. Bu çalışmada, yönetim bilimi literatüründe yukarıda belirtilen stratejilerin potansiyel değerini anlamamıza yardımcı olacak bazı teorik katkıları sunup, tartışmışlardır.

Levin ve diğ. (2009); kolay bozulan tüketim ürünleri satan oligopolistik firmalara yönelik dinamik fiyatlandırma modeli sunmuşlardır. Bu model; firmaların ve tüketicilerin stratejik davranışlarını, tüketici alışveriş yoğunluğunu tahsis eden tüketici modeline yanıt veren stokastik dinamik oyunda incelemeyi ve her bir firmanın toplam beklenen gelirini en üst düzeye çıkarmayı amaçlamaktadır. Levin ve diğ. (2009) bu modelin, yöneticilerin ve işletme analistlerinin, rekabetçi endüstrilerde ve çoklu tüketici segmentlerinde fiyatlandırma ve envanter politikalarının karmaşık stratejik etkileşimlerini keşfetmelerini sağlayabileceklerini ileri sürmüşlerdir. Modelin en kısıtlayıcı varsayımlarından birinin bilgi bulunabilirliği

olduğunu belirtmişlerdir. Araştırmanın geliştirilebilir yönü olarak ise, öğrenme unsurlarının modele dahil edilebileceğini; böylelikle firmaların zamanla piyasanın özelliklerini öğrenerek optimal fiyatı dinamik olarak sürekli ayarlayabileceklerini dile getirmişlerdir.

Levin ve diğ. (2010) bir başka çalışmalarında; sınırlı sayıdaki stratejik müşteri kitlesine, bozulabilir bir ürün satan tekelleri bir firma için dinamik fiyatlandırma modeli sunmuşlardır. Müşteriler, fiyatlandırmanın dinamik olduğunun ve satın alımlarının stratejik olarak zamanlanabileceğinin farkında oldukları için, stratejik müşteri olarak belirtilmişlerdir. Levin ve diğerleri bu problemi; firmanın hedefinin beklenen toplam geliri en üst düzeye çıkarmak olduğu ve her müşterinin hedefinin, beklenen mevcut fayda değerini maksimuma çıkarmak olduğu stokastik bir dinamik oyunda modellemişlerdir. Hem müşteri, hem de satıcı için denge optimum koşulunu sağlayan eşsiz bir alt oyun ile mükemmel denge fiyatlandırma politikasının varlığını kanıtlamışlardır. Modelin sayısal sonuçları, stratejik tüketici davranışını göz ardı eden bir firmanın, stratejik denge fiyatlandırmasını kullanan bir firmadan çok daha düşük toplam gelir elde edebileceğini göstermiştir.

Dasu ve Tong (2010); stratejik alıcılara sınırlı bir zaman dilimi içinde bozulabilir ürünler satan bir tekel firmanın dinamik fiyatlandırma politikalarını incelemişlerdir. Uygulama kolaylığı nedeni ile fiyatlandırma şemasına odaklanmışlardır. Çalışmanın sayısal sonuçları, iki veya üç fiyat değişikliğine dayanan fiyatlandırma şemasının; üst sınıra yakın gelir elde etmek için yeterli olduğunu göstermiştir. Ayrıca Dasu ve Tong dinamik fiyatlandırmanın yalnızca, stratejik alıcıların ürün yokluğunu algıladığı durumda faydalı olduğunu ileri sürmüşlerdir. “Bir firma sezon başında satışa sunulan birim sayısını göstermez ise veya daha sonrasında da ürünün satıldığı birim sayısı bilgisini saklı tutar ise fayda sağlar” sonucuna ulaşılmıştır.

Martínez-de-Albéniz ve Talluri (2011); satıcıların her birinin, belirli bir sayıda periyot boyunca satılmaya hazır sabit birimlere sahip oldukları, dinamik bir ortamdaki oligopol için fiyat rekabetini incelemişlerdir. Talebin stokastik olduğunu ve talebin gelişimine bağlı olarak, satıcıların fiyatlarını istedikleri zaman değiştirebileceklerini kabul etmişlerdir. Bu durum firmaların; piyasa talebi, rakip fiyatları veya stok seviyeleri güncellemelerine sürekli ve neredeyse maliyetsiz tepki verebilecekleri gerçeğini yansıtmaktadır. Dolayısıyla bu yapı, birçok gelir yönetimi uygulamasında kullanılan marjinal değer teklif-fiyat kontrolü kavramını rekabetçi bir modele genişletmektedir. Martínez-de-Albéniz ve Talluri bir düopol için denge fiyatı belirlemede kapalı formülü bir çözüm vermişler ve tüm sonuçları n-firma oligopolüne

genişletmişlerdir. Sonrasında modelin birden çok müşteri türüne, belirsiz değerlemelere ve farklılaştırılmış ürünlere yönelik uzantılarını incelemişlerdir.

Kopalle ve Shumsky (2012); basit fiyatlandırma örnekleri kullanarak oyun teorisinin temel kavramlarını tanıttıktan sonra, P&G'nin değer fiyatlandırması tekniğini ve rekabetçi ortamdaki fiyat tepkisini anlamak amacı ile, hem literatürden hem de endüstri uygulamalarından ilişkili örnekler vermişlerdir. Oyunun temel öğelerini ve oyun teorisinin temelini oluşturan temel varsayımları açıklamışlardır. Çeşitli denge koşullarında, oyunların nasıl çalıştığına ve rekabetin fiyatlandırmayı nasıl etkilediğine dair fikir veren modelleri incelemişlerdir. Eylemlerin zamanlaması ve periyot sayısı olmak üzere modelleri iki özelliğe göre sınıflandırmışlardır. Modellerin çoğunda, rakiplerin eş zamanlı fiyatlandırma kararları verdiğini, böylece hiçbir oyuncunun rakiplerinin faaliyetleri hakkında diğerlerinden daha fazla bilgi sahibi olamadığını belirtmişlerdir. Sıralı zamanlaması olan diğer oyunlarda ise, rakiplerden birinin ilk önce fiyatı belirlediğini dile getirmişlerdir.

Lu ve Liu (2013); bir tedarikçinin fiziksel kanallarda ve e-ticaret kanallarında ortak bir ürün sattığı bir dağıtım sistemini incelemişlerdir. Bu çift kanallı dağıtım sisteminde, iki tür Stackelberg fiyatlandırma oyununu ve bir tür Nash fiyatlandırma oyununu incelemişlerdir. Tedarikçinin fiyatlandırma yöntemi, oyun planları ve e-ticaret kanalı verimliliği gibi birkaç anahtar faktörün, tedarikçi ve perakendecinin kârı üzerindeki etkilerini analiz etmişlerdir. Dolayısıyla bu çalışmada, çok kanallı bir ortamda modelleme rekabetini bir fiyatlandırma bakış açısı ile incelemişlerdir. Kanal kabulünün, çift kanallı dağıtım sisteminde denge fiyatlarını ve kârı etkilemede kritik bir rol oynadığını gözlemlemişlerdir. Bir kanalın müşteri kabulü değerinin belirli bir eşiği aştığı durumda, bu kanalın dağıtım sistemine hakim olduğunu ve tedarikçinin tekdüze fiyatlandırmayı tercih etmek yerine farklı fiyatlandırma teknikleri uygulayarak daha fazla kâr elde edebileceğini belirtmişlerdir. Analiz sonuçları, hem tedarikçinin hem de perakendecinin Nash oyununda, Stackelberg oyunundan daha kötü olduğunu göstermiştir.

Anton ve diğ. (2014); dayanıklı mallar için basit bir dinamik fiyatlandırma modeli analiz etmişlerdir. Oyunun başında iki satıcı ve potansiyel katılımcı kapasitelerini belirlemişlerdir. Denge kapasitesi seçimi ve zorunlu karışık fiyatlandırma stratejilerini çözmeyi hedeflemişlerdir. Dengede; alıcı, rekabeti korumak için siparişi pozitif olasılıkla bölerek, hem

yüksek hem düşük fiyatlı satıcıların satış yapmasını mümkün kılmaktadır. Satıcılar bu durumdan, diğer satıcı tarafından karşılanmayan talep değerinin üzerinde bir kira emri vererek yararlanmaktadır. Alıcılar ise bu durumdan, gelecekteki satın alımların gerçekleşmemesi olasılığını dikkate alarak ya da her zaman en düşük fiyatlı satıcıdan satın almak için bir aracı kiralarak yararlanmaktadır.

Tablo 2.6’da rekabetin dikkate alındığı ve bu tez çalışması kapsamında incelenen dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.6 : Rekabetin dikkate alındığı dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>	<i>Market Türü (Oligopol / Monopol)</i>
Perakis ve Sood (2006)	Sabit envantere sahip tek bir bozulabilir ürün için çok periyotlu oligopolistik pazarda fiyatlandırma çalışması yapmışlardır.	Nash denge politikası	Oligopol
Kachani ve diğ. (2007)	Oligopolistik bir pazarda, dinamik fiyatlandırma ve talep öğrenimi için geçici bir model önermişlerdir.	Denge kısıtlı matematiksel program	-
Aviv ve Pazgal (2008)	Stratejik müşterilerin mevcut olduğu durumda, moda gibi mevsimsel ürünlerin sınırlı bir miktarının optimum fiyatlandırmasını incelemiştir.	Satıcının Stackelberg lideri olarak davrandığı oyun teorisi yaklaşımı	-
Aviv ve diğ. (2009)	Yönetim bilimi literatüründe belirtilen stratejilerin potansiyel değerini anlamamıza yardımcı olacak bazı teorik katkıları sunup, tartışmışlardır.	Anket çalışması	-
Levin ve diğ. (2009)	Kolay bozulan tüketim ürünleri satan oligopolistik firmalara yönelik dinamik fiyatlandırma modeli sunmuşlardır.	Stokastik dinamik oyun	Oligopol
Levin ve diğ. (2010)	Sınırlı sayıdaki stratejik müşteri kitlesine bozulabilir bir ürün satan tekeli bir firma için dinamik fiyatlandırma modeli sunmuşlardır.	Stokastik dinamik oyun	Monopol
Dasu ve Tong (2010)	Stratejik alıcılara sınırlı bir zaman dilimi içinde bozulabilir ürünler satan bir tekel firma için dinamik fiyatlandırma politikalarını incelemiştir.	Müşterinin stratejik davranışının dikkate alındığı oyun teorisi	Monopol
Martínez-de-Albéniz ve Talluri (2011)	Satıcıların her birinin, belirli bir sayıdaki periyot boyunca satılmaya hazır sabit birimlere sahip olduğu; dinamik bir ortamdaki oligopol için fiyat rekabetini incelemiştir	Genel stokastik sayım süreci	Oligopol
Kopalle ve Shumsky (2012)	Oyun teorisinin temel kavramlarını tanıttıktan sonra, literatür ve endüstri uygulamaları ile ilişkili örnekler vermişlerdir.	Oyun teorisi literatürü ve endüstri uygulamaları örneği	-

Tablo 2.6 (devam): Rekabetin dikkate alındığı dinamik fiyatlandırma çalışmaları.

Lu ve Liu (2013)	Çift kanallı dağıtım sisteminde, iki tür Stackelberg fiyatlandırma oyunu ve bir tür Nash fiyatlandırma oyununu incelemiştir.	İki tür Stackelberg fiyatlandırma oyunu ve bir tür Nash fiyatlandırma oyunu	-
Anton ve diğ. (2014)	Kurulan oyun modeli ile denge kapasitesi seçimi ve zorunlu karışık fiyatlandırma stratejilerini çözmeyi hedeflemiştir.	Stratejik müşteri davranışının dikkate alındığı fiyatlandırma oyunu	-

2.3.2.7. Davranış Dinamiklerinin Dikkate Alındığı Dinamik Fiyatlandırma Çalışmaları

Popescu ve Wu (2007); tekrarlanan etkileşime sahip bir pazarda, talebin firmanın fiyatlandırma geçmişine duyarlı olduğu, tekeli bir firmanın dinamik fiyatlandırma problemini ele almışlardır. Bu problemde firma mevcut fiyatları manipüle ederken, tüketiciler de fiyat algılarına dayalı geçmiş fiyatları da baz alan bir referans fiyat standartını oluşturmuşlardır. Popescu ve Wu optimum fiyatlandırma politikalarının, monotonik fiyatların algılanmasına neden olduğunu kanıtlamışlar; bu durumu tüketicilerin, beklentilerine göre her zaman fiyat indirimi olarak algıladıklarını belirtmişlerdir. Tüketicilerin zarardan kaçınma eğiliminde olduğu durumda; optimal fiyatların, basit kapalı bir denklemle karakterize edilen sabit istikrarlı durum fiyatına yaklaştığını göstermişlerdir. Ayrıca sabit istikrarlı durumların aralığının, tüketicilerin zarardan kaçınma eğilimine bağlı olarak genişlediğini ifade etmişlerdir. Sık gelen müşterilerin, ara sıra gelen müşterilere göre fiyat değişikliklerine daha hassas olduğu durumda; sık gelen müşterilere daha düşük fiyatlar sunmanın optimal bir çözüm olmadığını savunmuşlardır. Yöneticilerin fiyatlandırma stratejilerinin uzun vadeli sonuçlarını göz ardı ettiği durumda model sonuçları, fiyatın düşük belirlendiğini ve gelir kaybının yaşandığını göstermiştir.

Zhao ve diğ. (2012) çalışmalarında; durgunluktan etkilenebilecek tüketicilere bozulabilir mallar satan tekel bir firmanın dinamik fiyatlandırma problemini ele almışlardır. Bu problemi çözümleyebilmek için sonlu ufuk dinamik programlama yaklaşımını kullanmışlar ve optimum dinamik fiyatlandırma politikasını türetmişlerdir. Tüketici durağanlığının, firmaların beklenen gelirleri ve optimal fiyatları üzerinde olumsuz etkiler yarattığını göstermişlerdir. Firmaların, tüketici durağanlığı seviyesinden etkilenmemeleri için önerilerde bulunmuşlardır.

Soysal ve Krishnamurthi (2012); sınırlı bir sezonda satılan mevsimlik ürünler için pazardaki tüketici seçimi davranışının dinamik bir modelini geliştirmişlerdir. Bunun için, bir moda ürünleri perakendesinden gelen toplam satışları ve envanter verilerini kullanmışlardır.

Oluşturdukları yapısal model, mevsimlik mallara olan talebi modellemek için gerekli olan; “değişen fiyatlar”, “sınırlı bulunabilirlik” ve “toplam tüketim hizmetinin satın alma zamanına olası bağımlılığı” özelliklerini içermiştir. Çalışmanın sonucunda Soysal ve Krishnamurthi, stratejik tüketicilerin indirimlerden yararlanmak için alımlarını ertelediklerini ve bu stratejik gecikmelerin perakendecinin gelirlerine zarar verdiğini tespit etmişlerdir.

Tablo 2.7’de, davranış dinamiklerinin dikkate alındığı ve bu tez çalışması kapsamında incelenen dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.7 : Davranış dinamiklerinin dikkate alındığı dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Popescu ve Wu (2007)	Pazarda tekeli bir firmanın dinamik fiyatlandırma problemini ele almışlardır. Tüketicilerin zarardan kaçınma eğilimini analiz etmişlerdir.	Genel referansa bağlı talep modelleri
Zhao ve diğ. (2012)	Durgunluktan etkilenebilecek tüketicilere bozulabilir mallar satan tekeli bir firmanın dinamik fiyatlandırma problemi üzerinde çalışmışlardır	Sonlu ufuk dinamik programlama modelleri
Soysal ve Krishnamurthi (2012)	Çalışmalarında sınırlı bir sezonda satılan mevsimlik ürünlerin için, pazardaki tüketici seçimi davranışının dinamik bir modelini geliştirmişlerdir.	Tüketici seçimi davranışının dinamik bir modeli

2.3.2.8. Talep Hakkında Kısıtlı Bilginin Olduğu Durumlarda Dinamik Fiyatlandırma Çalışmaları

Lim ve Shanthikumar (2007) çalışmalarında; optimizasyon aşamasında temel alınan modeldeki hataları dikkate alan, tek ürünlü dinamik gelir yönetimi yaklaşımı sunmuşlardır. Talep oranı modelindeki belirsizliği, göreceli entropi kavramını kullanarak temsil etmişler ve nokta süreçleri için olasılık ölçüsünün değiştirilmesine ilişkin sonuçlarını kullanarak robust fiyatlandırma probleminin yeni formülasyonunu elde etmişlerdir. Optimal fiyatlandırma politikasını; Isaacs’ın stokastik diferansiyel oyunlar için geliştirdiği denklemin bir versiyonuyla ve optimal çözümün yapısal özelliklerini bu denklemin analizi ile elde etmişlerdir.

Cohen ve diğ. (2018); bir firmanın sabit bir zaman dilimi içinde satılacak bir ürün sunduğu, dinamik bir fiyatlandırma problemi üzerinde çalışmışlardır. Firmanın belirli bir başlangıç envanter seviyesinin olduğunu; ancak her bir periyotta ürüne yönelik talep konusunda

belirsizlik olduğunu varsaymışlardır. Firmanın amacı, tüm satış sezonu boyunca geliri en üst düzeye çıkaran dinamik fiyatlandırma stratejisini belirlemektir. Talep verilerini doğrudan kullanan izlenebilir bir optimizasyon modeli geliştirerek, pratik bir karar ağacı oluşturmuşlardır. Hesaplamalara göre; pişmanlık temelli amaçların, ortalama gelir maksimizasyonu ve Bayesci bir yaklaşımla karşılaştırıldığında iyi performans gösterebileceğini savunmuşlardır. Cohen ve diğerleri, bu çalışmada önerdikleri modelleme yaklaşımının, riskten kaçınma eğilimi gösteren ve talep dağılımı hakkında geçmiş verilere sınırlı erişimi olan yöneticiler için özellikle yararlı olabileceğini ileri sürmüşlerdir. Son olarak, bu örnekleme tabanlı çözümün teorik performansının garantisini sunmuşlardır.

Tablo 2.8’de, talep hakkında kısıtlı bilginin olduğu ve bu tez çalışması kapsamında incelenen dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.8 : Talep hakkında kısıtlı bilginin olduğu dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Lim ve Shanthikumar (2007)	Çalışmalarında, optimizasyon aşamasında temel alınan modeldeki hataları dikkate alan tek ürünli dinamik gelir yönetimi yaklaşımı sunmuşlardır.	Girsanov teoremi ve Isaacs’ın stokastik diferansiyel oyunlar için denkleminin bir versiyonu
Cohen, Lobel ve Perakis (2018)	Bir firmanın sabit bir zaman dilimi içinde satılacak bir ürün sunduğu, dinamik bir fiyatlandırma problemi üzerinde çalışmışlardır.	Pişmanlıktan kaçınma temelli amaç fonksiyonu ve doğrusal kontrol politikaları

2.3.2.9. İndirim Optimizasyonu Dinamik Fiyatlandırma Çalışmaları

Smith ve Achabal (1998) çalışmalarında; azalan asorti çeşitliliğinin ve mevsim değişikliklerinin ürün satış oranları üzerindeki etkisini dikkate alan, optimum ürün temizleme fiyatlandırma politikası ve envanter yönetimi politikaları geliştirmişlerdir. Geliştirdikleri politikaların farklı versiyonlarını üç büyük perakende zincirinde uygulamış ve test etmişlerdir. Satış oranlarının fiyata, mevsimsel etkilere ve müşterilerin satın alabileceği kalan asorti çeşitliliğine bağlı olduğu sonucuna ulaşmışlardır. Ürün temizleme fiyatlarının belirlenmesinde yaşanacak hataların, envanter fazlasına ve potansiyel gelir kaybına yol açabileceğini savunmuşlardır.

Mantrala ve Rao (2001); moda ürünlerinin perakende mağaza alıcılarının optimum mal sipariş miktarlarına ve indirim fiyatlarına karar vermelerine yardımcı olmak amacı ile, stokastik dinamik programlama model tabanlı bir karar destek sistemi olan MARK’ı geliştirmişlerdir. Bu karar destek sistemi, kârlılığı artırmış ve yöneticilerin karar problemlerini anlamalarını

kolaylaştırmıştır. Bu sistem aynı zamanda sipariş miktarı ve dinamik fiyatlandırma kararları arasındaki etkileşime ilişkin değerli bilgiler sağlamıştır. Bu sistem ile “yüksek indirim yüzdelерinin mutlaka daha düşük kâr getirmeyeceğı” gibi çeşitli bulgular elde edilmiştir.

Heching ve diğ. (2002) çalışmalarında; kadınlara özel ürün satan moda perakendesinin, satış ve fiyat verilerinin analiz sonuçlarını raporlamışlardır. Literatürde mevcut talep modelleri ile çeşitli fiyatlandırma politikaları altında analizler gerçekleştirmişlerdir. Analiz sonuçları, firmanın satış sezonunun başlarında daha düşük indirimler yapmasının geliri önemli ölçüde artıracığını göstermiştir. Sonuçlar ayrıca, model tabanlı fiyatlandırma planlarının geliri yaklaşık %4 oranda artırabileceğini kanıtlamıştır.

Gupta ve diğ. (2006); moda perakendeleri için temizleme fiyatlarının belirlenmesinde kullanılabilecek ayırık zamanlı modeller sunmuşlardır. Talebin deterministik olduğu durumda; optimum fiyatların hesaplandığını ve azalan rezervasyon fiyatlarının optimum fiyatların düşmesine yol açtığını göstermişlerdir. Talebin planlama dönemlerinde stokastik olduğu ve isteğe bağlı korelasyonu olduğu durumda, optimum fiyat ile beklenen optimum gelir için sınırlar elde etmişlerdir. Optimum fiyatları belirleyebilmek için sezgisel bir prosedür geliştirmişler ve sayısal deneyler ile bu prosedürün doğruluğunu test etmişlerdir. Fiyatların zaman içinde kayda değer bir şekilde değişmemesi veya ilk dönemden sonra kesin bir şekilde düşmesi durumunda; sezon sonu temizleme fiyatının bir kez seçilip, satış sezonunun geri kalanında değiştirilmemesinin cezasının düşük olduğu sonucuna ulaşmışlardır.

Zhang ve Cooper (2008); stratejik müşteri davranışının, tek bir ürün satan bir firmanın 2 periyot boyunca fiyatlandırma ve rasyonel kararları üzerindeki etkisini incelemişlerdir. Satıcı bir ürünün bulunabilirliğini sınırlayabilmektedir. Bazı müşterilerin stratejik olduğunu ve satın almalarını zamanlayarak firmanın kararlarına yanıt verdiğini kabul etmişlerdir. Kapasite kısıtlayıcı olmadığında ve satıcı fiyatlandırma esnekliğine sahip olduğunda, ürün temizleme periyodundaki rasyonun geliri artıramayacağını göstermişlerdir. Ancak, fiyatlar önceden sabitlendiğinde; oranlama, geliri artırabilmektedir. Zhang ve Cooper doğrusal ve üstel talep eğrileri için ayrıntılı bir analiz yapmışlar ve optimum rasyonel seviyeleri için açık ifadeler türetmişlerdir. Temizleme fiyatında ürün bulunurluğunu kısıtlamamanın veya ürünü temizleme fiyatında sunmamaktan daha iyisini yapma politikasının tipik olarak en uygun olduğunu göstermişlerdir. Problemi, kapasite kısıtının olduğu vakalara genişletmişler ve benzer sonuçlar elde etmişlerdir.

Mersereau ve Zhang (2012), satıcı belirsizliğinin stratejik müşteri davranışı üzerindeki etkilerini indirim optimizasyonu fiyatlandırma ortamında incelemişlerdir. Fiyatın müşterilerin ödemeye istekli olduğu fiyatın altında kaldığı durumda; bazı müşterilerin ürünleri dürtüsel olarak satın aldığını, bazı müşterilerin ise stratejik olarak ikinci periyotta daha düşük fiyatları beklediğini varsaymışlardır. Satıcının toplam talep eğrisini bildiği, ancak stratejik davranan müşterilerin oranını bilmediği iki periyotluk bir satış sezonunu ele almışlardır. Stratejik davranışın kapsamı hakkında hiçbir bilgi gerektirmeyen robust bir fiyatlandırma politikasının oldukça iyi performans gösterdiğini savunmuşlardır. Modeli stokastik talebe sahip bir ortama taşımışlar ve kapasite gevşediğinde ya da problem büyüdüğünde robust fiyatlandırma politikasının iyi performans göstermeye devam ettiğini göstermişlerdir. Sonuçlar, stratejik davranış tanıma ihtiyacının altını çizmek ile birlikte, birçok durumda stratejik davranışın kesin bilgisi olmadan da etkili performansın mümkün olduğunu kanıtlamıştır.

Caro ve Gallien (2012); Zara'nın kullanmakta olduğu sezgisel indirim optimizasyonu modelini değiştirerek, bilimsel optimizasyon modeli ve bu modele girdi oluşturan tahmin modeli geliştirerek süreç tasarlamış ve uygulamışlardır. 2007 yılına kadar kullanılan sezgisel modelin yerine; tasarladıkları stok temizliği fiyatlandırma modelini, 2008 sonbahar-kış sezonu boyunca tüm Belçika ve İrlanda mağazalarında gerçekleştirdikleri saha deneyinde kullanmışlar ve %6'lık bir gelir artışı elde etmişlerdir. Bu deney sonuçlarına göre Zara, geliştirilen modeli dünya çapındaki tüm mağazalarında stok temizliği zamanında, indirim optimizasyonu süreçlerinde uygulamaya geçirmiştir.

Vakhutinsky ve diğ. (2012) çalışmalarında; envanter tükenmesinin yol açtığı asorti kırıklığı etkisinin, tüketici talebi üzerindeki olumsuz etkisini incelemişlerdir. Bazı popüler talep modellerini kullanarak, optimum fiyat için kapalı formulu bir analitik çözüm elde etmişlerdir. Amerikan moda perakende zinciri verileri üzerinde, dinamik ve stokastik dinamik programlama modelleri çalışmışlardır. Sürekli fiyat ve karar verme süresi olan indirim optimizasyonu problemine, kapalı formulu bir çözüm sunarak literatüre katkıda bulunmuşlardır. Bu metodolojinin ayırık zamanda fiyat önermek için nasıl uyarlanabileceğini göstermişlerdir.

Chen ve diğ. (2014); birçok büyük perakendecinin sıkça karşılaştığı, indirim optimizasyonu problemini incelemişlerdir. "Markdown" planlama ufkunun başlangıcında, bir depoda, planlama ufku üzerinde depo tarafından sunulan birçok perakende mağazasına tahsis edilmesi gereken belirli bir miktar ürün envanterinin var olduğunu ve planlama ufkunda her mağaza için

bir indirim fiyatlandırma şemasının belirlenmesi gerektiğini kabul etmişlerdir. Perakendecinin talep dağılımı hakkındaki bilgisi, yeni bilgiler elde edildikçe zaman içinde gelişmektedir. Bu nedenle perakendeci, sorunun her dönemin başında en son talep bilgilerini ekleyerek yeniden çözüldüğü bir ufuk çizgisi yaklaşımı kullanmaktadır. Talep fonksiyonunun belirli olduğu ve sadece tek bir mağaza ya da tek bir zaman periyodu olduğu durumda bile, problemin parametrik olmayan zor problem sınıfına gireceğini belirtmişlerdir. Bu nedenle problemin çözümü için sezgisel çözüm yaklaşımına odaklanmışlardır. Stokastik talebi, perakendecinin talep dağılımları hakkındaki en son bilgisine dayanan ayrı talep senaryolarını kullanarak modellemişler ve bu durum, olası talep korelasyonlarının farklı zaman dilimlerinde modellenmesini sağlamıştır. Her dönemin başlangıcındaki problemi, talep senaryoları ile karışık tamsayılı program olarak formüle ederek ve Lagrange çarpanına dayalı bir ayrışma yaklaşımı kullanarak çözmüşlerdir. Çalışma sonucunda; optimal stok tahsisi, beklenen gelir ve fiyatlandırma kararlarına ilişkin bir dizi yönetimsel bilgi elde edilmiştir.

Yao ve diğ. (2015), çalışmalarında çok ürün hacmine sahip çok mağazalı perakendecinin, tüm ilgili iş kurallarını içeren bir indirim optimizasyonu fiyatlandırma modeli sunmuşlardır. Önerdikleri çözüm, perakendecilere hangi ürünün ne zaman, hangi pazarlarda, hangi mağazalarda veya mağaza kümelerinde, ne kadar indirimde girmesi gerektiğini belirleme olanağı sağlamıştır. Bu çözüm ayrıca, perakendecilerin indirim devam ederken ayarlamalar yapmasına izin vererek; gereksiz indirimlerden ve sezon sonu envanter fazlalığından kaçınmasına yardımcı olmaktadır.

Tablo 2.9’de, bu tez çalışması kapsamında literatürden incelenen indirim optimizasyonu dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.9 : İndirim optimizasyonu dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Smith ve Achabal (1998)	Azalan asorti çeşitliliğinin ve mevsim değişikliklerinin ürün satış oranları üzerindeki etkisini dikkate alan, indirim en iyilemesi fiyatlandırma politikası geliştirmişlerdir.	Envanter ve maliyet etkilerini dikkate alan dinamik fiyatlandırma modeli
Mantrala ve Rao (2001)	Moda perakendesi için bir karar destek sistemi geliştirmişlerdir.	Stokastik dinamik programlama modeli tabanlı karar destek sistemi

Tablo 2.9 (devam): İndirim optimizasyonu dinamik fiyatlandırma çalışmaları.

Heching ve diğ. (2002)	Moda perakendesinin, satış ve fiyat verilerinin analiz sonuçları raporlamışlardır.	Sezgisel modeller, tam bilgi ve adaptif fiyatlandırma politikaları
Gupta ve diğ. (2006)	Moda perakendeleri için envanter temizleme fiyatlarının belirlenmesinde kullanılabilecek ayrık zamanlı modeller sunmuşlardır.	Çoklu indirim en iyilemesi deterministik modeller & stokastik tekil indirim optimizasyonu modeli
Zhang ve Cooper (2008)	Stratejik müşteri davranışının, tek bir ürün satan bir firmanın 2 periyot boyunca fiyatlandırma ve rasyonel kararları üzerindeki etkisini incelemişlerdir.	Dinamik müşteri talebi öğrenme modeli
Mersereau ve Zhang (2012)	Satıcı belirsizliğinin stratejik müşteri davranışı üzerindeki etkilerini indirim optimizasyonu fiyatlandırma ortamında incelemişlerdir.	Stratejik müşteri davranışını dikkate alan stokastik modelleme
Caro ve Gallien (2012)	Zara için tasarladıkları stok temizliği fiyatlandırma modelini, gerçekleştirdikleri saha deneyinde kullanmışlardır.	Regresyon & eşdeğer yaklaşım formülasyonları
Vakhutinsky ve diğ. (2012)	Sürekli fiyat ve karar verme süresi olan indirim optimizasyonu problemine kapalı formülü bir çözüm sunmuşlardır.	Deterministik ve stokastik dinamik programlama
Chen ve diğ. (2014)	Optimal stok tahsisi, beklenen gelir ve fiyatlandırma kararlarına ilişkin bir dizi yönetimsel bilgi elde etmişlerdir.	Sezgisel çözüm yaklaşımına odaklanan; karışık tam sayı programı
Yao ve diğ. (2015)	İndirim optimizasyonu fiyatlandırma modeli sunmuşlardır.	İndirim bütçesi kısıtlı sezgisel çözüm modeli

2.3.2.10. Talebin Öğrenilmesine Dayalı Dinamik Fiyatlandırma Çalışmaları

Xu ve Hopp (2005) çalışmalarında; dinamik fiyatlandırma ile tek adımlı stok yenileme sorunu bağlamında, talebin öğrenilmesine yönelik çeşitli yaklaşımları incelemişlerdir. Tam bilgi ile öğrenme, öğrenimsiz, pasif öğrenme ve aktif öğrenme yaklaşımları üzerinde çalışmışlardır. Farklı fiyatlandırma politikaları tarafından üretilen fiyatların, bir gözlemcinin bilgisine bağlı olarak süper, alt veya martingale yapıda olabileceği sonucuna ulaşmışlardır. Sayısal deneyler yolu ile, pasif öğrenme fiyatlandırma yaklaşımının optimal aktif öğrenme fiyatlandırma yaklaşımına yaklaşabileceğini; ancak öğrenimsiz fiyatlandırma yaklaşımının çok kötü performans sergilediğini gözlemlemişlerdir.

Araman ve Caldentey (2009); talep yoğunluğu bilinmeyen ve Poisson dağılımına göre dağılım gösteren fiyata duyarlı müşterilere dayanıklı ürünler satan bir perakendecinin karşılaştığı iki vaka üzerinde durmuşlardır. İlk vaka olarak, farklı bir ürün asortisi göz önünde bulundurulmadan, dayanıklı ürünün ilk stoğunun tamamını satma durumunu incelemişlerdir. İkinci vaka olarak ise, perakendecinin, dayanıklı ürünleri satmayı istediği zamanda durdurabilme ve farklı bir ürün menüsüne geçebilme olasılığını dikkate alan durumu incelemişlerdir. Araman ve Caldentey dinamik fiyatlandırma politikalarını kullanarak, promosyonlu ürünler üzerinden perakendecinin uzun vadeli ortalama kârını maksimize etmeyi amaçlamışlardır. Her iki vaka için, perakendecinin problemini Poisson yoğunluk kontrol problemi olarak formüle etmişler ve optimal bir çözümün yapısal özelliklerini elde eden basit ama verimli bir yaklaşım önermişlerdir. Önerdikleri politikanın performansını değerlendirmek için, asimtotik analizler ile birlikte sayısal hesaplamaları kullanmışlardır.

Besbes ve Zeevi (2009); başlangıç envanterinin belirli olduğu, beklenen geliri en üst düzeye çıkarmak amacı ile fiyatların sınırlı bir satış ufku üzerinde ayarlandığı bir tekli ürün gelir yönetimi problemini ele almışlardır. Gerçekleşen talebin zaman içinde gözlemlendiğini; ancak bu gözlemleri (talep fonksiyonu ya da talep eğrisi olarak da bilinen) yöneten fiyat ve ortalama talep oranı arasındaki temel fonksiyonel ilişkinin bilinmediğini kabul etmişlerdir. Bu problemin iki örneğini ele almışlardır. Her bir vaka için, talep fonksiyonunu anında öğrenen ve fiyatları buna göre optimize eden politikalar geliştirmişlerdir. Bu algoritmaların performansını; talep fonksiyonu satış sezonunun başlamasından önce bilinirse, elde edilebilecek maksimum gelire göre gelir kaybı (pişmanlık) açısından ölçmüşlerdir. Pişmanlığın büyüklüğünü, talep belirsizliği ile ilgili önceki bilginin ekonomik değeri olarak yorumlayarak, bu değer model belirsizliğinden kaynaklanan gelir kaybı olarak kendini gösterdiğini belirtmişlerdir.

Besbes ve Zeevi (2015); bilinmeyen bir talep eğrisine sahip, çok periyotlu, tek bir ürünün fiyatlandırma problemini incelemişlerdir. Satıcının amacını, belirli bir zaman dilimi boyunca kümülatif beklenen geliri en üst düzeye çıkarmak için her periyottaki fiyatları ayarlama olarak belirlemişlerdir. Bu amacı gerçekleştirmeye çalışan satıcının, bilinmeyen talep eğrisini öğrenme ile kazanılan gelirleri en üst düzeye çıkarma arasındaki gerilimi çözmesi gerektiğini belirtmişlerdir. Satıcı, temel talep eğrisine göre önemli ölçüde farklılık gösteren basit bir parametrik model kullanır ise, gelir kaybının büyüklüğü ne kadar olur? sorusunu araştırmanın ana sorusu olacağını belirlemişlerdir. Çalışmanın sonuçları; parametrik modelin aşırı derecede kısıtlı olduğu durumda, yanlış tanımlanan fiyatın çok önemli olmadığını göstermiştir.

Tablo 2.10’da, bu tez çalışması kapsamında incelenen, talebin öğrenilmesine dayalı dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.10 : Talebin öğrenilmesine dayalı dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Xu ve Hopp (2005)	Dinamik fiyatlandırma ile tek adımlı stok yenileme sorunu bağlamında; talebin öğrenilmesine yönelik çeşitli yaklaşımları incelemişlerdir.	Tam bilgi ile öğrenme, öğrenimsiz, pasif öğrenme ve aktif öğrenme stratejileri
Araman ve Caldentey (2009)	Talep yoğunluğu bilinmeyen, Poisson dağılımına göre dağılım gösteren fiyata duyarlı müşterilere; dayanıklı ürünler satan bir perakendecinin karşılaştığı iki vakayı incelemişlerdir.	Bayes talebin öğrenilmesine dayalı model
Besbes ve Zeevi (2009)	Başlangıç envanterinin belirli olduğu, beklenen geliri en üst düzeye çıkarmak amacı ile fiyatların sınırlı bir satış ufku üzerinde ayarlandığı bir tekli ürün gelir yönetimi problemini incelemişlerdir.	Parametrik olmayan fiyatlandırma politikası için stokastik modelleme
Besbes ve Zeevi (2015)	Bilinmeyen bir talep eğrisine sahip, çok periyotlu, tek bir ürünün fiyatlandırma problemini incelemişlerdir.	Genel doğrusal model & dinamik optimizasyon modeli

2.3.2.11. Bozulabilir Ürünler İçin Dinamik Fiyatlandırma Çalışmaları

Rekabetin dikkate alındığı dinamik fiyatlandırma çalışmaları başlığında ele alınan Levin ve diğ. (2008)’ne ait çalışma, kolay bozulan tüketim ürünleri satan oligopolistik firmalara yönelik dinamik fiyatlandırma modeli sunduğu için, bu başlık altında da yer almaktadır.

Bir diğer çalışmada Chew ve diğ. (2014); bozulabilir bir ürünün sipariş miktarını ve fiyatını çoklu satış periyodunda belirlemişlerdir. Farklı yaşlardaki ürünlere yönelik talepler, ikame edilebilir ürünlerin fiyatına bağlı olmaktadır. Öncelikle, iki dönemlik ömrü olan bir ürün için problemi analiz etmişler ve stokastik dinamik programlama modeli geliştirmişlerdir. Çalışmanın sayısal sonuçları, farklı yaşlardaki ürünler arasında talep transferleri hesaba katıldığında, toplam kârın önemli ölçüde arttığını göstermektedir. Ömrü iki dönemden uzun olan bir ürün için ise Chew ve diğerleri, tek bir dönem periyodunda optimum çözümü baz alan bir sezgisel yöntem önermişlerdir.

Tablo 2.11’de, bu tez çalışması kapsamında literatürden incelenen, bozulabilir ürünler için dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.11 : Bozulabilir ürünler için dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Levin ve diğ. (2008)	Bozulabilir hizmetlerin veya ürünlerin optimum dinamik fiyatlandırma problemi için basit bir risk ölçümü içeren yeni bir model sunmuşlardır.	Stokastik optimal kontrol modeli
Chew ve diğ. (2014)	Bozulabilir bir ürünün sipariş miktarını ve fiyatını çoklu satış periyodunda belirlemişlerdir.	Dinamik Programlama Modeli

2.3.2.12. Gıda Perakendesinde Dinamik Fiyatlandırma Çalışmaları

Lippmann (2003); perakende gelir yönetimi stratejisinin gıda perakendesi sektöründe ne gibi katkılarının olduğunu, perakendecilerin yatırımın geri dönüşünü hızlı elde edebilmeleri için ele almaları gereken zorlukları incelemiştir. Tüketicilerin ürün seçimlerinin fiyat, ürün bulunurluğu, konum, ürün imajı gibi birçok faktörün kombinasyonuna dayanmasına bağlı olarak, günümüz gıda perakendecilerinin en seçici tüketicilere yanıt vermek zorunda olduğunu belirtmiştir. Perakendecilerin gittikçe daha büyük mağaza açarak büyüme planlarının eskide kaldığını; artık odaklanılan konunun, mağazanın her bir m²'sinden ve her bir promosyondan elde edilen geliri en büyükleyebilmek için mağaza alanı ve ürün seleksiyonu üzerinde sıkı çalışma olduğunu ifade etmiştir. Ayrıca firmaların bütçeleri sürekli olarak sıkılaştırıldığından; her düzeydeki kararın sürekli bir analiz ve değerlendirme gerektirdiğini belirtmiştir. Ek olarak bu perakendecilerin, fiyatlandırma stratejilerinin fiyat imajıyla aynı doğrultuda olduğundan ve promosyonlara harcanan paradan emin olmaları gerektiğini dile getirmiştir.

Hawtin (2003) çalışmasında; gıda perakende satış noktasında ürünlerin fiyatlandırılması için gelir yönetimi ilkeleri uygulanırken, iş kurallarının tutarlı yönetimi için temel gereklilikleri göstermeyi amaçlamıştır. İş kuralları, bir şirketin fiyatlandırma politikasının açık ifadesidir ve gelir yönetimi sisteminden kaynaklanan fiyat önerilerinin, fiyat imajı (veya algısı) ve kâr ve pazar payının genel stratejik hedefler ile tutarlı olmasını sağlamada kritik bir rol oynamaktadır. Hawtin bunu göstermek için, bir Amerikan market zincirinde bir ürün kategorisinde gelir yönetimi sisteminin uygulamasını içeren ve iş kurallarının kâr ve hacim hedeflerine ulaşılmasındaki etkisini gösteren bir örnek olay incelemesi gerçekleştirmiştir.

Tablo 2.12'de incelenen gıda perakendesi dinamik fiyatlandırma çalışmaları özetlenmiştir.

Tablo 2.12 : Gıda perakendesinde dinamik fiyatlandırma çalışmaları.

<i>Yayın</i>	<i>İçerik</i>	<i>Kullanılan Model</i>
Lippmann (2003)	Gıda perakendesinde dinamik fiyatlandırma uygulamaları için stratejiler sunmuştur	Dinamik fiyatlandırma modelleri
Hawtin (2003)	Ürünlerin fiyatlandırılması için gelir yönetimi ilkeleri uygulanırken, iş kurallarının tutarlı yönetimi için temel gereklilikleri göstermeyi amaçlamaktadır.	Perakendecinin iş kuralların dahil olduğu talep tahmin modeli ve optimizasyon modeli

2.4. TAHMİNLEME ALGORİTMALARI

Bu bölümde makine öğrenmesinin ne olduğu, türleri ve kullanım alanları ile ilgili bir giriş yapılarak, sadece bu tez çalışmasının tahminleme modülünde kullanılacak ağaç tabanlı algoritmaların detaylı anlatımına yer verilecektir.

2.4.1. Makine Öğrenmesi

Makine öğrenmesi; örnek verileri veya geçmiş deneyimleri kullanarak, bir performans ölçütünü optimize etmek için bilgisayarların programlanmasıdır. Bazı parametrelerine kadar tanımlanmış bir modelin mevcut olduğu durumda ise öğrenme, eğitim verilerini veya geçmiş deneyimi kullanarak modelin parametrelerini optimize etmek için bir bilgisayar programının yürütülmesidir (Alpaydin, 2020).

Model; gelecek ile ilgili tahminlerde bulunmak için tahminleyici, verilerden bilgi edinmek için açıklayıcı ya da hem tahminleyici hem de açıklayıcı olabilmektedir.

Makine öğrenmesi istatistik ve bilgisayar bilimlerinden yararlanmaktadır. Makine öğrenmesinin temel amacı; örneklemden çıkarım yapmak olduğu için, matematiksel modeller oluştururken istatistik bilimini kullanmaktadır. Bilgisayar biliminin makine öğrenmesindeki rolü ise 2 yönlüdür:

1. Optimizasyon problemini çözmek ve ayrıca genel olarak sahip olduğumuz büyük miktarda veriyi depolamak ve işlemek için verimli algoritmalara ihtiyacımız vardır.
2. Bir model öğrenildikten sonra, modelden çıkarım yapabilmek için sunumunun ve algoritmik çözümünün de verimli olması gerekmektedir.

Bazı uygulamalarda, öğrenme algoritmasının tahmin doğruluğu kadar, uzay ve zaman karmaşıklığı da önemli olabilmektedir.

Literatürde çok sayıda farklı makine öğrenmesi algoritması mevcuttur ve bunları geniş kategorilerde sınıflandırmak mümkündür. Bunlardan birisi, insan gözetimi ile eğitilmiş olup olmadıklarına göre denetimli, denetimsiz, yarı denetimsiz ve pekiştirmeli öğrenme olarak sınıflandırmaktır (Géron, 2019).

2.4.1.1. Denetimli Öğrenme

Denetimli öğrenme (supervised learning); modelin, herhangi bir girdi verisi için doğru çıktı üretmeyi öğrendiği bir makine öğrenmesi türüdür. Model, belirli bir girdi için istenen çıktıyı sağlayabilen bir denetim yapısı tarafından hazırlanan veriler ile eğitilmektedir. Sınıflandırma ve regresyon, denetimli öğrenmenin örnekleridir. K-en yakın komşular, doğrusal regresyon, lojistik regresyon, destek vektör makineleri, karar ağaçları, rassal orman, gradyan artırımı ağaçlar, yapay sinir ağları en önemli denetimli öğrenme algoritmalarından bazılarıdır.

Makine öğrenmesi denetimli öğrenme tahmin algoritmaları için bir diğer alt sınıflandırma da parametrik ve parametrik olmayan yöntemler şeklinde yapılabilmektedir (Géron, 2019).

2.4.1.1.1 Parametrik Yöntemler

Parametrik yöntemler, veriler hakkında güçlü varsayımlar yapan yöntemlerdir. Yapılan varsayımlar geçerli ise, bu durum hesaplama ve veri açısından çok verimlidir; ancak varsayımlar her zaman geçerli değildir.

Parametrik yöntemlerde; sınıflandırma, regresyon, yoğunluk tahmini problemleri için, bütün girdi uzayında geçerli bir model olduğu varsayılmaktadır. Örneğin regresyon için doğrusal bir model olduğu varsayıldığı durumda, herhangi bir girdi için çıktının aynı doğrusal fonksiyonu olduğu varsayılmaktadır. Sınıflandırmada normal bir yoğunluk varsayıldığında, sınıfın tüm örneklerinin aynı yoğunluktan alındığı varsayılmaktadır. Doğrusal regresyon, lojistik regresyon, cezalandırılmış doğrusal modeller, naif bayes ve Lasso, parametrik yöntemler sınıfına girmektedir.

2.4.1.1.2. Parametrik Olmayan Yöntemler

Parametrik olmayan yöntemler, verilerin özellikleri hakkında güçlü varsayımlar yapmayan istatistiksel yöntemlerdir. Bu nedenle denetimli öğrenme yöntemlerine göre daha esnektirler, ancak daha fazla veriye ihtiyaç duyabilmektedirler.

Parametrik olmayan tahminde varsayılan tek şey, benzer girdilerin benzer çıktılar verdiğidir. Bu nedenle algoritma, uygun bir mesafe ölçüsü kullanarak eğitim veri setinden benzer geçmiş örnekleri bulmakta ve doğru çıktıyı elde etmek için bu örneklerden interpolasyon yapmaktadır. Parametrik olmayan modellerde, tek bir global model yoktur; lokal modeller, yalnızca yakındaki eğitim örneklerinden etkilenecek tahminleme gerçekleştirmektedir.

Yapay sinir ağları, k-en yakın komşular, destek vektör makineleri ve bu çalışmada kullanılacak ağaç tabanlı modeller (sınıflandırma ve regresyon ağaçları, rassal orman ve gradyan artırımı karar ağaçları) parametrik olmayan modeller sınıfına girmektedirler.

2.4.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme (unsupervised learning) algoritmalarındaki amaç, verideki düzenlilikleri yakalamaktır. Denetimsiz öğrenmede, denetimli öğrenmede olduğu gibi denetim yapısı yoktur; sadece girdi verileri mevcuttur. Girdi uzayında, belirli desenlerin diğerlerinden daha sık meydana geldiği bir yapı vardır. Bu durumda, istatistikte tanımlandığı gibi yoğunluk tahminine başvurulmaktadır. Yoğunluk tahmini yöntemlerinden biri olan kümelemenin hedefi, girdi verisinde kümeler ve gruplar bulmaktır. Anomali tespiti, boyut indirgeme, birliktelik kuralları çıkarımı denetimsiz öğrenme türlerindendir (Géron, 2019).

2.4.1.3. Yarı Denetimli Öğrenme

Yarı denetimli öğrenmede (semisupervised learning) algoritmalar, kısmen etiketlenmiş eğitim verileri, genellikle bir sürü etiketlenmemiş veri ve biraz da etiketlenmiş verilerle ilgilenmektedir. Çoğu yarı denetimli öğrenme algoritması, denetimsiz ve denetimli algoritmaların birleşiminden oluşmaktadır. Yarı denetimli öğrenme algoritmalarından Derin İnanç Ağları (Deep Belief Networks, DBNs), kısıtlı Boltzmann makineleri adı verilen denetimsiz bileşenlerin birbiri üstüne istiflenmiştir. Kısıtlı Boltzmann makineleri, denetimsiz bir şekilde eğitilmektedir ve sonrasında tüm sistemde denetimli öğrenme teknikleri kullanılarak ayarlamalar yapılmaktadır (Géron, 2019).

2.4.1.4. Pekiştirmeli Öğrenme

Bazı uygulamalarda, sistemin çıktısı bir dizi işlemdir. Böyle bir durumda, tek bir aksiyon önemli değildir; önemli olan hedefe ulaşmak için doğru aksiyonların sıralı olarak uygulandığı stratejidir. Herhangi bir ara durumda en iyi aksiyon diye bir şey yoktur; bir eylem, iyi bir stratejinin parçası ise iyidir. Böyle bir durumda; makine öğrenmesi programı, stratejilerinin iyiliğini değerlendirebilmeli ve bir strateji oluşturabilmek için geçmiş iyi aksiyon dizilerinden

öğrenebilmelidir. Bu tür öğrenme yöntemlerine pekiştirmeli öğrenme algoritmaları denmektedir.

Pekiştirmeli öğrenmede (reinforcement learning), ajan (agent) bir dizi aksiyon almakta ve aksiyonların sonucu olarak ödül ya da cezayı üstlenmektedir. Ajan, sınırlı bilgileri kullanarak, sonraki denemelerinde ödülü maksimize etmek için aksiyonlar oluşturmayı öğrenmelidir (Géron, 2019).

2.4.2. Regresyon Ağaçları

Karar ağaçları, karar düğümleri ve yapraklarından oluşan hiyerarşik bir modeldir. Karar ağaçları hızlı çalışmakta ve “if-then” kuralları oluşturularak, veriden bilgi çıkarılması işlemini gerçekleştirmektedir. Karar ağaçları, böl ve fethet stratejisini uygulayan hiyerarşik bir veri yapısıdır ve regresyon problemlerinde kullanılan verimli bir parametrik olmayan yöntemdir (Alpaydin, 2020). Regresyon modellerinde kullanılan karar ağaçları, regresyon ağaçları olarak isimlendirilmektedir.

Bir regresyon ağacı, örneklemin (kök düğüm) terminal düğümlere kadar daha homojen gruplara yinelemeli bir şekilde bölünmesi ile oluşturulmaktadır. Her bölme bir değişkenin değerine dayanmakta ve bir bölme kriterine göre seçilmektedir. Ağaç oluşturulduktan sonra; gözlemlenen değerlere dayanarak, kök düğümünden ağacın uygun terminal düğümüne kadar olan yolu izleyerek yanıt tahminlenebilmektedir. Yanıt değeri, terminal düğümdeki ortalama yanıttır. Ağaçtan tahmin edilen regresyon fonksiyonu, çok boyutlu basamak fonksiyonudur.

Çıktı, bölme kurallarına göre belirlenen dalları olan bir ağaç şeması ve ortalama yanıtı içeren bir dizi terminal düğümdür. Yöntem başlangıçta maksimum boyutta ağaçları büyütme ve daha sonra çapraz doğrulama gibi teknikleri kullanarak aşırı uyum sağlamış ağacı optimum boyuta budamaktadır.

Regresyon ağaçları, hiyerarşik ve katkısız olmayan (nonadditive) değişkenli verilerin yapısını ortaya çıkarmada klasik istatistiksel yöntemlere göre daha avantajlıdır. Yanıt ve tahmin değişkenleri arasındaki ilişki önceden belirlenmiş olan (düz çizgi, kuadratik vb.) klasik regresyon tekniklerinin aksine; regresyon ağaçları, bu ilişkiyi kanıtlamak veya reddetmek için öncü ilişkiyi varsaymaz (Prasad ve diğ., 2006).

2.4.2.1. Sınıflandırma ve Regresyon Ağaçları

Breiman ve diğ. (1984) tarafından önerilen Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Trees, CART) algoritması, regresyon için artık kareler toplamını safsızlık ölçütü olarak kabul etmekte ve her düğüm için genel düğüm safsızlığını maksimum azaltan bölünmeyi seçmektedir. Artık kareler toplamı (Residual Sum of Squares, RSS) denklem 2.1 ile hesaplanmaktadır.


$$RSS = \sum_{sol} (y_i - y_L^*)^2 + \sum_{sağ} (y_i - y_R^*)^2 \quad (2.1)$$

y_L^* = sol düğüm için y değerlerinin ortalaması

y_R^* = sağ düğüm için y değerlerinin ortalaması

Tahmin değişkenleri ve bölünme noktaları, tahmin hatalarını en aza indirmek için seçilmektedir.

Şekil 2.1' de görüldüğü gibi bir ağacı geliştirmek, özyinelemeli ikili bölünmeleri içermektedir. Bu ikili bölünmeler durdurma kriterlerine ulaşılan kadar tekrarlı olarak uygulanmaktadır.



Şekil 2.1 : Özyinelemeli ikili bölünmeler ve sınıflandırma ve regresyon ağaçları algoritmasının gösterimi (Hastie ve diğ., 2009).

CART algoritması için ilk önce çok büyük bir ağaç yetişmekte ve daha sonra tahmin performansına katkıda bulunmayan dallar kesilerek budama gerçekleştirilmektedir. Küçük bir ağacı büyütmek yerine büyük bir ağacın budanması, ağacın öngörülen performansında iyileşme sağlamaktadır (daha erken durdurmak sonraki iyileştirmeleri engelleyebilir). Ancak CART rassal orman algoritmasında kullanılıyorsa, genellikle oldukça büyük boyutlarda büyütülmekte ve hiçbir budama yapılmamaktadır.

2.4.2.2. Regresyon Ağacı Oluşturma

Her N gözlem değeri için veri seti, p girdi değişkenleri ve yanıtta oluşmaktadır (x_i, y_i) .

Bu durum $i = \{1, 2, \dots, N\}$ ve $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$ şeklinde gösterilmektedir.

M bölgeye ayrılmış bölütlere sahip olunduğu düşünülürse; $R_1, R_2, \dots, R_m$ olmak üzere her bir bölgedeki yanıt değişkeni bir c_m sabiti olarak denklem 2.2'deki gibi modellenmektedir.

$$f(x) = \sum_{m=1}^M c_m I(x \in R_m) \quad (2.2)$$

c_m , R_m 'deki tahmin değeridir ve $I()$ gösterge fonksiyondur. Hata kareler toplamını $\sum (y_i - f(x_i))^2$ en küçükleme kriteri kullanılarak denklem 2.3'ten, en iyi c_m değerinin R_m bölgesindeki y_i değerlerinin ortalaması olduğu görülebilmektedir.

$$\hat{c}_m = \text{ortalama}(y_i | x_i \in R_m) \quad (2.3)$$

Ancak bu değeri hesaplamak mümkün değildir. Regresyon ağacının oluşumu aşamasında, her bir j bölme değişkeni ve s bölünme noktası için açgözlü algoritması (greedy algorithm) izlenerek denklem 2.4'teki gibi iki bölge oluşturulmaktadır.

$$R_1(j, s) = \{x | x_j \leq s\} \quad \text{ve} \quad R_2(j, s) = \{x | x_j > s\} \quad (2.4)$$

Daha sonra j bölme değişkeni, s bölünme noktası ve yarı düzlem çiftleri tanımlanmaktadır; ilk bölünme denklem 2.5 çözülerek elde edilmektedir.

$$\min_{j,s} [\min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_2)^2] \quad (2.5)$$

Her bir bölme değişkeni için, bölünme noktası s 'in belirlenmesi hızlı bir şekilde denklem 2.6'daki gibi yapılabilmektedir ve bu nedenle tüm girdileri tarayarak en iyi çiftin (j, s) belirlenmesi mümkün olmaktadır. En iyi bölünmeyi bulduktan sonra veriler, sonuçta ortaya çıkan iki bölgeye bölünmekte ve bölme işlemi her iki bölgede de tekrarlanmaktadır. Ardından bu süreç, sonuçta ortaya çıkan tüm bölgeler üzerinde yinelenmektedir.

$$\hat{c}_1 = \text{ortalama}(y_i | x_i \in R_1(j, s)) \quad \text{ve} \quad \hat{c}_2 = \text{ortalama}(y_i | x_i \in R_2(j, s)) \quad (2.6)$$

2.4.2.3. Regresyon Ağacı Budama

Regresyon ağaçlarında ağaç boyutu modelin karmaşıklığını belirleyen bir ayarlama parametresidir ve optimum ağaç büyüklüğü, veriye bağlı olarak seçilmelidir. Çok büyük bir

ağaç, aşırı öğrenmeye neden olabilmekte; küçük bir ağaç ise önemli yapıyı yakalayamayabilmektedir.

Ağaç düğümlerini bölmek için bir yaklaşım; eğer bölmeden dolayı hata karelerin toplamının azalması bir eşik değerini aşar ise olabilmektedir. Bununla birlikte; görünüşte değersiz bir bölünmeden çok daha aşağıya bölünmeler gerçekleştirilebileceğinden bu yaklaşım çok tercih edilmemektedir.

Tercih edilen yaklaşım ise; T_0 olarak adlandırılan büyük bir ağaç büyütme ve bölünme sürecini minimum düğüm sayısına (örneğin 5) ulaşıldığında durdurmaktır. Ulaşılan bu büyük ağaç maliyet kompleksliği budaması kullanılarak budanır.

T_0 'ın herhangi bir sayıda iç düğümlerinin budanmasından elde edilebilecek herhangi bir ağaç, T_0 'ın alt kümesi olan T olarak denklem 2.7'deki gibi belirlenmektedir. Terminal düğümler m ile gösterilmekte, R_m ise bölgeyi temsil etmektedir. T 'deki terminal düğümlerin sayısı $|T|$ olarak simgelenir;

$$\begin{aligned} N_m &= \#\{x_i \in R_m\}, \\ c'_m &= \frac{1}{N_m} \sum_{x_i \in R_m} y_i, \\ Q_m(T) &= \frac{1}{N_m} \sum_{x_i \in R_m} (y_i - c'_m)^2, \end{aligned} \tag{2.7}$$

Maliyet karmaşıklık fonksiyonu, denklem 2.8 ile elde edilmektedir.

$$C_\alpha(T) = \sum_{m=1}^{|T|} N_m Q_m(T) + \alpha |T|. \tag{2.8}$$

α nın tahmini 5 veya 10 kez çapraz doğrulama ile sağlanır. Çapraz kareler toplamını en aza indirgeyen α değeri araştırılır. Elde edilen son ağaç T_α olarak elde edilir (Hastie ve diğ., 2009).

2.4.2.4. Karar Ağacı Algoritmalarının Avantajları

Karar ağacı algoritmalarının avantajlarını aşağıdaki gibi sıralamak mümkündür:

- Karar ağaçları parametrik değildir. Girdi ve çıktı değişkenleri arasındaki karmaşık ilişkileri herhangi bir önsel varsayım yapmadan modelleyebilmektedirler.
- Karar ağaçları heterojen verileri (sıralı veya kategorik değişkenler veya ikisinin karışımı) işlemektedirler.

- Karar ağaçları, aykırı değerlere veya etiketlerdeki hatalara karşı dayanıklıdır.
- Karar ağaçları kolayca yorumlanabilirler.
- Karar ağaçları yapısı itibarıyla özellik seçimini gerçekleştirirler ve onları alakasız veya gürültülü değişkenlerden ayırarak en azından bir dereceye kadar sağlam (robust) hale getirirler.
- Karar ağaçları, rassal orman algoritması ve artırım (boosting) yöntemleri de dahil olmak üzere birçok modern ve son teknoloji algoritmanın yapıtaşdır. Bu nedenle bu yöntemlerin analizi için, tek bir karar ağacının tüm algoritmik ayrıntılarını anlamak ön koşuldur (Breiman ve Cutler, 2004; Hastie ve diğ., 2009).

2.4.3. Torbalama Yöntemi

Torbalama (bagging) yöntemi, tahmin fonksiyonunun varyansını azaltmak için kullanılan bir tekniktir. Torbalama yönteminin ardında yatan temel fikir, birçok gürültülü (noisy); ancak neredeyse yansız (low bias) modellerin ortalamasının alınarak varyansın azaltılmasıdır.

Torbalama yönteminin; ağaçlar gibi yüksek sapma ve düşük yanlılığın görüldüğü prosedürler için iyi sonuçlar verdiği görülmüştür. Bu çalışmada kullanılan algoritmalarından biri olan Rassal orman algoritması, torbalama yönteminin önemli ölçüde modifiye edilmesi ile oluşturulmuştur (Hastie ve diğ., 2009).

2.4.4. Rassal Orman Algoritması

Rassal orman (Random Forest, RF) algoritması, büyük bir ilintisiz (decorrelated) ağaç topluluğu oluşturan ve daha sonra bu ağaçların ortalamasını alan torbalama yönteminin önemli bir modifikasyonudur. (Hastie ve diğ., 2009).

Algoritma, Breiman (2001) tarafından tanıtılmış olmasına rağmen; algoritmanın geliştirilmesini sağlayan fikirlerin birçoğu, literatürde daha öncesinde farklı şekillerde yer almaktadır. Breiman (2001), Ho (1995) tarafından önerilen ve rassal alt gruplar seçmek için kullanılan rassal alt uzay seçme tekniğini ve yine Breiman (1996) tarafından geliştirilen torbalama (bagging) yöntemini birleştirerek rassal orman algoritmasını geliştirmiştir.

Friedman ve Hall (2007), torbalama yönteminde kullanılan yer değişiminin yerine alt örnekleme kullanarak alternatif bir yöntem geliştirmiştir. $N / 2$ boyutundaki örnekleme ağaçların büyümesinin ve ortalamasının alınmasının, yansızlık / varyans değerlendirmesinde,

torbalama yöntemi ile yaklaşık eşdeğer olduğunu; hatta N 'in daha küçük kesirli değerlerinde varyansı daha da azalttığını göstermişlerdir.

2.4.4.1. Rassal Orman Algoritması Adımları

Rassal orman algoritmasının regresyon için sözde kodu Şekil 2.2'de gösterilmektedir.

1. Ağaç sayısı $b = \{1, 2, \dots, B\}$ için

(a) Eğitim verisinden N gözlemlili olan “Bootstrap” örneklemini (Z^*) çek.

(b) Minimum düğüm sayısına (n_{min}) ulaşılan kadar, aşağıdaki adımları yinelemeli olarak tekrarlayarak bu örneklemden T_b RF ağaçları büyüt:

i. p tahmin edici değişkenden m tanesini rassal seç.

ii. m değişken arasından en iyi değişken / bölünme noktası seç.

iii. Düğümü iki yavru düğüme böl.

2. Ağaç topluluğunun çıktısı al. $\{T_b\}_1^B$

Yeni x noktasında tahmin yapmak için kullanılan fonksiyon:

$$\hat{f}_{rf}^B(x) = \frac{1}{B} \sum_{b=1}^B T_b(x)$$

Şekil 2.2 : Rassal orman algoritması sözde kodu (Hastie ve diğ., 2009).

Rassal orman algoritması için Şekil 2.2'de sunulan sözde kodun daha detaylı adımları aşağıdaki şekilde izlenmektedir:

Adım 1: Belli sayıda ağaca sahip ormanda eğitim verisinden yer değiştirme metodu ile N_T örneklem seçilir.

Adım 2: Her bir “bootstrap” örnekleminde, özellikler arasından rassal seçilen N_V değişkeni baz alınarak regresyon ağaçları büyütülür.

Adım 3: Torbalama yöntemi ile test verisi elde edilir. Bu teknik, “bootstrap” örnekleminde oluşturulan ağaçların çıktı değerlerinin ortalamasını alır.

Yukarıdaki algoritma, model performansında iyi bir tahminleme sağlamaktadır. Her bir “bootstrapping” örnekleminin $1/3$ 'ü, torba dışı (Out Of Bag , OOB) durumu olarak dışarıda

birakılmaktadır. Ardından, OOB durumundaki örnekleme'deki ağaçların ortalama hatalar karesi hesaplanmaktadır. Hesaplanan hataların ortalaması alınarak hata oranı (error rate) elde edilmektedir.

N_T örneklemini yeterince büyük olduğu durumda hata oranı doğru olmaktadır. Sonuç olarak, rassal orman algoritmasında çapraz geçerlilik gibi geçerlilik stratejilerine gerek yoktur.

RF algoritmasında ormandaki her ağaç (temel öğrenici), iki rassallık kaynağını kullanarak gelişmekte ve böylece ağaçlar arasındaki korelasyon azalarak daha güvenilir bir algoritma elde edilmektedir. Bu iki kaynak şu şekildedir:

- Herbir ağacı oluşturmak için kullanılan örneklemler, belirli bir eğitim setinden rassal seçilmektedir.
- Her bir ağacı oluşturmak için kullanılan değişkenler, mevcut girdi değişkenlerinin toplam setinden rassal seçilmektedir (Breiman, 2001).

RF algoritması, mevcut olan her tahmin değişkeninin dikkate alınmasına izin vermez; böylelikle çok güçlü olmayan tahmin edicilerin en üstteki bölünmelerde görünmesi, ağaçların çok benzer olması ve yüksek korelasyonlu tahminler yapılması engellenmektedir. Dolayısıyla ağaçlar neredeyse bağımsız olarak kabul edilebilmektedir. Böylece; neredeyse bağımsız olan birçok ağaç analiz için birleştirildiğinde, yanlış kararlar verme veya aşırı uyum (overfitting) riskleri ve tahminlerin varyansı büyük ölçüde azalmaktadır.

Sonuç olarak RF algoritması, makine öğrenmesinde etkili bir yöntem olarak, birçok sınıflandırma ve regresyon problemi için doğru tahminler sağlayan bir algoritma olarak literatürde kabul görmektedir.

2.4.4.2. Rassal Orman Algoritması Öğrenme Stratejisi

RF algoritması çok sayıda karar ağacının toplamından oluşmaktadır. Bu nedenle RF algoritması, güçlü bir gürültü önleme kabiliyeti olan basit bir yapıya ve tek bir karar ağacının yorumlama yeteneğinin çok üstünde doğruluğa sahiptir. Çok sayıda ağaçtan oluşması, aşırı uyum riskini ortadan kaldırmaktadır. RF algoritmasının öğrenme stratejisi aşağıdaki adımlar ile ifade edilebilmektedir (Huang ve diğ., 2016):

Orijinal eğitim veri setinden torbalama prensibine göre yer değiştirme metodu ile rassal N boyutlu orijinal örnek alan oluşturulmaktadır. Seçilen örneklem, CART için yeni bir eğitim seti

meydana getirmektedir. Geri kalan örneklem, bu ağacın OOB veri kümesini oluşturmaktadır. Bu süreç ormandaki ağaç sayısı kadar tekrarlanmaktadır. Tüm ağaçlar budama olmadan büyütülmektedir. Yaprak olmayan düğüm bölündüğünde, bir özelliğin segmentasyon etkisi Gini endeksi tarafından belirlenmektedir. Yaprak olmayan bir düğüm A'nın D veri kümesini içerdiğini varsayarsak, D 'de toplam d örneklem bulunmaktadır. Bir küme D 'nin Gini dizini, bir özellik tarafından bölünmeden önce denklem 2.9'daki gibidir:

$$Gini_{\text{önce}}(D) = 1 - \sum_{j=1}^l \left(\frac{d_j}{d}\right)^2 \quad (2.9)$$

Burada l , D içerisindeki kategorilerin sayısını temsil etmektedir ve d_j ($j = 1, 2, \dots, l$) j . sınıfa ait örneklerden oluşan kümedir. Özellik F , düğüm A 'yı bölmek için kullanılıyorsa, D_0 alt gruplara ($D_1, D_2, \dots, D_o$) bölünmektedir. Küme D_i ($i = 1, 2, \dots, o$) 'da toplam d_j örnekleri bulunmaktadır.

Buna göre, D grubunun segmentasyon sonrası Gini endeksi denklem 2.10 ile hesaplanmaktadır:

$$Gini_{\text{sonra}}(D) = \frac{d_1}{d} Gini_{\text{önce}}(D_1) + \dots + \frac{d_o}{d} Gini_{\text{önce}}(D_o) \quad (2.10)$$


Denklem 2.10'a göre, Gini endeksi bölütleme efektiyle ters orantılıdır. Bu nedenle daha küçük $Gini_{\text{sonra}}$ 'lı özellik ile daha iyi bir performans elde edilebilmektedir.

2.4.4.3. Rassal Orman Algoritmasının Özellikleri

Rassal orman algoritmasında temel ayar parametreleri; ormanın ağaç sayısı, ağaçların her bir bölünmesi için rassal seçilecek değişkenlerin sayısı ve her bir ağacın derinliğidir. Bu parametrelerin optimum değerlerinin seçilmesi, modellerin performans doğruluğunu önemli ölçüde artırabilmektedir. Ancak optimum değerlerin seçimi vaka incelemesine bağlıdır.

2.4.4.3.1. Her Bir Ağacın Derinliği

Her bir tek ağacın derinliği ayarlanabilmekte veya algoritma tarafından otomatik olarak seçilebilmektedir. Şekil 2.3'ten görüldüğü üzere, ağaçlar çok derinleştğinde aşırı uyum riski ortaya çıkmaktadır. Algoritmanın yapımında belirtilen α parametresi, giriş-çıkış bağımsızlık testleri için anlam düzeyini belirtmekte ve doğrudan ağaçların derinliği ile ilgilidir (Criminisi ve Shotton, 2013).




Şekil 2.3 : Her bir ağacın derinliğinin aşırı uyum riskine etkisi.

2.4.4.3.2. Ormanın Ağaç Sayısı

Topluluğu oluşturmak için kullanılan ağaçların sayısı, tahmin doğruluğunda doğrudan bir etkiye sahiptir.

Şekil 2.4'te görüldüğü gibi ağaç sayısı arttıkça hata da azalmaktadır. Fakat bu trend asimptotiktir; eğer ağaç sayısı yeterince büyük bir değer ise, ağaç sayısının artırılması tahminlerde belirgin bir iyileşme ile sonuçlanmamaktadır. Ayrıca, daha fazla ağaç kullanmak daha büyük bilgi işlem süresi gerektirmektedir. Bu nedenle; ağaç sayısı, hesaplama zamanı ile tahmini performans arasında bir dengeleme çözümü temel alınarak belirlenmektedir (Criminisi ve Shotton, 2013).



Şekil 2.4 : Topluluğu oluşturan ağaçların sayısının tahmin doğruluğuna etkisi.

2.4.4.3.3. Rassal değişken seçimi

Rassal değişken seçimi ile ağaçlar ilişkisiz hale getirilmekte, ormandaki farklı ağaçlar arasındaki benzerlik azaltılmakta ve böylece tahmin hatası en aza indirgenmektedir. Klasik bir ağaç yapılandırma yinelemeli bölünme esnasında tüm değişkenler incelenerek en iyi bölünme noktası bulunmaya çalışılırken; rassal orman algoritmasının rassal değişken seçimi özelliği ile, regresyon için tahminci değişkenlerin toplam sayısı (p)'nin $1/3$ 'ü kadar rassal değişken seçilerek bunlar arasından en iyi bölünme noktası bulunmaktadır. Bu parametrenin değerini seçmek için, girdi değişkenleri arasındaki korelasyon göz önüne alınmalıdır. Çok sayıda alakasız girdi değişkeni varsa, daha iyi tahminler elde etmek için daha büyük bir m değeri gerekmektedir.

RF algoritmasında analiz sürecinde OOB ve değişken önemi olmak üzere iki önemli parametre söz konusudur. RF algoritmasının geçerliliği için OOB tekniği kullanılırken, değişken seçimi için ise değişken önemi parametresi kullanılmaktadır. RF algoritmasına ilişkin bu kavramlar aşağıda kısaca özetlenmektedir:

2.4.4.3.4. Torba Dışı (Out Of Bag , OOB) Hata Tahmini

Rassal orman algoritmasında test setindeki hata, analiz esnasında içsel olarak tahmin edildiğinden; yansız hata tahmini için herhangi bir çapraz geçerliliğe ya da ayrı bir teste gerek

yoktur. RF algoritmasında bunun için OOB hata tahmini kullanılmaktadır ve bu tahmin N kat çapraz geçerlilikle çok benzerdir. Bunun sonucu olarak; diğer doğrusal olmayan tahminleyicilerin aksine RF algoritması, tek bir dizi şeklinde uyum elde ederken çapraz geçerlilik de birlikte performans göstermektedir. OOB hatası sabit hale geldiğinde test süreci sonlandırılmaktadır. OOB hata tahmininin gerçekleşme süreci şu şekilde tanımlanmaktadır (Huang ve diğ., 2016):

Her bir ağaç orijinal veri setinden farklı bir bootstrap örneklemini oluşturulmaktadır. Gözlemlerin yaklaşık $1/3$ 'ü, k.'nci ağacın oluşturulmasında kullanılmaz ve örneklemin dışında bırakılmaktadır. Dışarıda bırakılan bu torba dışı (OOB) veri ile her bir ağaç için hata tahmini test edilmektedir.

Her bir karar ağacı için OOB hata tahmini yapıldıktan sonra, bu hata oranlarının bir ortalaması alınarak model için tüm hata oranı tahmini hesaplanmaktadır. OOB hata oranı denklem 2.11 ile elde edilmektedir.

$$OOBE = \frac{1}{n} \sum_{i=1}^n (y_r - y_p)^2 \quad (2.11)$$

RF algoritması, elde bulunan tüm tahmin edici değişkenlerin önemini belirlemek için kullanılmaktadır. OOB hata tahminine bağlı değişken önemi belirlemek, çok sayıda çalışmada kullanılmıştır.

2.4.4.3.5. Değişken Önemi (Variable Importance)

RF algoritmasının önemli özelliklerinden bir diğeri, değişken önemini hesaplayabilmesidir. Özellik seçiminde sergilediği yüksek performans sebebiyle RF algoritması, veri bilimi problemlerinde sıkça tercih edilmektedir (Boulesteix ve diğ., 2012). RF algoritmasında iki önemli değişken önemi ölçümü vardır:

Ortalama doğruluğun azaltılması (Mean Decrease Accuracy, MDA): Değişkenin önemi, OOB durumlarda incelenen değişkenin değeri yükseldiğinde (permütasyonlu) ve diğer değişkenler değişmeden kaldığında tahmin hatasının ne kadar değiştiğine bakılarak hesaplanmaktadır.

Ortalama safsızlığın azaltılması (Mean Decrease Impurity, MDI): Değişkenin görüldüğü her bir ağaç düğümünün toplam safsızlığı azaltımının toplamı alınarak hesaplanmaktadır. MDI

ölçümünün hesaplanması hızlıdır, “bootstrap” örneklemesi gerektirmez ve uygulamada MDA ölçümü ile iyi korelasyon göstermektedir.

Bunlara ek olarak, değişken önemi analiz edilirken; yüksek korelasyonlu özelliklerin varlığına işaret eden çoklu doğrusal bağlantı problemi, tahmin yapmayı zorlaştırmakta ve bazen de model performansını düşürmektedir. RF algoritması, değişken örneklemede yüksek korelasyonlu özelliklerin seçilme olasılığını düşürerek, çoklu doğrusal bağlantı probleminin azaltılmasına yardımcı olabilmektedir.

2.4.4.3.6. Permütasyon Öneme (PI) Dayanılarak Özellik Seçimi

RF algoritması, her bir özelliğin permütasyon önemi (PI: Permutation Importance) değerini hesaplayarak tahminlemeye olan etkisini belirleyebilmektedir. F^j özelliğinin önem değerini i ağacına dayanarak hesaplarken, ilk önce $OOBHata_i$ değeri hesaplanmaktadır. Daha sonrasında OOB veri kümesindeki F^j özelliğinin değerleri, rassal biçimde yeniden düzenlenmekte ve böylece yeni bir OOB_i veri seti oluşturulmaktadır. Bu sırada diğer özellikler değişmemektedir. Ardından yeni oluşturulan setin de $OOBHata'_i$ değeri hesaplanmaktadır. i .ağaç için F^j özelliğinin PI değeri, $OOBHata'_i$ değerinden $OOBHata_i$ çıkarılarak denklem 2.12'deki gibi elde edilmektedir.

$$PI(F^j) = OOBHata'_i - OOBHata_i \quad (2.12)$$

Bu hesaplama, her ağaç için tekrarlanmaktadır. F^j özelliği için en son PI değeri, tüm ağaçlardan elde edilen PI değerlerinin ortalaması alınarak denklem 2.13'deki gibi elde edilmektedir.

$$PI(F^j) = \frac{1}{c} \sum_{i=1}^c PI_j(F^j) \quad (2.13)$$

Bir özellik önemli ise, farklı örneklerin değerleri farklı olmayacaktır. Bu özelliğin değerleri OOB veri setinde rassal olarak yeniden düzenlendikten sonra, farklı örneklemlerin ayrımcılıkları azaltılacaktır. Yüksek PI değeri olan özellik, diğer özelliklerden daha önemlidir.

2.4.5. Artırım Yöntemi

Artırım (boosting) yöntemi, son 25 yılda tanıtılan en güçlü öğrenme tekniklerinden biridir. Bu yöntem, ilk olarak 1996 yılında Freund ve Schapire tarafından Adaboost algoritması olarak uygulanmıştır. Kademe bazında eklemeli model olarak da tanımlanabilmektedir (Freund ve

Schapiro, 1996). Başlangıçta sınıflandırma problemleri için tasarlanmış olan bu yöntem, regresyon problemlerinde de başarılı sonuçlar elde etmiştir.

Model oluşturmaya zayıf bir sınıflandırma veya regresyon ağacı ile başlanmaktadır ve daha sonrasında mevcut model performansını iyileştirmek amacı ile modele başka bir sınıflandırma veya regresyon ağacı eklenmektedir. Geçmiş sınıflandırıcının nerede hata yaptığı hesaba katılmaktadır. Bir ağaç oluşturulduktan sonra; algoritma, önceki hatalara ağırlık atayarak yeni bir ağaç oluşturmaktadır.

Artırım yönteminin ardında yatan motivasyon, güçlü bir “topluluk” üretmek için birçok “zayıf “ sınıflandırıcının çıktılarının birleştirilmesidir. Bu özelliği ile, torbalama (bagging) ve diğer topluluk temelli yaklaşımlar ile benzerlik taşımaktadır.

Artırım yöntemi ve rassal orman algoritmaları arasındaki temel fark, topluluk yapısının nasıl oluşturulduğudur. Rassal orman algoritmasında ağaçlar bağımsızdır, maksimum derinlik değerlerine ulaşabilirler ve modele eşit katkıda bulunabilmektedirler. Artırım yönteminde ise prosedür oldukça farklıdır; ağaçlar geçmiş ağaçlara bağımlıdır, derinlikleri sınırlıdır ve nihai modele farklı bir biçimde katkıda bulunmaktadır. Nihai sınıflandırıcı, tüm sınıflandırıcıların ağırlıkları ortalamasıdır (Hastie ve diğ., 2009) .

2.4.6. Gradyan Artırım Makinesi

Sınıflandırma ve regresyon ağaçları, torbalama, rassal orman ve artırma gibi modellerin sunulması ile gelişen karar ağacı algoritmalarına; Friedman (2001) tarafından Gradyan artırım makinesi (Gradient Boosting Machine, GBM) adı verilen yeni bir algoritma eklenmiştir.

GBM, regresyon veya sınıflandırma karar ağaçlarından oluşan topluluk makine öğrenmesi algoritmasıdır. Hem regresyon hem sınıflandırma algoritmaları, kademeli olarak iyileştirilmiş tahminler kullanarak nihai tahmin sonucu elde eden ileri öğrenme topluluğu yöntemleridir. Zayıf sınıflandırma algoritmaları, bir dizi karar ağacı oluşturmak için artırımlı olarak değiştirilen verilere sıra ile uygulanmakta ve zayıf tahmin modelleri topluluğu oluşturmaktadır. Ağaçları artırım işlemi, tahmin doğruluğunu yükseltmek ile birlikte algoritmanın hızını ve kullanıcı tarafından yorumlanabilirliğini azaltmaktadır. GBM ise, bu dezavantajları en aza indirmek için ağaç artırımını genelleştirmektedir (Click ve diğ., 2020). GBM algoritması, gradyan tabanlı optimizasyon ve artırım yöntemlerini birleştirmektedir.

2.4.6.1. Gradyan Artırım Makinesi Algoritması Adımları

Gradyan artırım makinesi algoritmasının sözde kodu Şekil 2.5'te gösterilmektedir.

Girdi değeri : $\{(x_i, y_i)\}_{i=1}^N$ veri seti ve diferansiyel kayıp fonksiyonu $L(y_i, F(x))$

1. $f_0(x) = \operatorname{argmin}_{\gamma} \sum_{i=1}^N L(y_i, \gamma)$ değeri ile başla.

2. Her $m = 1$ 'den M 'e :

(a) Her $i = 1, 2, \dots, N$ 'e aşağıdaki formülü hesapla.

$$r_{im} = \left[\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \right]_{f=f_{m-1}}$$

(b) r_{im} değerleri ile regresyon ağaçları oluştur ve

R_{jm} , $j = 1, 2, \dots, J_m$ terminal alanları yarat.

(c) Her $j = 1, 2, \dots, J_m$ hesapla.

$$\gamma_{jm} = \operatorname{argmin}_{\gamma} \sum_{x_i \in R_{jm}} L(y_i, f_{m-1}(x_i) + \gamma)$$

(d) $f_m(x) = f_{m-1}(x) + v \sum_{j=1}^{J_m} \gamma_{jm} I(x \in R_{jm})$ değerini güncelle.

3. $\hat{f}(x) = f_M(x)$ çıktı değeridir.

Şekil 2.5 : Gradyan artırım makinesi algoritması sözde kodu (Friedman, 2001; Hastie ve diğ., 2009).

Şekil 2.5'te yer alan sözde kodda $\{(x_i, y_i)\}_{i=1}^N$, eğitim veri setini temsil etmektedir. $i = \{1, 2, \dots, N\}$ olmak üzere N , veri setindeki gözlem sayısını; x_i değerleri ise, yanıt değerini tahminlemek için eğitim veri setinden kullanılan öznitelikleri ifade etmektedir. y_i değerleri, eğitim veri setindeki her bir gözlemin çıktı değeridir.

$L(y_i, f(x))$, diferansiyel kayıp fonksiyonunu belirtmektedir. Bu fonksiyon; eğitim verisine uygulanan yöntemin, eğitim veri setine ne kadar iyi uyumlandığını değerlendirmek için kullanılacak yöntemi ifade etmektedir. Regresyon problemleri için gradyan artırım makinesinde kullanılan en yaygın kayıp fonksiyonu denklem 2.14 'te verilmiştir.

$$\frac{1}{2} [y_i - f(x_i)]^2 \quad (2.14)$$

Denklem 2.14'te y_i veri setinde gözlemlenen değeri, $f(x_i)$ modelin tahminlemesi sonucu elde edilen yanıt değerini göstermektedir.

Modele sabit bir başlangıç değeri olan denklem 2.15 ile başlanmaktadır.

$$f_0(x) = \operatorname{argmin}_{\gamma} \sum_{i=1}^N L(y_i, \gamma) \quad (2.15)$$

İkinci aşamada döngü yapısı mevcuttur. m değeri, oluşturulacak ağaç sayısını temsil etmektedir. Modeldeki her bir gözlem ve ağaç için pseudo kalıntı değerleri denklem 2.16 ile hesaplanmaktadır.

$$r_{im} = \left[\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \right]_{f=f_{m-1}} \quad (2.16)$$

r_{im} değerleri için regresyon ağacı uyumlanmakta ve ağacın yapraklarını ifade eden j değeri için $j = 1, 2, \dots, J_m$ 'e R_{jm} terminal alanları yaratılmaktadır.

Oluşturulan ağaçtaki her bir yaprak için γ_{jm} çıktı değeri denklem 2.17 ile elde edilmektedir.

$$\gamma_{jm} = \operatorname{argmin}_{\gamma} \sum_{x_i \in R_{jm}} L(y_i, f_{m-1}(x_i) + \gamma) \quad (2.17)$$

Denklem 2.17'nin modelin sabit başlangıç değeri formülünden farkı; bir önceki tahmin değerinin hesaba katılması ve tüm gözlem değerleri yerine R_{jm} terminal alanındaki gözlem değerlerinin kullanılıyor olmasıdır.

$f_m(x)$ değeri; gerçekleştirilen bir önceki tahmin değeri $f_{m-1}(x)$ ve oluşturulan yeni ağaç baz alınarak denklem 2.18'deki gibi güncellenmektedir.

$$f_m(x) = f_{m-1}(x) + v \sum_{j=1}^{J_m} \gamma_{jm} I(x \in R_{jm}) . \quad (2.18)$$

Burada v , 0 ile 1 arasında değer alan öğrenme oranını sembolize etmektedir. Öğrenme oranı her bir ağacın nihai tahmin değerindeki etkisini düşürerek, uzun vadede tahmin doğruluğunda iyileşme sağlamaktadır.

Elde edilen $f_m(x)$ değeri, veri setindeki her bir gözlem değeri için tahminlemede kullanılmaktadır. $\hat{f}(x) = f_M(x)$ çıktı değeridir (Friedman, 2001; Hastie ve diğ., 2009).

2.4.6.2. Gradyan Artırım Makinesi Algoritması Öğrenme Stratejisi

Gradyan Artırım Makinesi Algoritması, her bir iterasyonda karar ağaçlarının negatif gradyanlarını (kalan hataları) modelleyerek öğrenmektedir. GBM algoritmasının öğrenme stratejisini aşağıdaki gibi özetlemek mümkündür:

Ağaç derinliği P ve iterasyon sayısı B değerleri belirlendiğinde $B = 1'$ den B' e kadar:

- (1) Zayıf bir regresyon ağacı veri setine uyumlanır.
- (2) Gözlenen değer ile herbir gözlenen değer için tahminlenen değer arasındaki fark olan kalıntı değerleri hesaplanır.
- (3) Kalıntı değerlerini yanıt olarak kullanarak, derinliği P olan bir regresyon ağacı oluşturulur.
- (4) Önceki adımda oluşturulan regresyon ağacı kullanılarak herbir örneklem tahmin edilir.
- (5) Mevcut adımda oluşturulan tahmin değerine bir önceki iterasyonun tahmin değeri eklenerek, her örneğin tahmin değeri güncellenir.

2.4.6.3. Gradyan Artırım Makinesi Algoritmasının Parametreleri

Gradyan artırım makinesi algoritmasının rassal orman algoritmasından daha iyi bir performans sergileyebilmesi için, parametrelerini doğru bir şekilde ayarlamak ve herbir problem için bu parametrelerin en iyi kombinasyonunu bulmak önemlidir. GBM algoritmasının en önemli parametrelerinden bazıları şunlardır (García-Calderón Chávez, 2017):

Öğrenme Hızı (Learning rate): Aşırı uyumu önlemek amacı ile her bir aşamada kullanılan adım boyutu büzülmesidir. Herbir artırım adımından sonra, yeni özelliklerin ağırlıkları doğrudan alınabilmektedir. Öğrenme hızı, özellik ağırlıklarını $[0, 1]$ arasında küçültür.

Satır örnekleme (Row sampling): Eğitim örnekleminde seçilen alt örneklem oranıdır. $(0,1]$ aralığında değer alır. Satır örnekleminin 0,4 olarak ayarlanması, GBM'in ağaç oluşturmak için veri setinin %40'ını rassal toplaması anlamına gelmekte ve bu durum aşırı uyumu engellemektedir.

Sütun örnekleme (Column sampling): Herbir ağacın oluşturulurken veri setinde kullanılacak sütunların alt örneklem oranını ifade eder ve $(0,1]$ aralığında değer alır.

Minimum yaprak ağırlığı (Min leaf weight): Her bir yaprak düğümünde kullanılacak minimum örneklem ağırlığının toplamını ifade eder. Ağaç bölme adımı, örnek ağırlığının minimum çocuk ağırlığından daha az olan bir yaprak düğümü ile sonuçlanırsa, oluşturma işlemi daha fazla bölümlendirmeyi bırakacaktır. Doğrusal regresyon modunda bu, sadece her bir düğümde olması gereken minimum örnek sayısına karşılık gelmektedir. $[0,1]$ aralığında değer alır.

Maksimum Ağaç Derinliği (Max Tree Depth): Bir ağacın maksimum derinliğinin artırılması, modeli daha karmaşık hale getirmekte, modelin aşırı uyum riskini artırmaktadır. Bu nedenle optimum değer seçilmelidir. $[0, \infty]$ aralığında değer alır.

Minimum Bölünme Kazancı (Min Split Gain): Ağacın yaprak düğümünde daha fazla bölüm oluşturmak için gereken minimum kayıp azaltımını ifade eder. Değerin büyümesi, modelin daha muhafazakar olmasına yol açar. $[0, \infty]$ aralığında değer alır.

2.5. TAHMİNLEME MODELLERİNDE İŞLEMLER

Bu başlık altında; makine öğrenmesi modellerinde kullanılan çapraz geçerlilik, hiperparametre ayarlama ve tahmin performansı değerlendirme ölçütleri gibi farklı başlıklar ele alınacaktır.

2.5.1. Çapraz Geçerlilik


Makine öğrenmesi çalışmalarında, uygulanan yöntemin başarısının değerlendirilmesi için modelin genellebilirliğine bakılmaktadır. Genellebilirlik, modelin eğitilmediği verilerde ne kadar iyi performans gösterdiği anlamına gelmektedir.

Veri seti; eğitim ve test veri seti olarak ayrılmaktadır. Bu ayırma süreci, çeşitli oranlarda (%70-%30, %66-%33, %80-20 vb.) yapılabilir. Veri setinin %80'lik kısmının eğitim veri seti, %20'lik kısmının ise test veri seti olarak ayrılması; eğitim veri seti ile modelin eğitilmesinin ardından, test veri seti ile modelin başarısının değerlendirilmesi sıklıkla tercih edilen bir yöntemdir.

Modelin genellebilirliğini ölçen bir diğer yöntem de k-katlamalı çapraz doğrulamadır. k-katlamalı çapraz doğrulama, veri kümesinin örneklendiği ve ardından k kez bölümlendiği bir yöntemdir. Bu yöntem, veri kümesini kalan k-1 bölümlerle eğitirken; her bölümü tahmin etmek amacı ile verilerin 1'den k'a kadar etiketlendiği yinelemeli bir süreçtir. K-katlamalı çapraz doğrulama yönteminde bir k değeri belirlenmektedir. Şekil 2.6'de görselleştirilmesi yapılan 10-katlamalı çapraz doğrulama yöntemi, literatürde en çok tercih edilen çapraz geçerlilik yöntemidir.

Tüm veri seti ile tahmin gerçekleştirildikten sonra, aralarından hata oranı en düşük olan alınmaktadır. k-katlamalı çapraz doğrulama uygulandıktan sonra, tahmin modelinin

değerlendirme ölçütleri değerlerine güvenmek daha doğru olmaktadır (García-Calderón Chávez, 2017).



Şekil 2.6 : 10 katlamalı çapraz geçerlilik yöntemi (García-Calderón Chávez, 2017).

2.5.2. Hiperparametre Ayarlama

Hiperparametreler, algoritmaların eğitim davranışlarını doğrudan kontrol ettikleri ve makine öğrenmesi modellerinin performansı üzerinde önemli bir etkiye sahip oldukları için makine öğrenmesi problemleri için önemlidir. Hiperparametre ayarlama (hyperparameter tuning), hiperparametre optimizasyonu olarak da adlandırılmaktadır ve makine öğrenmesi algoritmalarının tahmin doğruluğunda hayati bir rol oynamaktadır (Wu ve diğ., 2019).

Hiperparametre optimizasyonu probleminin çözümü için genellikle Bayezyen optimizasyon teknikleri, genetik algoritmalar, ızgara arama ve rassal arama gibi yöntemler tercih edilmektedir. Bu tez çalışmasında kullanılan tahmin modellerinin hiperparametrelerini optimize etmek için, talep tahmini problemlerinde yaygın tercih edilmeleri nedeni ile ızgara arama ve rassal arama yöntemleri kullanılmıştır. Bu yöntemlerin detayları aşağıda yer almaktadır.

2.5.2.1. Izgara Arama

Izgara arama (grid search), hiperparametre değerlerinden oluşan bir ızgara yapısı oluşturmakta; her bir hiperparametre kombinasyonunu değerlendirmekte ve algoritma en iyi sonucu döndürmektedir (Bergstra ve Bengio, 2012). Izgara arama, kapsamlı bir aramadır.

Örnek olarak; kurulan modelde 3 parametrenin değerlendirildiği ve bu 3 parametreye sırası ile 5, 10, 2 değer atandığı durumda ızgara yapısı $5 \times 10 \times 2 = 100$ model oluşturulmaktadır. Izgara arama, eğitim setindeki olası hiperparametre değerlerinin her kombinasyonu ile bir makine öğrenmesi modelini eğitmekte, performansı bir çapraz doğrulama setinde önceden tanımlanmış bir metriğe göre değerlendirmekte ve en iyi performansı sağlayan hiperparametreleri üretmektedir. Izgara arama yöntemi basittir ve bu yöntemi paralelde çalışacak hale getirmek mümkündür; ancak toplam hesaplama süresi açısından maliyetli bir yöntemdir.

2.5.2.2. *Rassal Arama*

Rassal arama (random search); ızgara aramadaki gibi tüm ızgaranın aranması yerine, yalnızca ızgaradaki rassal bir nokta örneklemini değerlendiren bir yöntemdir. Bu durum, ızgara aramaya göre toplam hesaplama süresi bakımından önemli bir avantaj kazandırmaktadır. Rassal arama, ızgara arama ile karşılaştırıldığında, yüksek boyutlu bir uzayda daha etkilidir (Wu ve diğ., 2019).

Bergstra ve Bengio (2012), saf bir ızgara arama ile yapılandırılan sinir ağları ile karşılaştırıldığında rassal aramanın, daha kısa sürede ızgara aramaya kıyasla iyi veya daha iyi olan modelleri bulabildiğini göstermişlerdir.

2.5.3. Regresyon Problemlerinde Kullanılan Değerlendirme Ölçütleri

Literatürde regresyon problemlerinin değerlendirme ölçütü olarak kullanılan birçok ölçüt bulunmaktadır. Bu ölçütlerden yaygın olarak kullanılanları şöyledir: Ortalama Mutlak Hata, Kök Ortalama Kare Hata, Ortalama Mutlak Yüzde Hata ve R^2 değeri. Bu bölümde bu ölçütler kısaca anlatılacaktır.

2.5.3.1. *Ortalama Mutlak Hata*

Ortalama Mutlak Hata (Mean Absolute Error, MAE) değeri, tahmin ve gözlemlenen satış değerlerinden denklem 2.19'daki gibi hesaplanmaktadır:

$$MAE = \frac{1}{N} \sum_{i=1}^N |S_G^i - S_T^i| \quad (2.19)$$

S_G = Gözlemlenen satış değeri

S_T = Tahmin edilen satış değeri

MAE değerinin en önemli sorunu, ortalama talebe göre ölçeklenmemiş olmasıdır. Bu nedenle bu çalışmada bu ölçütten yararlanılmayacaktır.

2.5.3.2. Ortalama Mutlak Yüzde Hata

Regresyon modellerinin değerlendirmesinde yaygın olarak kullanılan ölçütlerden biri “Ortalama Mutlak Yüzde Hata” dır. Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error, MAPE) değeri, tahmin ve gözlemlenen satış değerlerinden denklem 2.20 ile hesaplanmaktadır:

$$MAPE[\%] = \frac{1}{N} \sum_{i=1}^N \frac{|S_G^i - S_T^i|}{S_G^i} * 100 \quad (2.20)$$

S_G = Gözlemlenen satış değeri

S_T = Tahmin edilen satış değeri

MAPE değeri %10’un altında olan modeller “çok iyi”, % 10 ile % 20 arasında olan modeller “iyi”, % 20 ile % 50 arasında olan modeller “kabul edilebilir” ve % 50’nin üzerinde olan modeller ise “yanlış ve hatalı” olarak sınıflandırılmaktadır (Lewis, 1982; Var ve Türkay, 2014).

2.5.3.3. Kök Ortalama Kare Hata

Kök Ortalama Kare Hata (Root Mean Square Error, RMSE), tahminlenen ve gözlemlenen değerler arası uzaklığın bulunmasında kullanılan hatanın büyüklüğünü ölçen bir kuadratik ölçüttür. RMSE hata değeri, tahmin ve gözlemlenen satış değerlerinden denklem 2.21 ile hesaplanmaktadır:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_G^i - S_T^i)^2} \quad (2.21)$$

S_G = Gözlemlenen satış değeri

S_T = Tahmin edilen satış değeri

2.5.3.4. R^2 Değeri

Modeli değerlendirmek için kullanılan bir diğer önemli ölçüt, R^2 (Determinasyon Katsayısı) değeridir. İstatistikte determinasyon katsayısı, bağımsız değişkenlerden tahmin edilebilen yanıt değişkenindeki varyans oranını gösteren bir sayı olarak tanımlanmaktadır. Genel olarak, model ne kadar iyi olursa, R^2 değeri o kadar yüksektir. R^2 değeri denklem 2.22 ‘de ifade edildiği gibi hesaplanmaktadır.

$$R^2 = 1 - \frac{SS_{kalıntılar}}{SS_{toplam}} = 1 - \frac{\sum_i^n (y_i - \hat{y}_i)^2}{\sum_i^n (y_i - \bar{y}_i)^2} \quad (2.22)$$

$SS_{kalıntılar}$ artıkların toplam kareler toplamını ve SS_{toplam} ise toplam kareler toplamını ifade etmektedir. R^2 değeri varyasyonun ne kadarının kurulan regresyon modeli ile açıklanabildiğini göstermektedir. İyi bir regresyon modelinin R^2 değeri 1'e yakın olacaktır. Probleme bağlı olarak 0.8'in üzerindeki bir R^2 değeri iyi bir determinasyon katsayısı olarak kabul edilebilmektedir (García-Calderón Chávez, 2017).

2.5.3.5. Modelin Hesaplama Süresi

Hesaplama süresi, makine öğrenmesi modelleri için önemli bir metriktir. Bazı modellerin tahminlemeyi gerçekleştirebilmeleri için gereken hesaplama maliyetleri yüksektir; bu modeller değerlendirme ölçütlerine göre iyi sonuçlar vermelerine rağmen, zaman kısıtlamaları nedeni ile pratik kullanım için uygun değildirler. Kurulan tahmin modelinin makul sürede tahminlemeyi gerçekleştirmesi ve artan veriye ölçeklenebilmesi performans açısından beklenmektedir.

2.6. OPTİMİZASYON

Optimizasyon; veri bilimi dahil olmak üzere üretimde, hizmet sektöründe ve birçok alanda çok önemlidir. Her kararın süreç ve organizasyonun kârı için önemli olduğu üretimde; üretilen her ürünün sayısının belirlenmesinden, üretimin nasıl çizelgeleneceğine ve süreç için en uygun parametrelerin belirlenmesine kadar hemen hemen her aşamada optimizasyon problemlerine rastlanmaktadır.

Optimizasyon, literatürdeki tanımına göre kısıtlı kaynakların optimal dağılımını belirlemek için yararlanılan matematiksel bir prosedürdür (Avriel, 2003).

Bu tez çalışmasında; geliri en üst düzeye çıkarmak için, incelenen her ürünün talep tahmin çıktılarını, optimizasyon modelinin bir girdi değeri olarak kullanarak en uygun fiyat kombinasyonunu belirlemek amaçlanmaktadır.


Literatürde, optimizasyon problemlerinin sınıflandırması net olarak oluşturulamamıştır ve özellikle bazı terminolojilerin kullanımı konusunda karışıklıklar mevcuttur. Yang (2010)'ın çalışmasını baz alarak optimizasyon problemlerini Şekil 2.7'de görüldüğü gibi amaç sayısına, kısıt durumuna, fonksiyon yapısına, karar değişkenlerinin türüne ve belirliliklerine göre sınıflandırabilmek mümkündür.

Optimizasyon problemleri amaç sayısına göre tek amaçlı ve çok amaçlı optimizasyon problemleri olarak ikiye ayrılabilir. Benzer şekilde optimizasyon problemleri, kısıt durumuna göre kısıtlandırılmamış ve kısıtlı olarak ikiye ayrılmaktadır. Karar değişkenlerinin türüne göre optimizasyon problemlerini kesikli, sürekli ve karma olarak sınıflandırılabilir. Fonksiyon yapılarına göre ise optimizasyon problemleri doğrusal optimizasyon ve doğrusal olmayan optimizasyon olarak ikiye ayrılabilir.

Doğrusal Optimizasyon problemlerinde uygulanabilir aralığın sınırı aşırı düzlem (hyperlane) ve maliyet fonksiyonu doğrusaldır. Bir grafik ile temsil edilmek istendiğinde, amaç fonksiyonun maksimizasyon ya da minimizasyon olmasından bağımsız olarak, istenen çözümü sağlayan benzersiz bir nokta veya değer olduğunu gözlemlemek mümkündür.


Doğrusal olmayan optimizasyon problemleri, doğrusal olmayan amaç fonksiyonları ile ilgilenebilir. Amaç fonksiyonu, bir veya birden fazla maksimum veya minimum değere sahip, herhangi bir polinom türü olabilir. Bu tez çalışmada ele alınan problemin türü, doğrusal olmayan optimizasyon sınıfına girmektedir.

Optimizasyon yöntemleri ise belirliliklerine göre deterministik veya stokastik olarak sınıflandırılabilir. Yalnızca birkaç boyuta ve iyi ayrılmış yerel minimum değerlere sahip basit konveks olmayan fonksiyonlar için simpleks optimizasyonu (simplex optimization), en dik iniş yöntemi (steepest descent method) ve yarı-Newton (quasi-Newton) yöntemi gibi standart deterministik yöntemler makul sonuçlar sağlayabilmektedir. Ancak deterministik yöntemler yerel minimum değere takılma eğilimindedirler. Deterministik yöntemler ile karşılaştırıldığında, birçok stokastik yöntemin yerel bir minimuma takılma olasılığı çok daha düşüktür ve stokastik yöntemler makul bir hesaplama miktarı kullanarak global minimumun iyi bir tahminini bulabilmektedirler. Global optimum problemlerini çözmek için; genetik algoritmalar (Holland, 1975), tavlama benzetimi (Kirkpatrick ve diğ., 1983), parçacık sürü optimizasyonu (Kennedy ve Eberhart, 1995) ve tabu arama (Glover ve diğ., 1993) gibi birçok stokastik yöntem geliştirilmiştir. Optimizasyon algoritmalarını Şekil 2.8’de gösterildiği gibi sınıflandırmak ve Şekil 2.9’daki gibi detaylandırmak mümkündür.




Şekil 2.7 : Optimizasyon problemlerinin sınıflandırılması (Yang, 2010; Büyüksaatçı, 2015).

Stokastik yöntemlerin deterministik yöntemlere kıyasla avantajları nedeni ile, bu tez çalışmasındaki fiyat optimizasyonu probleminin çözümü için metasezgisel algoritmalar tercih edilmişlerdir. Sörensen (2015) çalışmasında; son yıllarda kombinasyonel optimizasyon alanının, çoğu doğanın ya da insan aktivitelerinin metaforuna dayanan yeni metasezgisel yöntemlerin tsunamisine uğradığını ifade etmiştir. Ancak; hemen hemen her bir böcek ve hayvan türünün davranışına, su akışı gibi fiziksel olaylara, kimyasal reaksiyonlara ya da müziğe dayanan bu algoritmaların mevcut bilgiyi yinelemek dışında literatüre herhangi bir katkı sağlayıp sağlamadığı tartışma konusudur. Metasezgisel algoritmalar, bir algoritma mantığında takip edilmesi gereken eylemler dizisinden çok; sezgisel optimizasyon algoritmalarını tasarlamak için kullanılabilen tutarlı bir fikir, kavram ve operatör kümesidir. Dolayısıyla bir metasezgiselden bahsedilecek ise; tabu arama, genetik algoritmalar, benzetilmiş tavlama, karınca kolonisi optimizasyonu ya da parçacık sürü zekası gibi algoritmalar dikkate alınmalıdır. Çünkü; her ne kadar literatüre yeni eklenen yöntemler, yaratıcıları tarafından "orijinal" veya "yeni geliştirilen" olarak adlandırılırsalar da, mevcut bir yöntemin ara sıra ortaya çıkan marjinal varyantı dışında çoğu yeni fikir sunmamaktadır. Sörensen (2015)'in bu fikrinden yola çıkarak; bu tez çalışmasında, incelenen problemin yapısına uygun, yayınladıkları yıldan itibaren literatürdeki çalışmalarda sıklıkla tercih edilen ve performansı kanıtlanmış tavlama benzetimi ve parçacık sürü optimizasyonu algoritmaları tercih edilmiştir. Kullanılan parçacık sürü optimizasyonu, sürü zekası tabanlı algoritmalar kategorisine; tavlama benzetimi algoritması ise, fiziksel algoritmalar kategorisine girmektedir.



Şekil 2.8 : Optimizasyon algoritmalarının sınıflandırılması (Yang, 2010; Büyüksaatçı, 2015; Altay ve diğ., 2020).



Şekil 2.9 : Metasezgisel algoritmaların detaylı sınıflandırılması (Yang, 2015; Akyol ve diğ., 2017; Abdel-Basset ve diğ., 2018; Altay ve diğ., 2020).

2.7. WEB KAZIMA

Web kazıma teorik olarak; bir web sunucusunu sorgulayan, HTML (Hiper Metin İşaret Dili) ve web sayfalarını içeren diğer dosyalar biçiminde veri isteyen ve sonrasında gerekli bilgileri ayıklamak için verileri ayrıştıran bir otomasyon programı yazılarak gerçekleştirilen bir süreçtir.

Web kazıma, bir Uygulama Programlama Arayüzü (Application Programming Interface, API) ile veri çekme uygulamaları veya web tarayıcısı kullanan bir insan aracılığı ile yapılan manuel uygulamalar dışındaki veri toplama uygulamalarını kapsamaktadır. Web kazıyıcılar büyük miktarlarda veriyi toplamak ve işlemek için idealdirler (Mitchell, 2018). Birden fazla web sayfasına dağılmış olan verileri çıkarmak ve bu verileri başka bir uygulamaya veya web servisine entegre etmek amacı ile kullanılabilmektedirler.

Uygulamada web kazıma, veri analizi ve bilgi güvenliği gibi çok çeşitli programlama tekniklerini ve teknolojilerini kapsamaktadır. Veri kazıma işlemi ile elde edilen veriler veritabanında, Excel, SOAP (Basit Nesne Erişim Protokolü), REST (Temsili Durum Transferi) gibi çeşitli dosya formatlarında saklanabilmekte ve bu dosyalardan; veri madenciliği, veri görselleştirme gibi birçok uygulamada yararlanılabilmektedir (UiPath, 2020).

Fiyat ve içerik kazıma; e-ticaret, online yayıncılık, iş portalları, eğitim, emlak, seyahat, finansal bilgi siteleri gibi birçok online işletmede kullanılan başlıca veri kazıma formudur. Fiyat ve içerik kazıma ile online perakende firmaları, rakiplerinin fiyat verilerini elde ederek rekabet avantajı elde etmektedirler.

3. MALZEME VE YÖNTEM


Bu bölümde; çalışmada kullanılan yazılımların genel tanıtımı yapıldıktan ve kullanılacak veri setinin nasıl elde edildiği açıklandıktan sonra; veri setinin analizi yapılarak, veri ön işleme süreci gerçekleştirilecektir. Ardından çalışmada kullanılan yazılımlar, yöntem olarak seçilen tahminleme ve optimizasyon algoritmaları detaylı bir şekilde ele alınacaktır.

3.1. ÇALIŞMADA KULLANILAN YAZILIMLAR

3.1.1. R Programlama Dili

R veri işleme (manipülasyonu), hesaplama ve grafik görüntüleme işlevlerini yerine getiren entegre yazılım paketleri grubudur. Veri analizi için geniş, tutarlı ve entegre araçlar sunan iyi geliştirilmiş basit ve etkili bir programlama dilidir. Sanılanın aksine; sistematik bir sistem değil, istatistiksel tekniklerin uygulandığı bir ortamdır. R programı, paket yüklenmesi yoluyla genişletilebilmektedir (Venables ve diğ., 2009).

Bu çalışmada veri analizi, veri temizleme, değişken mühendisliği, tahmin modelleri, H2O modelleri için arayüz olarak ve optimizasyon modelleri çalışmalarında Şekil 3.1’de arayüzü verilen R programlama dili kullanılmıştır.




Şekil 3.1 : R Studio arayüzü.

3.1.2. H2O Derin Öğrenme Platformu

H2O derin öğrenme platformu; büyük veri üzerinde makine öğrenmesi modelleri oluşturmayı sağlayan, açık kaynak kodlu, bellek içi (in-memory), dağıtık (distributed), hızlı ve ölçeklenebilir (scalable) makine öğrenme ve tahmin modelleri platformudur (H2Oa, 2020). Platform, büyük veri setleri için; derin öğrenme, karar ağacı toplulukları, genelleştirilmiş doğrusal model, k-ortalamlar kümeleme gibi gözetimli ve gözetimsiz algoritmalar ile hızlı ve kaliteli tahminler yapılmasını sağlamaktadır. H2O'nun temel kodu Java dili ile yazılmıştır. R, Python, Scala gibi programlama dilleri, H2O flow ile model oluşturma ve tahmin yapma imkanı sağlamaktadır.

Şekil 3.2'de H2O.ai Flow arayüzüne yer verilmiştir.



Şekil 3.2 : H2O.ai Flow arayüzü.


Bu tez çalışmasında; talep tahmini için R arayüzü kullanılarak H2O ağaç tabanlı makine öğrenme algoritmaları kullanılmıştır.

3.1.3. UiPath Robotik Süreç Otomasyonu Platformu

UiPath, Robotik Süreç Otomasyonu pazarında lider platformlardandır. Robotik Süreç Otomasyonu, insanlar tarafından gerçekleştirilen hizmet görevlerinin otomasyonunun yapıldığı yazılım robotlarını ifade etmektedir (Van der Aalst ve diğ., 2018). Robotik süreç

otomasyonu ile yazılım robotuna; veri çekme, veri kaydetme, hesaplamalar ve programlama dilleri ile elde edilebilecek tüm fonksiyonlar bir iş akışı içerisinde öğretilmektedir.

UiPath'in masaüstü, Web, PDF, Excel, mail otomasyonu, veri kazıma gibi birçok fonksiyonu vardır. Şekil 3.3'de UiPath Studio arayüzüne yer verilmiştir.



Şekil 3.3 : UiPath Studio arayüzü.

Bu tez çalışmasında, rakip perakende firmalarının fiyat verilerinin çekilmesi işleminde UiPath'in veri kazıma fonksiyonu kullanılmıştır. UiPath'in veri kazıma fonksiyonu ile birden fazla web sayfasına dağılmış olan veriler ayıklanarak çıkarılmakta ve bu verileri başka bir uygulamaya veya web servisine entegre etmeden önce filtreleme ve istenilen biçime dönüştürme işlemi gerçekleştirilmektedir.

Veri kazıma işlemi ile elde edilen veriler veritabanında, .NET tablolarında, Excel, SOAP (Basit Nesne Erişim Protokolü), REST (Temsili Durum Transferi) gibi çeşitli dosya formatlarında saklanabilmekte ve böylelikle veri madenciliği, veri görselleştirme gibi birçok uygulamada kullanılabilmektedir (UiPath, 2020).


3.2. ÇALIŞMADA KULLANILAN VERİ SETİ

Bu çalışmada; dinamik fiyatlandırma karar destek sistemini geliştirebilmek amacı ile; Türkiye’de önde gelen bir gıda perakendecisinin (Perakende firması olarak adlandırılacaktır) Kurumsal Kaynak Planlama Sisteminden, toplam satış verileri ve maliyet verileri çekilmiş; ayrıca talebi ve optimizasyon modelini etkileyeceği varsayılan tamamlayıcı veriler elde edilmiştir.

Çalışmada incelenen perakende firması, online ve fiziksel mağazadan satış yapması nedeni ile çok kanallı (multichannel) hibrit iş modeline sahiptir. Ayrıca perakende firması, kendi bünyesinde eve teslim dağıtım lojistik sistemini de kullanmaktadır. Online mağazadan satış yapıldığında, ürünler depodan değil mağazalardan müşterilere teslim edilmektedir. Perakende firması, depodan eve teslim avantajına sahip değildir ve bu durum online mağazadaki ürünlerin fiyatlarının belirlenmesinde rol oynamaktadır.

Perakende firmasının satış kanallarında sattığı ürünler temelde; meyve ve sebze, et ve balık, süt ve kahvaltılık, diğer gıda ürünleri, içecekler, bebek ürünleri, temizlik ürünleri, kağıt- kişisel bakım ve kozmetik ürünleri, gıda dışı ürünler olmak üzere 9 ana kategoriden oluşmaktadır.

İlgili perakende firması, ürün portföyünü düzenlemek için hiyerarşik bir yapı kullanmaktadır. Şekil 3.4’te bu tez kapsamında incelenen bir ürünün ürün hiyerarşi grafiğine yer verilmektedir. Bu hiyerarşiye dayanarak ürün, Stok Tutma Birimi (Stock Keeping Unit, SKU) olarak da adlandırılmakta ve en üst seviyede yer almaktadır. Ürün kategorisi ise hiyerarşide en düşük seviyede bulunmaktadır.



Şekil 3.4 : Ürün hiyerarşisi grafiği.

Bu tez çalışmasında; temizlik ürünleri ve kağıt, kişisel bakım ve kozmetik ürünleri kategorilerinden, ürünlerin rakip perakende firmalarında da bulunurluğu dikkate alınarak 53 ürün incelenmiştir. Gıda perakendelerinde fiyat değişimi genellikle günlük yapıldığı için; perakende firmasının bu 53 ürüne ait 01.01.2018 ve 31.12.2019 tarihleri arasındaki 2 yıllık günlük geçmiş satış verileri dikkate alınmıştır.

Tablo 3.5'te, perakende firmasının Kurumsal Kaynak Planlama Sisteminden elde edilen ham veri setinin yapısına yer verilmiştir.

Tablo 3.5: Perakende firmasının kurumsal kaynak planlama sisteminden elde edilen ham veri seti yapısı.

<i>Değişken adı</i>	<i>Veri formatı</i>	<i>Değer aralığı</i>
Tarih	Zaman serisi	01.01.2018 - 31.12.2019
Ürün Kodu	Tam Sayı (integer)	{1,...,53}
Mağaza Kodu	Tam Sayı (integer)	{1,...,7}
Satış Kanalı	Tam Sayı (integer)	{1,2,3}
Kategori Kodu	Faktör	{1,...,4}
Alt Kategori Kodu	Faktör	{1,...,11}
Toplam Satış	Tam Sayı (integer)	{0,...,1924}
Eldeki Stok	Tam Sayı (integer)	{-19370,, 47103}
Müşteri Sayısı	Tam Sayı (integer)	{1,...,55}
Fiyat	Rasyonel sayı	(0, 1053]
Promosyon	Faktör	0-1
Ürün Maliyet	Tam Sayı (integer)	[0, 72.98]

Veri setindeki değişkenlerin tanımı ise aşağıdaki gibidir :

Tarih: Satış tahmininin incelendiği 01.01.2018 - 31.12.2019 tarihleri arasındaki tüm günleri ifade etmektedir.

Ürün Kodu: Satış tahmini yapılan 53 ürünün ürün kodu değerlerini ifade etmektedir.

Mağaza Kodu: İlgili perakende firmasının satış tahmininde kullanılan 7 mağazasının kod değerlerini ifade etmektedir.

Satış Kanalı: Perakende firmasının satışlarını gerçekleştirdiği 3 farklı satış kanalı tipini ifade etmektedir. 1: İnternet mağazası, 2: Kurumsal mağaza, 3: Fiziksel mağaza satış kanalı tipidir.

Kategori Kodu: Satış tahmininde incelenen 53 ürünün ana kategori kodlarını ifade etmektedir. 1-4 aralığında değer almaktadır. 1: Temizlik, 2: Kozmetik, 3:Kağıt, 4: Bebek kategorisini ifade etmektedir.

Alt Kategori Kodu: Satış tahmininde incelenen 53 ürünün ana kategorilerinin alt kırılımı olan alt kategori değerlerini ifade etmektedir. Kod, 1-11 aralığında değer almaktadır. 1: Çamaşır Yıkama, 2: Bulaşık Yıkama, 3: Genel Temizlik, 4: Banyo Ürünleri, 5: Saç Bakım, 6: Ağız Bakım, 7: Traş Ürünleri, 8: Hijyenik Pedler, 9: Kağıt Ürünleri, 10 : Bebek Banyo Ürünleri, 11: Bebek Bezi alt kategori değerleridir.

Toplam Satış: İlgili gündeki, birim mağazadaki ilgili ürünün satış miktarını ifade etmektedir.

Müşteri Sayısı: İlgili gündeki, birim mağazadaki müşteri sayısını ifade etmektedir.

Promosyon: Belirli bir gün için ilgili birim mağazadaki ilgili birim ürünün indirim girip girmediğini ifade etmektedir. 0: Promosyon yok 1: Promosyon olduğu durumdur.

Eldeki Stok: İlgili birim mağazadaki ilgili birim ürünün eldeki stok miktarını ifade etmektedir.

Fiyat: İlgili birim mağazadaki ilgili birim ürünün satış fiyatını ifade etmektedir.

3.3. ÇALIŞMADA KULLANILAN TAHMİN ALGORİTMALARI

Bu tez çalışmasının talep tahmini modülünde kullanılacak tahmin algoritmaları aşağıda kısaca açıklanmaktadır.

3.3.1. Dağıtık Rassal Orman Algoritması

Dağıtık Rassal Orman (Distributed Random Forest Algorithm, DRF) algoritması; Rassal orman algoritmasının geliştirilmesi ile elde edilen, büyük veriler için güçlü bir dağıtık sınıflandırma ve regresyon algoritmasıdır. Bir veri kümesi girdi olarak verildiğinde, DRF algoritması tek bir sınıflandırma veya regresyon karar ağacı yerine bir sınıflandırma veya regresyon ağaçları ormanı oluşturmaktadır. Bu ağaçların herbiri, bir satır ve sütun alt kümesi baz alınarak kurulmuş zayıf bir öğrenicidir. Ağaç sayısının artırılması, modelin varyansını azaltmaktadır.

Hem sınıflandırma hem de regresyon problemlerinde son tahmin değeri, tüm ağaçların ortalama tahmin değeri alınarak elde edilmektedir. Sınıflandırma probleminde kategorik bir yanıt sütunu için DRF algoritması faktörleri, sözcük diziliminde tam sayı indeksleri olan bir isim arama dizisine eşlemektedir (H2O, 2020a).

3.3.1.1. Dağıtık Rassal Orman Algoritmasının Özellikleri

Dağıtık rassal orman algoritmasının özellikleri aşağıda sıralanmaktadır (H2O, 2020a).

3.3.1.1.1. Yaprak Düğümü Ataması

Modeldeki ağaçlar veri setindeki gözlemleri, yaprak düğümlerine kümelemektedir. Bu yaprak düğümleri, en önemli kuralların sınırlı bir setini elde etmek için diğer modelleri besleyebilecek karar kurallarını temsil etmektedir. DRF algoritmasının bu özelliği, özellik mühendisliği ve modelin yorumlanabilirliği için faydalı olmaktadır.

3.3.1.1.2. Özellik Bölümü

DRF algoritması, modeldeki hangi özelliğin bölüneceğine karar verirken algoritmadaki tüm alanları dikkate almaktadır. Bu noktada ağaç yapısı, alt ağaçtaki kalıntı kareler toplamında en büyük azalmayı sağlayan sütun ve seviyeye bölünmektedir.

Herhangi bir şekilde sütun ve satır örnekleme alınması (her bölünme kararının tüm veri noktalarını dikkate almaması) daha robust algoritmalar üretmeyi amaçlamaktadır.

3.3.1.1.3. Eksik Değerlerin Ele Alınması

DRF algoritmasında veri kümesindeki eksik değerler, rassal eksik veri olmaktan ziyade bir nedenle eksik veri olarak kabul edilmektedirler. Algoritma yapısında, her düğüm için bölünmüş kararlar bulundurmaktadır. Bu özelliği ile kayıp fonksiyonunu en aza indirmekte ve eksik değerleri karar düğümünde sağa veya sola gidebilen bir kategori olarak ele almaktadır. Kurulan modelin testi sırasında, eksik değerlere kayıp fonksiyonunu minimize eden optimal bir yol ile karar verilmektedir.

3.3.1.1.4. Değişken Önemi Hesabı

DRF algoritması değişken önemini hesaplarken, belirli bir değişken kullanarak ağacın düğümlere bölünmeden önceki ve sonraki hata karesini baz almaktadır. DRF algoritması, bölünen her özellik için doğruluk oranı yerine hata kare değerindeki iyileşmeyi kullanmaktadır. Toplam özellik önemini elde etmek için her özellik iyileştirmesi toplanmakta ve sonrasında 0-1 değerleri arasında ölçeklendirilmektedir.

3.3.2. H2O Gradyan Artırım Makinesi

Gradyan Artırım Makinesi (Gradient Boosting Machine, GBM) algoritmasında ana hesaplama maliyeti; karar ağaçlarının öğrenilmesinde yatmaktadır ve bir karar ağacının öğrenilmesinde en çok zaman alan kısım, en iyi bölünme noktalarını bulmaktır. Bu duruma bir geliştirme olarak H2O'nun GBM uygulaması dağıtık ağaçları kullanmaktadır. H2O, veri setindeki tüm gözlemler ile, sayısal sırada olup olmadığında bakılmaksızın en verimli yöntemi kullanarak ağaç oluşturmaktadır. Ağacın her düğümündeki her satır için, paralel olarak yalnızca yerel verileri kullanan bir yerel histogram meydana getirmektedir. Histogramlar daha sonra birleştirilmekte ve karar vermek için bölünme sütunu seçilmektedir. Daha sonra satırlar düğümlere yeniden atanmakta ve tüm işlem tekrarlanmaktadır. Tüm bölmeler değerlendirildikten sonra en iyi bölünme noktası seçilmektedir (H2O, 2020b).

3.3.3. Ekstrem Gradyan Artırımlı Ağaçlar

GBM algoritmasının literatürde mevcut gözetimli algoritmaların performansından daha iyi sonuçlar üretebildiğinin gözlemlenmesi ile ölçeklenebilir, taşınabilir ve tahmin doğruluğu yüksek bir algoritma elde etmek amacı ile; Friedman tarafından sunulan orjinal GBM modeli geliştirilerek, Ekstrem Gradyan Artırımlı Ağaçlar (Extreme Gradient Boosting Trees, XGBoost) algoritması elde edilmiştir.

XGBoost algoritmasının başarısının ardında yatan en önemli faktör, tüm senaryolarda ölçeklenebilirliğidir. XGBoost, tek bir makinede mevcut popüler çözümlerden 10 kat daha hızlı çalışmakta ve dağıtık veya limitli hafızanın olduğu durumlarda milyarlarca veriye ölçeklendirilebilmektedir. XGBoost'un ölçeklenebilirliği, geliştirilen birkaç önemli sistemden ve algoritmik optimizasyondan kaynaklanmaktadır. Bu geliştirmeler, seyrek verileri işlemek için yeni bir ağaç öğrenme algoritması ve teorik olarak doğrulanmış, yaklaşık ağaç öğrenmesinde örnek ağırlıklarının kullanılmasını sağlayan, ağırlıklı dağılım çizim prosedürüdür. Paralel ve dağıtık bilgi işlemi, öğrenmeyi daha hızlı hale getirmekte ve model araştırmasını hızlandırmaktadır. En önemlisi de XGBoost, çekirdek dışı hesaplamadan yararlanarak, veri bilimcilerin masaüstünde yüz milyonlarca veriyi işlemelerine olanak tanımaktadır (Chen ve Guestrin, 2016).

Bir XGBoost modelinin parametrelerini ayarlamak karmaşık ve maliyetli bir süreçtir. XGBoost paketindeki ızgara genişletme seçeneği, herbir parametre için değer vektörlerini seçerek bir

kombinasyon ızgarası oluşturmaya imkan tanımaktadır. Sonrasında kombinasyonların her biri üzerinde model oluşturularak, en iyi sonucu veren parametre değerleri elde edilmektedir.

3.4. ÇALIŞMADA KULLANILAN OPTİMİZASYON ALGORİTMALARI

Bu tez çalışmasının optimizasyon modülünde kullanılacak tahmin algoritmaları aşağıda kısaca açıklanmaktadır.

3.4.1. Parçacık Sürü Optimizasyonu


Parçacık sürü optimizasyonu (Particle Swarm Optimization, PSO) algoritması, 1995 yılında Kennedy ve Eberhart tarafından doğadaki balık ve kuş sürülerinin davranışı baz alınarak geliştirilmiştir. Parçacık sürü optimizasyonu, gerçek sayı rassallığını ve parçacıklar arası global iletişimi kullanmaktadır. Bu algoritmada yörüngeler, yarı stokastik bir şekilde parçalı yollar oluşturduğundan; algoritma, parçacık adı verilen bireysel ajanların yörüngelerini ayarlayarak bir nesnel işlevin alanını araştırmaktadır (Yang, 2010).

Sürüdeki her bir parçacığın hareketi, stokastik bir bileşen ve deterministik bir bileşen olmak üzere iki ana bileşenden oluşmaktadır. Her parçacık, mevcut global en iyi konumuna (g^*) ve geçmişteki kendi en iyi konumuna (x^*) doğru yönelirken, aynı zamanda rassal hareket etme eğilimindedir.

Parçacık sürü optimizasyonu algoritması, hızı ve konumu olan bir grup rassal parçacık ile başlatılmakta ve sonraki iterasyonlarda bu hız ve konum değerleri güncellenerek global optimum değer aranmaktadır. Sürüdeki her bir parçacık, global optimum değeri bulma amacı ile çözüm uzayında hareket etmektedir. Parçacıkların hareket yönünü ve hızını; atalet değeri, bireysel en iyi değer ve sürünün en iyi değeri bileşenleri belirlemektedir.

Aramanın kapsamını daha iyi kontrol etmek için, atalet ağırlığı değeri bir önceki iterasyondaki hız değeri ile çarpılmaktadır. Bu parametre, arama uzayının keşfini kontrol etmektedir; yüksek bir atalet değeri, global optimum değerine hızlı bir şekilde yakınsamak için parçacıkların büyük hızlarda hareket etmesine izin vermekte; öte yandan düşük bir atalet değeri, parçacık arama bölgesini daraltabilmektedir (Kennedy ve Eberhart, 1995).

Şekil 3.5’de parçacık sürü optimizasyonu algoritmasının akış şemasına yer verilmiştir.



Şekil 3.5 : Parçacık sürü optimizasyonu algoritması akış şeması (Kennedy ve Eberhart, 1995).

Her bir iterasyonda bir parçacığın hızı denklem 3.1 ile güncellenerek bir sonraki iterasyondaki hızı (v_i^{t+1}) hesaplanmaktadır.

$$v_i^{t+1} = w \cdot v_i^t + c_1 * rand[0,1] * (g^* - x_i^t) + c_2 * rand[0,1] * (x_i^* - x_i^t) \quad (3.1)$$

Burada;

v_i^t : i parçacığının t anındaki hızını,

x_i^t : i parçacığının t anındaki konumunu,

v_i^{t+1} : i parçacığının $t+1$ anındaki hızını,

x_i^{t+1} : i parçacığının $t+1$ anındaki konumunu,

$rand[0,1]$: 0-1 aralığındaki rassal sayıları.

x_i^* : Her bir parçacığın bireysel en iyi çözüm değerini,

g^* : Her bir parçacığın global en iyi çözüm değerini,

w : Atalet ağırlığı değerini ifade etmektedir.

c_1 : Bireysel en iyi konum için öğrenme katsayısıdır; 0-4 arasında değer alır (Genel olarak 2 seçilir)

c_2 : Global en iyi konum için öğrenme katsayısıdır; 0-4 arasında değer alır (Genel olarak 2 seçilir)

Her bir iterasyonda bir parçacığın konumu denklem 3.2 ile güncellenerek bir sonraki iterasyondaki konumu (x_i^{t+1}) hesaplanmaktadır:

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (3.2)$$

Bireysel en iyi değer, parçacığın mevcut iterasyona kadar elde ettiği en iyi uygunluk değeridir. Global en iyi değer ise, sürüdeki herhangi bir parçacık tarafından mevcut iterasyona kadar elde edilen en iyi uygunluk değeridir. Algoritmanın çalışmayı durdurması durumunda global en iyi değer, optimum değer olacaktır.

Şekil 3.6’de parçacık sürü optimizasyonu algoritmasının sözde koduna yer verilmiştir.

Amaç fonksiyonu $f(x)$, $x = (x_1, \dots, x_p)^T$

n parçacığın x_i başlangıç konumunu ve v_i başlangıç hızını belirle

$\min\{f(x_1), \dots, f(x_n)\}$ ($t=0$ için) g^* değerini bul

while (kriter)

$t = t + 1$ (iterasyon sayacını 1 artır)

for n parçacığın p boyut

$v_i^{t+1} = w \cdot v_i^* + c_1 * rand[0,1] * (g^* - x_i^t) + c_2 * rand[0,1] * (x_i^* - x_i^t)$

eşitliğini kullanarak

v_i^{t+1} hızını hesapla

$x_i^{t+1} = x_i^t + v_i^{t+1}$ eşitliğini kullanarak x_i^{t+1} konumunu hesapla

x_i^{t+1} yeni konum değerindeki amaç fonksiyonu değerini hesapla

Her bir parçacık için en iyi x_i^* konum değerini hesapla

end for

Global en iyi değeri g^* bul

end while

x_i^* ve g^* çıktı değerleridir

Şekil 3.6 : Parçacık sürü optimizasyonu algoritması sözde kodu (Yang, 2010; Büyüksaatçı, 2015).

3.4.2. Tavlama Benzetimi Algoritması

Tavlama Benzetimi algoritması (Simulated Annealing Algorithm), metalurjideki tavlama ilhamı olarak geliştirilen bir algoritmadır. Metalurjideki tavlama tekniği, kristallerin boyutunu artırma ve kusurları azaltmak için bir malzemenin ısıtılmasını ve kontrollü soğutulmasını içermektedir. Erimiş bir metalin tavlama, termodinamik enerji açısından global minimum olarak kabul edilen kristal haline gelmesine neden olmaktadır. Algoritma, amaç fonksiyonunun global bir minimumunu bulmak için tavlama sürecini simüle etmek amacıyla geliştirilmiştir. Tavlama benzetimi tekniğini kullanarak, termal gürültüyü simüle etmek için modele bir veya daha fazla yapay sıcaklık eklenmekte ve kademeli soğuma gerçekleştirilmektedir (Kirkpatrick ve diğ., 1983; Xiang ve diğ., 2013).


Şekil 3.7’te tavlama benzetimi algoritmasının akış şeması sunulmuştur.

Tavlama benzetimi algoritması istatistiksel doğası nedeniyle yerel minimuma takılma ihtimali gradyan yöntemlere göre daha düşüktür. Gradyan temelli yöntemlerin ve yerel minimuma takılma dezavantajına sahip diğer deterministik arama yöntemlerinin aksine tavlama benzetimi algoritmasının ana avantajı, yerel minimumda takılmayı önleme yeteneğidir. Çok yavaş soğutma ile birlikte yeterli rassallık kullanılırsa, tavlama benzetimi algoritmasının global optimuma yaklaşacağı kanıtlanmıştır. Tavlama benzetimi algoritması, geçiş olasılığı ile ilgili uygun koşullar altında yakınsayan bir Markov zinciri kullanan bir arama yöntemidir.

Şekil 3.8’de tavlama benzetimi algoritmasının sözde koduna yer verilmiştir.

Szu ve Hartley tarafından 1987 yılında hızlı tavlama benzetimi algoritması geliştirilmiştir (Szu and Hartley, 1987). Klasik tavlama benzetimi algoritması ve hızlı tavlama benzetimi algoritması; Tsallis istatistiklerine göre, geliştirilmiş tavlama benzetimi adı verilen birleşik bir resim ile geliştirilebilmektedir (Tsallis and Stariolo, 1996).

Bu tez çalışmasında, klasik tavlama algoritmasından daha iyi performans gösteren ve Boltzmann-Gibbs istatistiğinin bir genellemesinden ilham alınarak geliştirilmiş tavlama benzetimi (GenSA) algoritması kullanılmıştır. Tsallis ve Stariolo tarafından geliştirilen bu algoritma, bozuk bir Cauchy-Lorentz ziyaret dağıtımı kullanarak algoritmanın daha hızlı yakınsamasına ve geliştirilmesine olanak tanımaktadır.



Şekil 3.7 : Tavlama benzetimi algoritması akış şeması (Lin ve Yeh ,2006).

Bir başlangıç çözümünü seç : $s_0 \in S$ ve amaç fonksiyonu $f(s_0)$ hesapla;

Bir başlangıç sıcaklığı belirle : $T > 0$;

Sıcaklık değişim sayacını sıfırla $t \leftarrow 0$;

s_{iyi} problem için bulunan metasezgisel çözüm

$s \leftarrow s_0 ; f(s) \leftarrow f(s_0)$;

$s_{iyi} \leftarrow s_0 ; f(s_{iyi}) \leftarrow f(s_0)$;

Tekrarla

$n \leftarrow 0$;

Tekrarla

s' 'in bir komşusu olan s' çözümünü ($s' \in N(s)$) rassal olarak üret;

$\Delta \leftarrow f(s') - f(s)$;

$\Delta \leq 0$ ise $s \leftarrow s'$;

değilse (0,1) aralığında düzgün dağılımdan bir rassal sayı üret (u) ve

$u < \exp(-\Delta/T)$ ise $s \leftarrow s'$;

$f(s') \leftarrow f(s_{iyi})$ ise $s_{iyi} \leftarrow s'$;

$n \leftarrow n + 1$;

$n > M$ koşulu sağlanana kadar devam et

$t \leftarrow t + 1$;

$T = T(t)$;

Durdurma koşulu sağlanana kadar devam et

Şekil 3.8 : Tavlama benzetimi algoritması sözde kodu (Kirkpatrick ve diğ., 1983).


Bu çalışmada kullanılan Genelleştirilmiş Tavlama Benzetimi R paketi, çok sayıda yerel minimum (Xiang ve diğ., 2013) ile karmaşık doğrusal olmayan amaç fonksiyonlarını başarıyla işleyerek uygun bir yakınsama göstermiştir. Genelleştirilmiş Tavlama Benzetimi algoritması ile çok sayıda yerel minimum ile karmaşık olmayan hedef fonksiyonları işlenebilmektedir. Geliştirilen R paketinin çekirdek işlevi, paketin olabildiğince verimli çalışmasını sağlamak amacı ile C++ ile yazılmıştır.

4. BULGULAR

Tez çalışmasının bu bölümünde, Perakende Firmasının ihtiyaçlarına göre hazırlanmış olan Dinamik Fiyatlandırma Karar Destek Sisteminin temel parçaları açıklanacaktır. Ardından, çalışmada kullanılan veri setinin talep tahmin algoritmaları ve optimizasyon algoritmaları ile elde edilen sonuçları paylaşılacaktır.

Şekil 4.1’de, tez çalışması kapsamında önerilen karar destek sistemi modelinin akış şeması yer almaktadır. Şemada da ifade edildiği gibi; perakende firmasından elde edilen ham veri, öncelikle veri ön işleme sürecine tabi tutulmuştur. Veri ön işleme süreci sonrası elde edilen yeni veri, veri kazıma süreçleri sonrası elde edilen rakip firma verileri ile birleştirilerek talep tahmin modülünde kullanılmıştır. Talep tahmin modülünün ardından, optimizasyon modülü çalıştırılmıştır. Bu aşamada, talep tahmin modülünün sonucu optimizasyon modülünde girdi olarak kullanılarak, incelenen ürünlerin optimum fiyat değerlerinin elde edilmesi amaçlanmıştır.

Tüm bu işlemler, sistem konfigrasyonu Intel Core i5-8250U @ 3.4 GHz, RAM - 6 GB, 64 bit 4 çekirdekli Windows10 laptopta gerçekleştirilmiştir.




Şekil 4.1 : Dinamik fiyatlandırma karar destek sistemi şeması.


4.1. VERİ ÖN İŞLEME SÜRECİ

Bu bölümde, Perakende Firmasının Kurumsal Kaynak Planlama veritabanından çekilen ham veriler üzerinde gerçekleştirilen veri ön işleme sürecine yer verilmiştir. Önerilen modelin genellenebilirliğini iyileştirmek ve kurulan tahmin modülünün performansını artırmak amacı ile, veri temizleme ve veri mühendisliği adımları bu aşamada gerçekleştirilmiştir.

Şekil 4.2’de perakende firmasının 01.01.2018 ve 31.12.2019 tarihleri arasındaki 2 yıllık günlük satış verilerinin zaman serisi grafiği sunulmuştur. Şekil 4.3’te ise toplam satış değerlerinin histogram grafiği çizilmiştir.




Şekil 4.2 : Toplam satış değerlerinin zaman serisi grafiği.



Şekil 4.3 : Toplam satış değerlerinin histogram grafiği.

Şekil 4.3'ten görüleceği üzere, satış miktarlarının dağılımı normal dağılıma uymamaktadır ve oldukça sağa (pozitif) çarpık bir eğilim göstermektedir. Bu nedenle, talep tahmini modelleri ile çalışılmadan önce, satış değerlerine logaritmik dönüşüm yapılmıştır. Logaritmik dönüşüm sonucunda elde edilen toplam satış değerlerinin histogram grafiği Şekil 4.4'teki gibidir. Böylece; logaritmik dönüşüm sonucunda toplam satış değerlerinin çarpıklığı azaltılarak, veri seti talep tahmin modelleri için hazır hale getirilmiştir.



Şekil 4.4 : Logaritmik dönüşüm sonucu toplam satış değerlerinin histogram grafiği.

Logaritmik dönüşüm sonucunda elde edilen toplam satış değerleri ile tahmin modelleri kurulduktan sonra, toplam satış değerleri orijinal ölçeğine çevrilerek optimizasyon modülünde kullanılmıştır.

4.1.1. Veri Temizleme İşlemleri

Perakende Firmasının Kurumsal Kaynak Planlama veritabanından yalnızca, talep tahmin modülü ve optimizasyon modülü çalışmalarında kullanılacak değişkenler çekilmiştir.


Satış değerinin 0 olduğu gözlemler tahmin modeline katkı sağlamayacağı için veri setinden çıkarılmıştır. Veri setinin “NA”, “N/A”, “Null” gibi eksik veri içerip içermediği sorgulanmış ve eksik veri içermediği sonucuna ulaşılmıştır.

Model performansını olumsuz etkileyen aykırı değerler veri setinden çıkarılmıştır. Tahmin modülünün çıktısı olan Toplam Satış değişkeninin aykırı değerlerinin tespiti için kutu grafiğinden yararlanılmıştır.

Şekil 4.5’te toplam satış değişkeninin kutu grafiği, Tablo 4.1’de ise toplam satış değişkeninin özeti yer almaktadır. Tablo 4.1’deki veriler ve Şekil 4.6’daki kutu grafiğinin çıktısı dikkate alındığında; veri setindeki Toplam Satış değişkeni gözlem değerlerinin 1 ile 3 aralığında yoğunlaştığı gözlemlenmektedir.

Tablo 4.1 : Toplam satış değişkeni özeti.

<i>Minimum</i>	<i>1.çeyrek</i>	<i>Ortanca</i>	<i>Ortalama</i>	<i>3.çeyrek</i>	<i>Maksimum</i>
1	1	1	3.66	3	1924

**Şekil 4.5 :** Toplam satış değişkeni kutu grafiği.

Tek değişkenli yaklaşımı (Univariate approach), aykırı değerlerin çeyrekler arası aralık (interkartil) değerinin 1.5 katının dışındaki değerler olduğunu ileri sürmektedir. Bu yaklaşım dikkate alınarak veri setindeki Toplam Satış değişkeni değeri 3’ün üstünde olan gözlemler veri setinden çıkarılmıştır.

4.1.2. Özellik Mühendisliği

Bölüm 3.2’de detayları sunulan ve perakende firmasının Kurumsal Kaynak Planlaması sisteminden çekilen ham veri seti, talep tahmini modülünde kullanılmak ve algoritmaların öğrenme gücünü artırmak amacı ile bazı işlemlere tabi tutulmuştur.

Zaman serisi formatındaki tarih değişkeni, ağaç tabanlı makine öğrenmesi algoritmaları için anlamsızdır. “Ay”, “Gün” ve “Yıl-Ay-Gün” formatındaki değişkenlerin satış değişkeni üzerinde anlamlı etki yaratacağı düşünüldüğünden, “Tarih” değişkeninden ayrıştırılmıştır.

Ramazan Bayramı, Kurban Bayramı, Yılbaşı, Sevgililer Günü gibi özel günlerin talep üzerindeki etkisini modelleyebilmek adına özel gün veri seti oluşturularak ilgili veri setine eklenmiştir.

Gelecekteki müşteri sayısını tahmin etmekteki güçlükler nedeni ile “Müşteri Sayısı” değişkeni modele girdi değişkeni olarak eklenmemiştir. Bunun yerine; 01.01.2018 - 31.12.2019 tarihleri arası her bir mağazaya gelen ortalama müşteri sayısı müşteri değişkeninden türetilerek “Müşteri Trafiği” olarak modele girdi değişkeni olarak eklenmiştir.

Kategori Kodu ve Alt Kategori Kodu değişkenlerinin tahmin modülünde yer alabilmesi için, formatları faktör formatından tam sayı formatına dönüştürülmüştür.

Özellikle XGBoost algoritması için talep tahmininde kullanılacak olan ve veri formatı faktör olan değişkenlerin veri formatı tam sayıya çevrilmiştir.

Mevcut veri setine ek olarak, rakip perakendecilerin fiyatlarının ilgili perakende firmasının satışlarını etkileyeceği varsayıldığından; incelenen perakendecinin rakibi olan 2 perakende firmasının ilgili kategorilerdeki ürünlere ait fiyat bilgilerini web kazıma yöntemi ile elde edilerek, önerilen modelin talep tahmin modülünde kullanılmak üzere veri setine eklenmiştir.

Bölüm 4.2’de rakip fiyat verilerinin veri kazıma ile elde edilmesi sürecine yer verilmiştir.

4.2. VERİ KAZIMA SÜRECİ

Bu tez çalışmasında incelenen vakada, rakibi ve talebi baz alan hibrit bir dinamik fiyatlandırma stratejisi kullanılmıştır. Oluşturulan modelin talep tahmin modülüne rakip perakende firmalarının fiyat bilgileri de katılarak, rekabetin etkisi fiyatlandırma stratejisine dahil edilmiştir.


“Rakip1” ve “Rakip2” olarak adlandırılan perakende firmalarının çalışmada incelenen ürünlere ait web sitelerindeki fiyat bilgileri, veri kazıma yöntemi ile çekilmiştir. Veri kazıma aracı olarak robotik süreç otomasyonu yazılımı olan UiPath kullanılmıştır. Veri kazıma ile rakip fiyatlarının çekilme süreci, 01.01.2018 ve 31.12.2019 tarihleri arası günlük gerçekleştirilmiş ve çekilen veriler Excel dosyasına aktarılmıştır.

Bu tez çalışması kapsamında gerçekleştirilen veri kazıma işlemi aşağıdaki süreç adımları ile gerçekleştirilmiştir:

1. Sürece, ürün bilgilerinin tutulduğu Excel dosyasının okunması ile başlanır.
2. Web kazımanın yapılacağı tarayıcı olan Google Chrome açılır.


3. Web kazıma ile fiyat verileri elde edilecek tüm ürünlerin kategori bilgileri ilgili dosyadan okunur ve her bir kategori için ilgili sitedeki fiyat verileri web kazıma aracı ile çekilir.
4. Süreç, tüm kategorilerin rakip fiyat verilerinin çekilmesi işlemi tamamlanana kadar devam eder.
5. İlgili güne ve ürüne ait Rakip1 ve Rakip2 perakende firmalarının fiyat bilgileri, talep tahmini için kullanılan veri setine eklenir.

Veri kazıma ile rakip fiyatlarının çekilme sürecinin mimari üst seviye tasarım şeması Şekil 4.6'da verilmiştir.



Şekil 4.6: Veri kazıma ile rakip fiyatlarının çekilme süreci mimari üst seviye tasarım şeması.

Şekil 4.7'de ise, bir kategorideki tüm ürünlerin fiyat verilerinin web kazıma süreci ile çekilmesi işlemi gösterilmektedir.



Şekil 4.7 : Veri kazıma işlemi ile fiyat verilerinin çekilmesi süreci.

Veri ön işleme ve veri kazıma sonrası; bu vakadaki talebin davranışını modellemek, talebi etkileyen önemli öznitelikleri belirlemek ve talep tahmini ve fiyat optimizasyonunu gerçekleştirebilmek için gerekli olan veri seti elde edilmiştir.

Tablo 4.2’de, veri ön işleme ve veri kazıma işlemleri sonrası elde edilen veri setinin yapısına yer verilmiştir.

Tablo 4.2 : Veri ön işleme ve veri kazıma işlemleri sonrası elde edilen veri setinin yapısı.

<i>Değişken adı</i>	<i>Veri formatı</i>	<i>Değer aralığı</i>
Yıl-Ay-Gün	Pozitif sayı	{20180101,...,20191231 }
Gün	Pozitif sayı	{1,...,31}
Ay	Pozitif sayı	{1,...,12}
Ürün Kodu	Tam Sayı (integer)	{1,...,53}
Mağaza Kodu	Tam Sayı (integer)	{1,...,7}
Satış Kanalı	Tam Sayı (integer)	{1,2,3}
Kategori Kodu	Tam Sayı (integer)	{1,...,4}
Alt Kategori Kodu	Tam Sayı (integer)	{1,...,11}
Toplam Satış	Tam Sayı (integer)	{1,2,3}
Eldeki Stok	Tam Sayı (integer)	{-19370,...,39029}
Müşteri Trafiği	Tam Sayı (integer)	{1,...,46}
Fiyat	Pozitif sayı	(0,152.52]
Ürün Maliyet	Tam Sayı (integer)	(0, 32.73]
Rakip1 Fiyat	Pozitif sayı	(0,183.99]
Rakip2 Fiyat	Pozitif sayı	(0,195.95]
Promosyon	Tam Sayı(integer)	{0,1}
Özel Gün	Tam Sayı(integer)	{0,1}

Bölüm 3.2’deki ham veri setinin tanıtımına ek olarak, veri ön işleme ve veri kazıma işlemleri sonucunda elde edilen yeni değişkenlerin tanımı aşağıdaki gibidir:

Yıl-Ay-Gün: YılAyGun tam sayı formatındaki tarih değerini ifade etmektedir.

Gün: Orjinal veri setindeki tarih değişkeninden ayrıştırılan gün değerlerini ifade eden değişkendir.

Ay: Orjinal veri setindeki tarih değişkeninden ayrıştırılan ay değerlerini ifade eden değişkendir.

Müşteri Trafiği: 01.01.2018 - 31.12.2019 tarihleri arası, her bir mağazaya gelen ortalama müşteri sayısını ifade etmektedir.

Özel Gün: Veri setindeki günlerin Türkiye’de özel gün olarak kabul edilen bir gün olup olmadığını ifade etmektedir. 0: İlgili gün özel gün değil; 1: İlgili gün özel gün olduğu durumdur.

Rakip1 Fiyat: İlgili birim ürünün Rakip1 perakende firmasındaki satış fiyatını ifade etmektedir.

Rakip2 Fiyat: İlgili birim ürünün Rakip2 perakende firmasındaki satış fiyatını ifade etmektedir.

4.3. TALEP TAHMİNİ MODÜLÜ


Fiyat optimizasyonunun sonuçları üzerinde büyük öneme sahip olan talep tahmini, bu tez çalışmasının üçüncü aşamasıdır. Talep tahmini ile amaçlanan, gelecek dönem talebini olabildiğince doğru tahmin etmektir.

Bu tez çalışmasında, geçmiş satış verileri ile olan doğrusal olmayan karmaşık ilişkiyi yüksek tahmin doğruluğunda inceleyebilmek ve talep tahmini üzerinde hangi özelliklerin etkili olduğunu gözlemleyebilmek amacı ile; bölüm 3.3.’de detaylı açıklaması yapılan ve ağaç tabanlı olan H2O’nun Dağıtık Rassal Orman Algoritmasından (DRF), H2O’nun Gradyan Artırım Makinesinden (GBM) ve Ekstrem Gradyan Artırımlı Ağaçlar (XGBoost) algoritmasından yararlanılmıştır.

Talep tahmini algoritmalarının sonuçlarını iyileştirmek amacı ile veri ön işleme ve veri kazıma süreçlerinde oluşturulan değişkenler modele eklenmiş ve bu değişkenlerin algoritmalara katkısı test edilmiştir. Bu çalışmada H2O DRF algoritması ile oluşturulan en iyi modelin değişkenleri; H2O DRF, H2O GBM ve XGBoost algoritmalarının farklı hiperparametre kombinasyonları ile oluşturulan tahmin modellerinde kullanılmıştır.

Bu çalışmanın tahmin modülündeki iş akışı, Şekil 4.8’de görüldüğü gibi iteratif bir süreçtir. Öncelikle mevcut veri üzerinde, veri ön işleme ve veri kazıma süreçleri gerçekleştirilmiştir. Oluşturulan yeni veri seti ile H2O DRF modelleri kurulmaktadır. Ardından, kurulan modellerin test veri setindeki MAPE hata değerleri ve modellerin hesaplama süreleri karşılaştırılmaktadır. Bu süreçte veri ön işleme ve veri kazıma ile oluşturulan değişkenler, modellere teker teker eklenerek, baz alınan modele göre değişkenlerin modelin performansı üzerindeki etkisi

değerlendirilmektedir. Değerlendirme ölçütlerine göre en başarılı bulunan model ile Ocak 2020'in ilk haftasının talep tahmini gerçekleştirilmektedir.



Şekil 4.8: Tahmin modülü iş akışı grafiği.

4.3.1. H2O Dağıtık Rassal Orman Algoritması ile Talep Tahmin Modeli

Öncelikle veri ön işleme sonrası ağaç tabanlı makine öğrenmesi algoritmaları için uygun hale getirilen veri setinin %80'i eğitim veri seti %20'i test veri seti olarak alınıp, H2O DRF algoritması ile tahmin gerçekleştirilmiştir. DRF algoritması eğitim veri setinden OOB hata oranı hesaplamaktadır; bu sayede diğer ağaç tabanlı topluluk algoritmalarına göre çapraz geçerlilik stratejisine gerek duymamaktadır. OOB hata tahmini, değişken önemi belirlemede de yaygın olarak kullanılmaktadır.

Ardından; oluşturulan DRF modeli baz alınarak; veri mühendisliği ve veri kazıma süreçlerinde oluşturulan değişkenlerin tahmin doğruluğundaki etkisini ölçmek amacı ile değişkenler bu modele teker teker eklenmiştir.

Oluşturulan baz DRF modeli aşağıdaki gibidir:

Toplam Satış ~ Ürün Kodu + Mağaza Kodu + Satış Kanalı + Kategori Kodu + Alt Kategori Kodu + Promosyon + Eldeki Stok +Fiyat

Tablo 4.3'te oluşturulan her bir modelin hata değerleri ve hesaplama süreleri yer almaktadır.

Tablo 4.3 : Yeni eklenen değişkenlere göre kurulan modellerin hata değerleri ve hesaplama süreleri.

<i>Model</i>	<i>Test Veri Seti Performans Ölçütü MAPE Değerleri (%)</i>	<i>Test Veri Seti Performans Ölçütü RMSE Değerleri</i>	<i>Modelin hesaplama süresi</i>
Baz model	%34.23	0.7487	16.32 sn
Baz model + Gün değişkenleri	%35.12	0.7669	23.41 sn
Baz model + Gün değişkenleri + Müşteri Trafiği	%15.58	0.4951	19.12 sn
Baz model + Gün değişkenleri + Müşteri Trafiği + Rakip Fiyatları	%14.27	0.4717	17.73 sn
Baz model + Gün değişkenleri + Müşteri Trafiği + Özel Gün	%15.81	0.4718	14.70 sn
Baz model + Gün değişkenleri + Müşteri Trafiği + Rakip Fiyatları + Özel Gün değişkeni	%17.54	0.5004	18.32 sn


Tablo 4.3'ten görüldüğü gibi; baz alınan modele ek olarak gün değişkenleri, müşteri trafiği ve rakip fiyatları değişkenlerinin eklendiği model en düşük MAPE ve RMSE değerleri ile en iyi performansı göstermiştir. Bundan sonraki aşamada bu değişkenler, farklı hiperparametreler ile oluşturulan H2O DRF, H2O GBM ve XGBoost algoritmalarında kullanılmıştır. Veri ön işleme ile oluşturulan özel gün değişkeni ise bu çalışmada incelenen ürün grubu için anlamsız çıkmıştır. Ancak ürün grubunun farkı olduğu veri setlerinde (Ramazan Bayramı için gıda, şekerleme; Sevgililer Günü için kozmetik, parfümeri gibi) özel gün değişkeninin anlamlı çıkacağı düşünüldüğünden ve önerilen dinamik fiyatlandırma karar destek sistemi modelinin tüm durumlar için genel geçer bir yapıda olması istendiğinden, bu değişken modele katılmıştır.

DRF algoritmasında temel ayar parametreleri ormanın ağaç sayısı, tek tek ağaçların her bir bölünmesi için rassal seçilecek değişkenlerin sayısı ve her bir ağacın derinliğidir. Topluluğu oluşturan ağaçların sayısı, tahminin doğruluğunda doğrudan bir etkiye sahiptir. Ağaç sayısı arttıkça hata da azalmaktadır. Ancak; eğer ağaçların sayısı yeterince büyük ise, ağaç sayısının artırılması tahminlerde belirgin bir iyileşme ile sonuçlanmamaktadır.

Ayrıca, daha fazla ağaç kullanmak, daha büyük bilgi işlem süreleri gerektirmektedir. Bu nedenle; ağaç sayısı, hesaplama zamanı ile tahmini performans arasında bir dengeleme çözümü temel alınarak belirlenmektedir. Gün değişkenleri, müşteri trafiği ve rakip fiyatları

değişkenlerinin eklendiği H2O DRF algoritması ile kurulan talep tahmini modelinde; ağaç sayısı, ağaç derinliği ve rassal değişken sayısı hiperparametrelerinin ayarlanması için paralelde çalışan rassal arama yöntemi kullanılmıştır.

Şekil 4.9’de ağaç sayısına bağlı olarak hesaplanan OOB hata oranı değerleri yer almaktadır. Şekilden görüleceği üzere; topluluktaki ağaç sayısının artışı ile birlikte eğitim veri setinden hesaplanan OOB hata oranı azalmaktadır ve ağaç sayısı 100’e ulaştıktan sonra bu değer sabitlenmektedir.



Şekil 4.9 : Ağaç sayısının artışına bağlı olarak torba dışı (OOB) hata oranı azalması.

Tablo 4.4’de ise rassal arama ile kurulan H2O DRF modellerinin seçilen parametre değerlerine bağlı olarak test veri setindeki MAPE ve RMSE hata değerlerine ve modellerin hesaplanma süresine yer verilmiştir.

Tablo 4.4’deki kurulan modellerin parametre ve hata değerleri incelendiğinde; ağaç derinliğinin artırılmasının model performansı üzerinde en çok etkiyi yarattığı gözlemlenmiş, modelin aşırı uyum sağlamasını engellemek için test verisinin hata oranıyla bu parametre kontrol edilmiştir. Her bir ağacın bölünmesinde kullanılan rassal değişken sayısı girdi değişkenleri arasındaki korelasyon ilişkisi dikkate alınarak seçilmiştir.

Tablo 4.4 : Kurulan modellerin parametre ve hata değerleri.

<i>Model No:</i>	<i>Ağaç Sayısı</i>	<i>Ağaç Derinliği</i>	<i>Rassal Değişken Sayısı</i>	<i>Test Veri Seti Performans Ölçütü MAPE Değerleri (%)</i>	<i>Test Veri Seti Performans Ölçütü RMSE Değerleri</i>	<i>Modelin hesaplama süresi</i>
DRF1	35	35	4	%14,52	0.4797	8.62 sn
DRF2	50	35	4	%14,50	0.4783	11.97 sn
DRF3	50	25	4	%14,37	0.4760	8.53 sn
DRF4	100	25	4	%14,27	0.4717	17.73 sn
DRF5	150	25	4	%14,30	0.4718	25.93 sn
DRF6	100	25	6	%14,53	0.4792	18.81 sn
DRF7	100	30	4	%14,34	0.4723	19.85 sn
DRF8	150	25	6	%14,54	0.4788	27.35 sn
DRF9	100	30	6	%14,67	0.4827	22.88 sn
DRF10	150	30	6	%14,70	0.4829	31.52 sn

Topluluktaki ağaç sayısının 100, ağaç derinliğinin 25, rassal değişken sayısının 4 olduğu durumda en düşük hata değeri gözlemlenmiştir. Buna göre en iyi DRF modelinin özeti Tablo 4.5’de gösterilmektedir.


Tablo 4.5 : En iyi dağıtık rassal orman algoritması modelinin özeti.

Ağaç sayısı	100
Maximum ağaç derinliği	25
Rassal değişken sayısı	4
R^2 değeri	%75
Test Veri Seti Performans Ölçütü (MAPE[%]) Hata Değerleri	%14,27
Test Veri Seti Performans Ölçütü (RMSE) Hata Değerleri	0.4717
Modelin hesaplama süresi	17.73 sn

Tablo 4.5’ten görüldüğü gibi; en iyi performansı gösteren DRF modelinin R^2 değeri %75 çıkmıştır. Bu durum; satış değişkenindeki varyasyonun %75’inin kurulan model ile açıklanabildiğini göstermektedir. Yapılan tahminde Ortalama Mutlak Yüzde Hata (MAPE) değeri %14,27 ve Kök Ortalama Kare Hata (RMSE) değeri 0.4717 olarak bulunmuştur. Modelin hesaplama süresi ise 17.73 saniyedir.

H2O DRF modelinin değişken önemi seçme işlemi; değişkenin, ağaç oluşturma sürecinde bölünme sırasında seçilip seçilmediği ve sonuç olarak değişkenin yer aldığı tüm ağaçlar için ortalama karekök hatayı ne kadar düşürdüğü gibi göreceli etki faktörleri hesaplanarak belirlenmektedir.

Şekil 4.10’te, modelde yer alan değişkenlerin dağıtık rassal orman algoritması ile elde edilen önem dereceleri yer almaktadır. Buna göre; sonradan eklenen Müşteri Trafiği, Gün ve Rakip Fiyatları değişkenleri ile fiyat değişkeninin tahmin performansı üzerinde diğer değişkenlere kıyasla yüksek etkiye sahip olduğu sonucu çıkarılmaktadır. Dolayısıyla, veri ön işleme çalışmasının da anlamlı ve tutarlı olduğu sonucuna ulaşılmaktadır.



Şekil 4.10 : Dağıtık rassal orman algoritması ile elde edilen önem dereceleri sıralaması.


4.3.2. H2O Gradyan Artırım Makinesi ile Talep Tahmin Modeli

Veri ön işleme sonrası ağaç tabanlı makine öğrenmesi algoritmaları için uygun hale getirilen ve rakip fiyatlarının eklendiği veri setinin %80’i eğitim veri seti, %20’i si test veri seti olarak alınıp, bir diğer tahminleme algoritması olan H2O GBM algoritması ile tahmin gerçekleştirilmiştir. Modelin genellenebilirliğini ölçebilmek adına 10-katlamalı çapraz doğrulama yönteminden yararlanılmıştır.

Kurulan H2O GBM modellerinde; “Müşteri Trafiği”, “Gün”, “Fiyat”, “Rakip1 Fiyat”, “Rakip2 Fiyat”, “Yıl-Ay-Gün”, “Ay”, “Eldeki Stok”, “Satış Kanalı”, “Mağaza Kodu”, “Promosyon”, “Ürün Kodu” ve “Alt Kategori Kodu” değişkenleri kullanılmıştır.

H2O GBM algoritması ile kurulan talep tahmini modelinde; ağaç sayısı, maksimum ağaç derinliği, sütun örnekleme ve örneklem oranı hiperparametrelerinin ayarlanması için paralelde

alışan rassal arama yöntemi kullanılmıştır. Şekil 4.11’de kurulan GBM modellerinde ağaç sayısı hiperparametresinin artışına baėlı olarak test veri setinin hata oranının azalmasını gösteren grafiėe yer verilmiştir. Eėitim ve test veri setlerinin hata oranı, ağaç sayısı 200’e ulaştıktan sonra sabitlenmektedir.



Şekil 4.11 : Ağaç sayısının artışına baėlı olarak eėitim ve test veri setinin hata oranının azalması.

Tablo 4.6’da rassal arama ile kurulan H2O GBM modellerinin seçilen parametre deėerlerine baėlı olarak test veri setindeki MAPE ve RMSE hata deėerlerine ve modellerin hesaplanma süresine yer verilmiştir. Buna göre; topluluktaki ağaç sayısının 200, maksimum ağaç derinliğinin 10, öğrenme oranının 0.06 olduėu durumda en düşük hata deėerleri gözlemlenmiştir.

Tablo 4.6 : Kurulan modellerin parametre ve hata değerleri

<i>Model No:</i>	<i>Ağaç Sayısı</i>	<i>Ağaç Derinliği</i>	<i>Rassal Değişken Sayısı</i>	<i>Test Veri Seti Performans Ölçütü MAPE Değerleri (%)</i>	<i>Test Veri Seti Performans Ölçütü RMSE Değerleri</i>	<i>Modelin hesaplama süresi</i>
GBM1	35	10	0.06	%15,64	0.5176	22.68 sn
GBM2	50	10	0.06	%15,57	0.5051	35.08 sn
GBM3	100	10	0.06	%15,40	0.5041	79 sn
GBM4	150	10	0.06	%15,39	0.4999	99 sn
GBM5	200	10	0.06	%15,38	0.4819	90 sn
GBM6	150	8	0.08	%15.72	0.5457	66 sn
GBM7	150	8	0.10	%15.91	0.5848	53.28 sn
GBM8	150	6	0.08	%16.26	0.6452	69 sn
GBM9	150	6	0.10	%15.92	0.5853	56.41 sn
GBM10	150	8	0.09	%15.76	0.5578	56.51 sn


Tablo 4.7’de kurulan en iyi modelin özetine yer verilmiştir. Tablo 4.7’den görüldüğü gibi; en iyi performansı gösteren H20 GBM modelinin R^2 değeri %67 çıkmıştır. Bu; satış değişkenindeki varyasyonun %67’in kurulan model ile açıklanabildiğini göstermektedir. Yapılan tahminde Ortalama Mutlak Yüzde Hata (MAPE) değeri %15.38 ve Kök Ortalama Kare Hata (RMSE) değeri ise 0.4819 bulunmuştur. Modelin hesaplama süresi 90 saniyedir.

Tablo 4.7 : En iyi gradyan artırım makinesi modelinin özeti.

Ağaç sayısı	150
Maximum ağaç derinliği	10
Öğrenme Oranı	0.06
R^2 değeri	% 67
Test Veri Seti Performans Ölçütü (MAPE[%]) Hata Değerleri	% 15,38
Test Veri Seti Performans Ölçütü (RMSE) Hata Değerleri	0.4819
Modelin hesaplama süresi	90 sn

Şekil 4.12’de, modelde yer alan değişkenlerin gradyan artırım makinesi algoritması ile elde edilen önem dereceleri yer almaktadır. Şekildeki grafikten görüldüğü gibi; “Müşteri” değişkeninden yaratılan “Müşteri trafiği” değişkeni, “Fiyat” değişkeni, “Satış kanalı” değişkeni ve veri kazıma ile elde edilen “Rakip1” ve “Rakip2” fiyatı değişkenlerinin tahmin performansı üzerindeki önem derecesi sıralaması, modelde kullanılan diğer değişkenlere göre yüksek

çıkılmıştır. Buradan, veri ön işleme çalışmasının yine anlamlı ve tutarlı olduğu sonucuna ulaşılmıştır.



Şekil 4.12 : Gradyan artırım makinesi algoritması ile elde edilen önem dereceleri sıralaması.

4.3.3. Ekstrem Gradyan Artırmalı Ağaçlar Algoritması ile Talep Tahmini

Veri ön işleme sonrası ağaç tabanlı makine öğrenmesi algoritmaları için uygun hale getirilen ve rakip fiyatlarının eklendiği veri setinin %80'i eğitim veri seti, %20'si test veri seti olarak alınıp; en son olarak XGBoost algoritması ile tahmin gerçekleştirilmiştir. Modelin genellenebilirliğini ölçebilmek için 10-katlamalı çapraz doğrulama yönteminden yararlanılmıştır.

Kurulan Ekstrem Gradyan Artırmalı Ağaçlar modellerinde; “Müşteri Trafiği”, “Gün”, “Fiyat”, “Rakip1 Fiyat”, “Rakip2 Fiyat”, “Yıl-Ay-Gün”, “Ay”, “Eldeki Stok”, “Satış Kanalı”, “Magaza Kodu”, “Ürün Kodu”, “Alt Kategori Kodu” ve “Promosyon” değişkenleri kullanılmıştır.

XGBoost algoritması ile kurulan talep tahmini modelinde de diğer iki tahmin algoritmasında olduğu gibi; ağaç sayısı, maksimum ağaç derinliği, sütun örnekleme ve örneklem oranı hiperparametrelerinin ayarlanması için paralelde çalışan ızgara arama yöntemi kullanılmıştır.

Tablo 4.8’de rassal arama ile kurulan XGBoost modellerinin seçilen parametre değerlerine bağlı olarak test veri setindeki MAPE ve RMSE hata değerlerine ve modellerin hesaplanma süresine yer verilmiştir. Kurulan modellerin parametre ve hata değerleri tablodan incelendiğinde; ağaç sayısının artırılmasının model performansı üzerinde en çok etkiyi yarattığı

gözlemlenmiş, modelin aşırı uyum sağlamasını engellemek için test verisinin hata oranı ile bu parametre kontrol edilmiştir. Topluluktaki ağaç sayısının artırılmasının modelin hesaplama süresini artırdığı; ancak test veri setindeki MAPE ve RMSE hata değerlerini düşürdüğü sonucuna ulaşılmıştır.

Ayrıca; topluluktaki ağaç sayısının 2200, maksimum ağaç derinliğinin 6, öğrenme oranının 0.1, örneklem oranının 0.1, sütun örnekleminin 0.9 olduğu durumda en düşük hata değerleri gözlemlenmiştir

Tablo 4.6 : Ekstrem gradyan artırımı ağaçlar algoritması ile kurulan modellerin parametre ve hata değerleri.

<i>Model No</i>	<i>Ağaç Sayısı</i>	<i>Maksimum Ağaç Derinliği</i>	<i>Öğrenme Hızı</i>	<i>Örneklem</i>	<i>Sütun örnekleme</i>	<i>Test Veri Seti Performans Ölçütü MAPE Değerleri (%)</i>	<i>Test Veri Seti Performans Ölçütü RMSE Değerleri</i>	<i>Modelin hesaplama süresi</i>
XG1	200	6	0.01	0.7	0.8	%17.81	0.6056	7.06 sn
XG2	200	6	0.1	0.9	0.9	%15.21	0.4942	6.75 sn
XG3	500	6	0.1	0.9	0.9	%14,27	0.4723	19.02 sn
XG4	1000	8	0.1	0.7	0.8	%13,63	0.4552	32.48 sn
XG5	1500	6	0.1	0.9	0.8	%13,57	0.4527	65 sn
XG6	2000	6	0.1	0.8	0.8	%13,65	0.4584	141 sn
XG7	2200	6	0.1	0.7	0.8	%13.46	0.4501	88 sn
XG8	2500	6	0.1	0.7	0.8	%13,77	0.4611	112 sn
XG9	2200	6	0.1	0.9	0.9	%13,28	0.4485	78 sn
XG10	2200	8	0.1	0.9	0.9	%13,63	0.4552	128 sn

Tablo 4.9’da kurulan en iyi modelin özetine yer verilmiştir.Tablodan görüldüğü üzere; en iyi performansı gösteren XGBoost modelinin R^2 değeri %82 çıkmıştır. Modelin hesaplama süresi 78 saniyedir. Test veri seti için hesaplanan RMSE hata değeri 0.4485 bulunmuştur. Yapılan tahminde Ortalama Mutlak Yüzde Hata (MAPE) değeri %10 ile %20’in arasında bir değer olan % 13.28 bulunmuştur. Lewis (1982) ve Var ve Türkay (2014)’e göre model iyi bir model olarak sınıflandırılmaktadır.

Tablo 4.7 : En iyi ekstrem gradyan artırımı ağaçlar algoritması modelinin özeti.

Ağaç sayısı	2200
Maximum ağaç derinliği	6
Öğrenme oranı	0.1
Örnekleme	0.9
Sütun örnekleme	0.9
R^2 değeri	%82
Test Veri Seti Performans Ölçütü (MAPE[%]) Hata Değerleri	%13.28
Test Veri Seti Performans Ölçütü (RMSE) Hata Değerleri	0.4485
Modelin hesaplama süresi	78 sn

4.3.4. Talep Tahmini Sonuçlarının Karşılaştırılması


Tablo 4.10’da H2O DRF, H2O GBM ve XGBoost algoritmaları ile kurulan ve en iyi sonuç alınan modellerin değerlendirme ölçütlerine göre karşılaştırılmasına yer verilmiştir. Karşılaştırma sonuçları dikkate alındığında; değerlendirme ölçütü sonuçlarına göre en iyi performansı gösteren XGBoost modeli ile perakende firmasının ilgili ürünler için Ocak 2020’in ilk haftasının talep tahminini gerçekleştirmek en doğrudur. Hesaplanacak bu tahmin değerleri, önerilen dinamik fiyatlandırma karar destek sisteminde optimizasyon modülünün girdisi olarak kullanılacaktır.

Tablo 4.8 : Kurulan modellerin değerlendirme ölçütlerine göre karşılaştırılması.

<i>Model No</i>	<i>Test Veri Seti Performans Ölçütü MAPE Değerleri (%)</i>	<i>Test Veri Seti Performans Ölçütü RMSE Değerleri</i>	<i>R^2 değeri</i>	<i>Modelin hesaplama süresi</i>
DRF4	%14,27	0.4717	%75	17.73 sn
GBM5	%15,38	0.4819	%67	90 sn
XG9	%13.28	0.4485	%82	78 sn

Kabul edilen XGBoost tahmin modelinde Şekil 4.13’te görüldüğü gibi; Müşteri değişkeninden yaratılan Müşteri trafiği değişkeninin ve “Fiyat”, “Satış kanalı”, “Yıl-Ay-Gün”, “Ürün Kodu”, “Gün” değişkenlerinin tahmin performansı üzerindeki önem dereceleri sıralaması modelde

kullanılan diğer değişkenlere göre yüksek çıkmıştır. Buradan, veri ön işleme çalışmasının anlamlı ve tutarlı olduğu sonucuna bir kez daha ulaşılmıştır.



Şekil 4.13 : Ekstrem gradyan artırımı ağaçlar algoritması ile elde edilen önem dereceleri sıralaması.

4.4. OPTİMİZASYON MODÜLÜ

Bu tez çalışmasında geliştirilen karar destek sistemindeki optimizasyon modülünün amacı, tez çalışmasında incelenen ürünlerden maksimum kâr elde etmek için optimum fiyat değerlerinin elde edilmesidir. Ürünler için düşük fiyat belirlemek ve indirim uygulamak talebi artırabilmektedir; ancak bu durum her zaman maksimum kâr elde edilmesi ile sonuçlanmamaktadır. Öte yandan ürünler için yüksek fiyatlar belirlemek müşteri kaybına neden olabilmektedir.

Perakende firması, farklı değişkenlere göre bir sonraki haftanın en iyi fiyat değerlerini elde etmek için bir araca ihtiyaç duymaktadır. Ocak 2020'in ilk haftasında, bu çalışma kapsamında dikkate alınan ürünlerin fiyatlarını belirlemek için, test verisindeki ürünlerin optimum fiyatları hesaplanarak optimizasyon algoritması ile elde edilecek kâr ortaya konmuştur.

Optimizasyon problemini çözümlmek için, öncelikle maksimize edilecek olan kâr fonksiyonunun tanımlanması gerekmektedir. Çalışmada kullanılan kâr fonksiyonunun genel hali denklem 4.1'de ifade edilmiştir.

$$Kâr = \sum_{i=1}^p Talep_i * (Fiyat_i - Maliyet_i) \quad (4.1)$$

Optimizasyon modelinde girdi olarak kullanılacak 4 parametre ise aşağıdaki gibidir:

Minimize edilecek fonksiyon: Optimizasyon algoritması minimizasyon problemi olarak çalışmaktadır. Ancak incelediğimiz problem kârın maksimizasyonudur. Bu nedenle kâr fonksiyonu negatif değere çevrilmiştir. Denklem 4.2’de kullanılacak olan amaç fonksiyonunun formülü ifade edilmiştir.

$$Min - \sum_{i=1}^p Kar_i \quad (4.2)$$

Başlangıç parametresi: Başlangıç parametresi, algoritmanın iterasyona başlaması için gerekli olan fiyat vektörüdür. Başlangıç parametresi için eğitim veri setindeki ürün portföyünün son gözlem fiyatları kullanılmıştır.

Üst Sınır: Üst sınır, ürün portföyü için mümkün olan maksimum fiyatları içeren bir vektördür. Bu üst sınır vektörü için, eğitim veri setindeki rakip perakende fiyatlarından ilgili ürün için maksimum ürün fiyat değerleri alınmıştır.

Alt Sınır: Alt sınır, ürün portföyü için mümkün olan minimum fiyatları içeren bir vektördür. Bu alt sınır vektörü için, perakende firmasının eğitim veri setindeki minimum fiyat değerleri alınmıştır.

Denklem 4.3 ve 4.4’te, optimizasyon probleminin amaç fonksiyonuna ve kısıtlarına sırasıyla yer verilmiştir.

Amaç Fonksiyonu Minimizasyon:

$$- \sum_{i=1}^{53} \sum_{j=1}^7 ((Talep_{ij}(\overrightarrow{Fiyat}_{ij}) \times (Fiyat_{ij} - Maliyet_i)) \quad (4.3)$$

Kısıtlar:

$$\overrightarrow{Fiyat}_{ij} \geq MinimumFiyat (\overrightarrow{Fiyat}_{ij}),$$

$$\overrightarrow{Fiyat}_{ij} \leq MaksimumFiyat (\overrightarrow{Rakip1Fiyat}_i, \overrightarrow{Rakip2Fiyat}_i), \quad (4.4)$$

$$i = 1, \dots, 53$$

$$j = 1, \dots, 7$$

Burada i ürünleri; j ise mağazaları temsil etmektedir.

Daha önce de belirtildiği üzere; optimizasyon probleminin çözümü için, bu çalışmada parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi metasezgisel algoritmaları kullanılacaktır. Algoritmalar için sırası ile R programlama dilinde yer alan PSO ve GenSA paketlerinden yararlanılmıştır. Optimizasyon işlemlerine başlamadan önce algoritmalara ait bazı parametrelerin belirlenmesi gerekmektedir. Tablo 4.11’de, her iki algoritma için kullanılacak parametre değerlerine yer verilmiştir.

Tablo 4.9 : Parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi algoritmaları için kullanılan parametreler.

	Parçacık Sürü Optimizasyonu (PSO)	Genelleştirilmiş Tavlama Benzetimi (GenSA)
Maksimum iterasyon sayısı	2000	2000
Başlangıç sıcaklığı (T)	-	5230
Popülasyon sayısı	100	-
Bireysel öğrenme parametresi (c_1)	2	-
Sosyal öğrenme parametresi (c_2)	2	-
Atalet ağırlığı (ω)	0.90	-

Parçacık sürü optimizasyonu ve genelleştirilmiş tavlama benzetimi algoritmaları ile optimizasyon başarılı bir şekilde yürütülmüş ve iki algortmadan da farklı çıktılar elde edilmiştir. Tablo 4.12’de her iki algortmadan elde edilen sonuçlar yer almaktadır.

Tablo 4.10: Kurulan optimizasyon modellerinin karşılaştırılması.

Algoritma	Toplam Kâr	% Kâr	Modelin hesaplama süresi
Mevcut fiyat	12728.59 ₺	-	-
PSO ile optimize edilen fiyat	12826.61 ₺	% 0.77	1.29 dk.
GenSA ile optimize edilen fiyat	17071.33 ₺	% 34.12	23.38 sn.

Genelleştirilmiş tavlama benzetimi (GenSA) algoritması incelenen tüm ürünler için mümkün olan en yüksek fiyat kombinasyonunu verirken; parçacık sürü optimizasyonu (PSO) algoritması, çoğu üründe maksimuma yakın sonuç vermek ile birlikte bazı ürünlerde minimum sınırlara yakın bir fiyat kombinasyonu vermiştir. Ayrıca Tablo 4.12’deki sonuçlar incelendiğinde; genelleştirilmiş tavlama benzetimi algoritması ile elde edilen toplam kârın ve

% kâr'ın parçacık sürü optimizasyonu algoritmasından daha yüksek olduğu ve GenSA algoritmanın çok daha kısa sürede optimum değere ulaştığı açıkça görülmektedir.

Sonuç olarak; geliştirilmiş tavlama benzetimi algoritmasının çıktıları ile, incelenen 53 ürün için Ocak 2020'in ilk haftasındaki optimum fiyat verileri doğrultusunda perakende firmasının kârı elde edilmiştir.

Ekler bölümünde; 01.01.2020-06.01.2020 tarih aralığında yapılan talep tahminleri doğrultusunda, her bir ürün için 7 farklı mağazadan elde edilen mevcut fiyat veri aralıkları, PSO algoritması ile elde edilen optimum fiyat verileri ve GenSA algoritması ile elde edilen optimum fiyat verileri yer almaktadır.

|

TARTIŞMA VE SONUÇ

Dijitalleşmenin artışı ve sürekli değişen müşteri talebi, perakendecilerinde içinde bulunduğu birçok sektörün teknolojik geliştirmelere ve değişen tüketici davranışlarına hızla ayak uydurmasını gerektirmektedir. Perakendeciler tarafından kullanılan geleneksel, statik, kural bazlı fiyatlandırma sistemleri; piyasaya yeni bir ürün girdiğinde, bu ürünün ve diğer ürünlerin değişen taleplerinin fiyat üzerindeki etkisinin doğru bir şekilde tahmin edilmesi noktasında eksik kalmaktadır. Bu durum da; kârlılık ve ciro artışı sağlamak ve rekabet avantajı elde etmek için, fiyat optimizasyonunun yapıldığı dinamik fiyatlandırma sistemlerinin ve sonuç olarak veriye dayalı karar destek sistemlerinin kullanılmasını kaçınılmaz kılmaktadır.

Bu bağlamda bu tez çalışmasında; bir gıda perakendesi firmasında gelir optimizasyonunu sağlamak amacı ile vaka çalışması gerçekleştirerek, tüm perakende firmalarının yararlanabileceği bir dinamik fiyatlandırma karar destek sistemi geliştirilmiştir. Geliştirilen karar destek sistemi; veri ön işleme, veri kazıma, talep tahmini modülü ve optimizasyon modülü olmak üzere dört aşamadan oluşmaktadır.

Geliştirilen karar destek sistemini analiz edebilmek için; çalışmanın gerçekleştirildiği gıda perakende firmasının temizlik ürünleri, kağıt, kişisel bakım ve kozmetik ürünleri kategorisinden, ürünün rakip perakende firmalarda da bulunurluğu dikkate alınarak 53 ürün dikkate alınmıştır. Gıda perakendelerinde fiyat değişiminin genellikle günlük yapılması nedeni ile bu 53 ürüne ait, perakende firmasının 01.01.2018 ve 31.12.2019 tarihleri arasındaki 2 yıllık günlük geçmiş satış verileri firmanın kurumsal kaynak planlaması sisteminden çekilmiştir. Ayrıca maliyet verileri ve talebi ve optimizasyon modelini etkileyeceği varsayılan tamamlayıcı diğer veriler de sistemden elde edilmiştir.

Oluşturulan ham veri, veri ön işleme ve veri temizleme işlemlerine tabi tutularak; talep tahmini modülünde kullanılacak hale getirilmiştir. Ayrıca özellik mühendisliği ile değişkenler, tahmin modellerinde kullanılacak formata getirilmiş ve tahmin modellerinin gücünü artırmak için “müşteri trafiği” gibi yeni değişkenler veri setine eklenmiştir. Ek olarak veri setine rakip perakende firmalarının fiyat bilgileri de katılarak, rekabetin etkisi fiyatlandırma stratejisine dahil edilmiştir. “Rakip1” ve “Rakip2” olarak adlandırılan perakende firmalarının bu çalışmada incelenen ürünlere ait web sitelerindeki fiyat bilgileri, veri kazıma yöntemi ile çekilmiştir. Veri kazıma aracı olarak robotik süreç otomasyonu yazılımı olan UiPath

kullanılmıştır. Veri kazıma ile rakip fiyatlarının çekilme süreci 01.01.2018 ve 31.12.2019 tarihleri arası günlük gerçekleştirilmiştir.

Talep tahmini modülünde doğruluğu yüksek talep tahmini gerçekleştirebilmek amacı ile son teknoloji ağaç tabanlı makine öğrenmesi algoritmalarından yararlanılmıştır. Tüm ön işlemlerden geçirilerek elde edilen veri setinde; Dağıtık Rassal Orman (DRF), Gradyan Artırım Makinesi (GBM), Ekstrem Gradyan Artırım Ağaçları (XGBoost) algoritmaları ile talep tahmin modelleri kurularak, kurulan bu modeller birbirleri ile karşılaştırılmıştır. Karşılaştırma sonuçları dikkate alındığında; değerlendirme ölçütü sonuçlarına göre en iyi performansı gösteren XGBoost modeli ile Ocak 2020'in ilk haftasının talep tahmini gerçekleştirilmiştir.

Ağaç tabanlı makine öğrenmesi algoritmalarının bir avantajı olan talebi etkileyen değişkenler arasındaki önem derecelerinin sıralaması da talep tahmini modülünde elde edilmiştir. Çalışmada incelenen veri seti için; müşteri değişkeninden yaratılan müşteri trafiği değişkeninin, fiyat, yıl-ay-gün, satış kanalı, ürün kodu ve gün değişkenlerinin tahmin performansı üzerindeki önem dereceleri sıralaması, modelde kullanılan diğer değişkenlere göre yüksek çıkmıştır. Buradan, veri ön işleme çalışmasının anlamlı ve tutarlı olduğu sonucuna ulaşılmıştır.

Optimizasyon modülünde, Genelleştirilmiş Tavlama Benzetimi (GenSA) ve Parçacık Sürü Optimizasyonu olmak üzere iki farklı stokastik optimizasyon algoritmasından yararlanılarak, kârı maksimize etmek için en iyi tahmin yöntemine dayalı fiyat en iyilemesini baz alan optimizasyon sistemi geliştirilmiştir. Bu algoritmalarından elde edilen kâr değerleri birbiri ile karşılaştırılmıştır. Genelleştirilmiş Tavlama Benzetimi ile kurulan model, maksimum kâr elde etmiş ve Parçacık Sürü Optimizasyonu algoritmasına göre optimum sonuca çok daha kısa sürede ulaşmıştır. Bu algoritmanın çıktıları ile Ocak 2020'in ilk haftasının optimum fiyat verisi elde edilmiştir.

Literatürde sadece García-Calderón Chávez (2017)'in çalışmasında bir bira firması için dinamik fiyatlandırma aracı geliştirilerek, ürün portföyü için fiyatın bir fonksiyonu olarak talep öğrenme algoritması ile kârı maksimize etmek amacıyla ürünler için en uygun fiyatlar belirlenmiştir. Bu tez çalışmasında ise daha kapsamlı bir karar destek sistemi önerilerek, UiPath ile veri kazıma işlemi gerçekleştirilmiş ve rakip perakende firmalarının fiyat verileri de karar destek sistemine dahil edilmiştir. Ayrıca yine bu çalışmada, farklı tahminleme ve optimizasyon algoritmaları sistem içinde çalıştırılmıştır. Bu yönleri ile çalışmanın literatüre katkı sağlayacağı

aşıkardır. Önerilen dinamik fiyatlandırma karar destek sistemi Türkçe literatürde ise ilktir ve bu yönüyle önem taşımaktadır. Her ne kadar Türkçe literatürde moda endüstrisine ait indirim optimizasyonu çalışmalarında talep tahmini ve optimizasyondan oluşan karar yapıları mevcut olsa da, dinamik fiyatlandırma konusunda Türkçe literatürde bu içerikte bir çalışmaya rastlanmamıştır.

Gelecek çalışmalarda; bu tez çalışması kapsamında geliştirilen karar destek sisteminin incelenen ürün grubundaki uzun vadeli etkileri gözlendikten sonra, ürün kategori sayısının artırılarak karar destek sisteminin tüm ürün gruplarına ölçeklendirilmesi hedeflenmektedir. Ayrıca; ürün kategorisinin artırılmasının bir sonucu olarak, veri setinin boyutunun da artırılmasının vereceği avantaj ile mevcut modellerde başarının artırılması öngörülmektedir. Derin öğrenme gibi algoritmaları da tahmin modülüne ekleyerek tahmin modeli sayısının artırılması gelecek araştırma konularından bir diğeridir.

Ek olarak; optimizasyon modülündeki metasezgisel algoritmalarda kullanılan parametrelerin seviyelerinin deney tasarımı yaklaşımı ile analizlerinin yapılarak, daha iyi optimizasyon sonuçları elde edilebilmek amacı ile parametre optimizasyonunun gerçekleştirilmesi gelecek çalışmalar içinde yer almaktadır.

Özellikle geçirdiğimiz pandemi döneminde ürünlerde stok bulunurluğunda sıkıntıların yaşanması, tüketicilerin muadil ürünlere daha açık hale gelmesine neden olmuştur. Geliştirilen bu dinamik fiyatlandırma karar destek sistemine muadil ürünleri dahil eden bir karar mekanizmasının eklenmesi fiyatlandırma stratejisinin başarısını artırabilecek bir faktör olması nedeni ile gelecek araştırma konularından bir diğeri olarak düşünülmektedir. |

KAYNAKLAR

- [Abdel-Basset, M., Abdel-Fatah, L., & Sangaiah, A. K. (2018). Metaheuristic algorithms: A comprehensive review. *Computational intelligence for multimedia big data on the cloud with engineering applications*, 185-231.
- Akyol, S., & Alatas, B. (2017). Plant intelligence based metaheuristic optimization algorithms. *Artificial Intelligence Review*, 47(4), 417-462.
- Alpaydin, E. (2020). *Introduction to machine learning*. MIT press, London, ISBN: 978-0-262-02818-9.
- Akçay, Y., Natarajan, H. P., & Xu, S. H. (2010). Joint dynamic pricing of multiple perishable products under consumer choice. *Management Science*, 56(8), 1345-1361.
- Altay, E. V., & Alatas, B. (2020). Randomness as source for inspiring solution search methods: Music based approaches. *Physica A: Statistical Mechanics and its Applications*, 537, 122650.
- Anjos, M. F., Cheng, R. C., & Currie, C. S. (2005). Optimal pricing policies for perishable products. *European Journal of Operational Research*, 166(1), 246-254.
- Anton, J. J., Biglaiser, G., & Vettas, N. (2014). Dynamic price competition with capacity constraints and a strategic buyer. *International Economic Review*, 55(3), 943-958.
- Araman, V. F., & Caldentey, R. (2009). Dynamic pricing for nonperishable products with demand learning. *Operations research*, 57(5), 1169-1188.
- Aviv, Y., Levin, Y., & Nediak, M. (2009). Counteracting strategic consumer behavior in dynamic pricing systems. In *Consumer-Driven Demand and Operations Management Models* (pp. 323-352). Springer, Boston, MA.
- Aviv, Y., & Pazgal, A. (2008). Optimal pricing of seasonal products in the presence of forward-looking consumers. *Manufacturing & Service Operations Management*, 10(3), 339-359.
- Avriel, M. (2003). *Nonlinear programming: analysis and methods*. Courier Corporation, New York, ISBN: 978-0486432274
- Aydin, G., & Ziya, S. (2008). Pricing promotional products under upselling. *Manufacturing & Service Operations Management*, 10(3), 360-376.
- Aydin, G., & Ziya, S. (2009). Personalized dynamic pricing of limited inventories. *Operations Research*, 57(6), 1523-1531.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *The Journal of Machine Learning Research*, 13(1), 281-305.

- Besbes, O., & Zeevi, A. (2009). Dynamic pricing without knowing the demand function: Risk bounds and near-optimal algorithms. *Operations Research*, 57(6), 1407-1420.
- Besbes, O., & Zeevi, A. (2015). On the (surprising) sufficiency of linear models for dynamic pricing with demand learning. *Management Science*, 61(4), 723-739.
- Brassington, F., & Pettitt, S. (2005). *Principles of marketing*. London, NY: FT Prentice Hall, ISBN: 0-273-65791-7..
- Bilişik, M. T., & Gürgen, O. (2012). Perakendecilik sektöründe dinamik fiyatlandırma: geniş bir literatür taraması, *Öneri*, 10(37), 111-119.
- Bitran, G. R., & Wadhwa, H. K. S. (1996). *Some structural properties of the seasonal product pricing problem*. MIT Sloan School of Management.
- Bitran, G., & Caldentey, R. (2003). An overview of pricing models for revenue management. *Manufacturing & Service Operations Management*, 5(3), 203-229.
- Boulesteix, A. L., Bender, A., Lorenzo Bermejo, J., & Strobl, C. (2012). Random forest Gini importance favours SNPs with large minor allele frequency: impact, sources and recommendations. *Briefings in Bioinformatics*, 13(3), 292-304.
- Breiman, L., & Cutler, A. (2004). RFtools-for predicting and understanding data. *In Interface'04 Workshop*.
- Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A. (1984). *Classification and regression trees*. CRC press.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2), 123-140.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Büyüksaatçı, S. (2015), *Doğadan esinlenen ve ses yankısına dayalı çözüm arama algoritması ile belge kümeleme*, Doktora Tezi, İstanbul Üniversitesi.
- Capocchi, A., Capocchi, A., & Barlow. (2019). *Economic Value and Revenue Management Systems*. Springer International Publishing, Switzerland, ISBN: 978-3-030-02417-8.
- Caro, F., & Gallien, J. (2012). Clearance pricing optimization for a fast-fashion retailer. *Operations Research*, 60(6), 1404-1422.
- Chen, M., Chen, Z. L., Pundoor, G., Acharya, S., & Yi, J. (2015). Markdown optimization at multiple stores. *IIE Transactions*, 47(1), 84-108.
- Chen, M., & Chen, Z. L. (2015). Recent developments in dynamic pricing research: multiple products, competition, and limited demand information. *Production and Operations Management*, 24(5), 704-731.

- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785-794.
- Chew, E. P., Lee, C., Liu, R., Hong, K. S., & Zhang, A. (2014). Optimal dynamic pricing and ordering decisions for perishable products. *International Journal of Production Economics*, 157, 39-48.
- Click, C., Malohlava, M., Parmar, V., Roark, H., and Candel, A. (2020). Gradient Boosting Machine with H2O. <http://h2o.ai/resources/>.
- Criminisi, A., & Shotton, J. (Eds.). (2013). *Decision forests for computer vision and medical image analysis*. Springer Science & Business Media.
- Cohen, M. C., Lobel, R., & Perakis, G. (2018). Dynamic pricing through data sampling. *Production and Operations Management*, 27(6), 1074-1088.
- Den Boer, A. V. (2015). Dynamic pricing and learning: historical origins, current research, and new directions. *Surveys in operations research and management science*, 20(1), 1-18.
- Dal (2020), “Gıda Perakendesi Ve E-Ticaret İçin Covid-19 Tespit Ve Öngörülleri”, available at: <https://blog.obase.com/tr/gida-perakendesi-icin-covid-19-tespit-ve-ongoruleri-2/>
- Dannenberg, P., Fuchs, M., Riedler, T., & Wiedemann, C. (2020). Digital transition by COVID-19 pandemic? The German food online retail. *Tijdschrift voor economische en sociale geografie*.
- Dasu, S., & Tong, C. (2010). Dynamic pricing when consumers are strategic: Analysis of posted and contingent pricing schemes. *European Journal of Operational Research*, 204(3), 662-671.
- Deloitte (2020), “Perakende sektörü COVID-19 sonrası döneme nasıl hazırlanmalı?”, available at: <https://www2.deloitte.com/tr/tr/pages/consumer-business/articles/perakende-sektoru-covid-19-sonrasi-doneme-nasil-hazirlanmali.html>
- Dolgui, A., & Proth, J. M. (2010). Pricing strategies and models. *Annual Reviews in Control*, 34(1), 101-110.
- Elmaghraby, W., & Keskinocak, P. (2003). Dynamic pricing in the presence of inventory considerations: Research overview, current practices, and future directions. *Management science*, 49(10), 1287-1309.
- Faith, D. O., & Agwu, E. (2018). A review of the effect of pricing strategies on the purchase of consumer goods. *International Journal of Research in Management, Science & Technology (E-ISSN: 2321-3264)*, 2(2), 88-102.
- Ferreira, K. J., Lee, B. H. A., & Simchi-Levi, D. (2015). Analytics for an online retailer: Demand forecasting and price optimization. *Manufacturing & Service Operations Management*, 18(1), 69-88.

- Fisher, M., Gallino, S., & Li, J. (2017). Competition-based dynamic pricing in online retailing: A methodology validated with field experiments. *Management Science*, 64(6), 2496-2514.
- Freund, Y., & Schapire, R. E. (1996). Experiments with a new boosting algorithm. In *icml*, 96, 148-156.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 1189-1232.
- Friedman, J. H., & Hall, P. (2007). On bagging and nonlinear estimation. *Journal of statistical Planning and Inference*, 137(3), 669-683.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media, New York, ISBN: 978-0-387-84857-0.
- Hawtin, M. (2003). The practicalities and benefits of applying revenue management to grocery retailing, and the need for effective business rule management. *Journal of Revenue and Pricing Management*, 2(1), 61-68.
- Heching, A., Gallego, G., & van Ryzin, G. (2002). Mark-down pricing: An empirical analysis of policies and revenue potential at one apparel retailer. *Journal of Revenue and Pricing Management*, 1(2), 139-160.
- Hinterhuber, A. (2008). *Customer value-based pricing strategies: why companies resist*. *Journal of Business Strategy*, 29(4), 41-50.
- Ho, T. K. (1995). Random decision forests. In *Proceedings of 3rd international conference on document analysis and recognition*, IEEE, 1, 278-282.
- Huang, N., Lu, G., & Xu, D. (2016). A permutation importance-based feature selection method for short-term electricity load forecasting using random forest. *Energies*, 9(10), 767.
- H2O (2020a), “Distributed Random Forest (DRF)”, available at: <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/data-science/drf.html>
- H2O (2020b), “Gradient Boosting Machine (GBM)”, available at: <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/data-science/gbm.html>
- Gallego, G., & Van Ryzin, G. (1994). Optimal dynamic pricing of inventories with stochastic demand over finite horizons. *Management Science*, 40(8), 999-1020.
- García-Calderón Chávez, S. A. (2017), *Pricing recommendation by applying statistical modeling techniques*, Master's thesis, Universitat Politècnica de Catalunya.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media.

- Glover, F., & Taillard, E. (1993). A user's guide to tabu search. *Annals of Operations Research*, 41(1), 1-28.
- Grunert, K. G., & Aachmann, K. (2016). Consumer reactions to the use of EU quality labels on food products: A review of the literature. *Food Control*, 59, 178-187.
- Gupta, D., Hill, A. V., & Bouzdine-Chameeva, T. (2006). A pricing model for clearing end-of-season retail inventory. *European Journal of Operational Research*, 170(2), 518-540.
- Kachani, S., Perakis, G., & Simon, C. (2007). Modeling the transient nature of dynamic pricing with demand learning in a competitive environment. In *Network science, nonlinear science and infrastructure systems* (pp. 223-267). Springer, Boston, MA.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-International Conference on Neural Networks, IEEE*, 4, 1942-1948.
- Kerin, R., & Hartley, S. (2015). *Marketing: the core (4th edition)*. McGraw-Hill, Toronto, ISBN: 978-1259103179.
- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by simulated annealing. *Science*, 220(4598), 671-680.
- Koenig, M., & Meissner, J. (2010). List pricing versus dynamic pricing: Impact on the revenue risk. *European Journal of Operational Research*, 204(3), 505-512.
- Kopalle, P. K., & Shumsky, R. A. (2012). Game Theory Models of Pricing. *The Oxford Handbook of Pricing Management*, 381.
- Levin, Y., McGill, J., & Nediak, M. (2008). Risk in revenue management and dynamic pricing. *Operations Research*, 56(2), 326-343.
- Levin, Y., McGill, J., & Nediak, M. (2009). Dynamic pricing in the presence of strategic consumers and oligopolistic competition. *Management Science*, 55(1), 32-46.
- Levin, Y., McGill, J., & Nediak, M. (2010). Optimal dynamic pricing of perishable items by a monopolist facing strategic consumers. *Production and Operations Management*, 19(1), 40-60.
- Lewis, C. (1982). *International and Business Forecasting Methods* Butterworths: London, ISBN: 0408005599 9780408005593.
- Levy, M., Weitz, B. A., & Grewal, D. (2012). *Retailing Management (ed.)*. New York: Irwin.
- Lin, Y. C., & Yeh, H. D. (2006). Identifying Groundwater Contaminant Source Characteristics Using Simulated Annealing. *Journal of the Chinese Institute of Environmental Engineering*, 16(3), 183-188.
- Lim, A. E., & Shanthikumar, J. G. (2007). Relative entropy, exponential utility, and robust dynamic pricing. *Operations Research*, 55(2), 198-214.

- Lippman, B. W. (2003). Retail revenue management—Competitive strategy for grocery retailers. *Journal of Revenue and Pricing Management*, 2(3), 229-233.
- Liu, B., & Milner, J. (2006). Multiple-item dynamic pricing under a common pricing constraint. *University of Toronto: Toronto, ON, Canada*.
- Lu, Q., & Liu, N. (2013). Pricing games of mixed conventional and e-commerce distribution channels. *Computers & Industrial Engineering*, 64(1), 122-132.
- Maglaras, C., & Meissner, J. (2006). Dynamic pricing strategies for multiproduct revenue management problems. *Manufacturing & Service Operations Management*, 8(2), 136-148.
- Mantrala, M. K., & Rao, S. (2001). A decision-support system that helps retailers decide order quantities and markdowns for fashion goods. *Interfaces*, 31(3_supplement), S146-S165.
- Martínez-de-Albéniz, V., & Talluri, K. (2011). Dynamic price competition with fixed capacities. *Management Science*, 57(6), 1078-1093.
- Mersereau, A. J., & Zhang, D. (2012). Markdown pricing with unknown fraction of strategic customers. *Manufacturing & Service Operations Management*, 14(3), 355-370.
- Mitchell, R. (2018). *Web scraping with Python: Collecting more data from the modern web*. "O'Reilly Media, Inc."
- Perakis, G., & Sood, A. (2006). Competitive multi-period pricing for perishable products: A robust optimization approach. *Mathematical Programming*, 107(1-2), 295-335.
- Philips, J. (2019), "How Uber's dynamic pricing model works", available at: <https://www.uber.com/en-GB/blog/uber-dynamic-pricing/>
- Popescu, I., & Wu, Y. (2007). Dynamic pricing strategies with reference effects. *Operations Research*, 55(3), 413-429.
- Prasad, A. M., Iverson, L. R., & Liaw, A. (2006). Newer classification and regression tree techniques: bagging and random forests for ecological prediction. *Ecosystems*, 9(2), 181-199.
- Smith, S. A., & Achabal, D. D. (1998). Clearance pricing and inventory policies for retail chains. *Management Science*, 44(3), 285-300.
- Soysal, G. P., & Krishnamurthi, L. (2012). Demand dynamics in the seasonal goods industry: An empirical analysis. *Marketing Science*, 31(2), 293-316.
- Sörensen, K. (2015). Metaheuristics—the metaphor exposed. *International Transactions in Operational Research*, 22(1), 3-18.
- Szu, H., & Hartley, R. (1987). Fast simulated annealing. *Physics letters A*, 122(3-4), 157-162.

- Şen, A. (2013). A comparison of fixed and dynamic pricing policies in revenue management." *Omega*; 41(3), 586-597.
- Talluri, K. T., & Van Ryzin, G. J. (2006). *The theory and practice of revenue management*. Vol. 68, Springer Science & Business Media, Boston, ISBN: 1-4020-7933-8.
- Tsallis, C., & Stariolo, D. A. (1996). Generalized simulated annealing. *Physica A: Statistical Mechanics and its Applications*, 233(1-2), 395-406.
- UiPath (2020), "Web Scraping software that works everywhere", available at: <https://www.uipath.com/solutions/technology/web-scraping-software>
- Vakhutinsky, A., Kushkuley, A., & Gupte, M. (2012). Markdown optimization with an inventory-depletion effect. *Journal of Revenue and Pricing Management*, 11(6), 632-644.
- Van der Aalst, W. M., Bichler, M., & Heinzl, A. (2018). Robotic process automation. *Business & Information Systems Engineering*, 60, 269–272. <https://doi.org/10.1007/s12599-018-0542-4>
- Var, H., & Türkay, B. E. (2014). Yapay sinir ağları kullanılarak kısa dönem elektrik yükü tahmini, *ELECO 2014: Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, 34-37.
- Venables, W. N., Smith, D. M., & R Development Core Team. (2009). *An introduction to R: Notes on R: A Programming Environment for Data Analysis and Graphics*. ISBN 3-900051-12-7
- Wu, X., Xiong, J., Li, H., & Wu, H. (2019). The myth of retail pricing policy for developing organic vegetable markets. *Journal of Retailing and Consumer Services*, 51, 8-13.
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., & Deng, S. H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1), 26-40.
- Xiang, Y., Gubian, S., Suomela, B., & Hoeng, J. (2013). Generalized Simulated Annealing for Global Optimization: The GenSA Package. *R Journal*, 5(1).
- Xu, X. I. A. O. W. E. I., & Hopp, W. J. (2005). *Dynamic pricing and inventory control: The value of demand learning*. Department of Industrial Engineering, Northwestern University.
- Yang, X. S. (2010). *Engineering Optimization: An Introduction with Metaheuristic Applications*. John Wiley & Sons, Hoboken, New Jersey, ISBN : 9780470640418
- Yang, X. S. (Ed.). (2015). *Recent advances in swarm intelligence and evolutionary computation*. Springer International Publishing.

Yao, X., Sanl, T., & Gulcu, A. (2015). Markdown optimization for multiple products with a common markdown budget constraint. *Journal of Revenue and Pricing Management*, 14(6), 442-450.

Zhang, D., & Cooper, W. L. (2008). Managing clearance sales in the presence of strategic customers. *Production and Operations Management*, 17(4), 416-431.

Zhang, D., Dai, H., Dong, L., Qi, F., Zhang, N., Liu, X., ... & Yang, J. (2017). How do price promotions affect customer behavior on retailing platforms? Evidence from a large randomized experiment on Alibaba. *Production and Operation Management, Special Issue on Patient-Centric Healthcare Management in the Age of Analytics*, 27(12), 2343-2345.

Zhao, W., & Zheng, Y. S. (2000). Optimal dynamic pricing for perishable assets with nonhomogeneous demand. *Management Science*, 46(3), 375-388.

Zhao, L., Tian, P., & Li, X. (2012). Dynamic pricing in the presence of consumer inertia.

EKLER

EK 1. Tez çalışmasında incelenen 53 ürünün, 01.01.2020 tarihli mevcut fiyat ve PSO ve GenSA algoritmaları ile elde edilen optimum fiyat verileri

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
1	2.53	3.06	2.53
2	6.69	8.09	8.09
3	4.87	5.89	4.87
4	3.52 - 3.69	4.26 - 4.46	3.52 - 3.69
5	9.74	11.79	9.74
6	3.09 - 3.38	3.74 - 4.09	3.09 - 3.38
7	4.66 - 4.94	5.64-5.98	4.66 - 4.94
8	6.77	8.19	6.77
9	13.98	16.91	16.9
10	25.85	31.28	25.85
11	29.66 - 33.81	35.81 - 40.81	29.66 - 33.81
12	3.46-3.94	4.19 - 4.77	3.46 - 3.94
13	3.73	4.51	3.73
14	3.72 - 4.61	4.5 - 5.58	3.72 - 4.61
15	11.86	14.35	11.86
16	13.98 - 13.99	16.91 - 16.92	13.98 -13.99
17	3.38	4.09	3.38
18	4.66	5.64	4.66
19	6.57	7.95	6.57
20	36.35	43.87	36.35
21	13.13	15.89	13.13
22	9.74	11.79	9.74
23	11.85	14.34	11.85
24	8.04	9.73	8.04
25	53.3-55	64.29 - 66.41	53.3 - 55
26	45.68	55.11 - 55.18	45.68
27	109.1	131.59	109.1
28	23.72 - 24.49	28.65 - 29.63	23.72 - 29.63
29	6.77	8.19	6.77
30	4.57	5.53	4.57
31	10.59	12.81	10.59
32	22.67 -24.49	27.38 - 29.63	22.67 -24.49
33	6.77	8.19	6.77

* Ürünlere ait fiyat değerleri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
34	6.77	8.19	6.77
35	6.77	8.19	6.77
36	24.49	29.58	24.49
37	6.77	8.19	6.77
38	6.77	8.19	6.77
39	6.77	8.19	6.77
40	37.2	44.89	37.2
41	50.76	61.23	50.76
42	9.31	11.27	9.31
43	6.77	8.19	6.77
44	15.67	18.95	15.67
45	18.51	22.37 - 22.40	18.51 - 22.3
46	40.67	49.07	40.67 - 49.07
47	12.5 - 13.47	15.12 - 16.30	12.5 -13.47
48	11.44	13.84	11.44
49	14.06	17.01	14.06
50	30.93	37.34	30.93
51	21.19	25.60	21.19
52	6.77	8.19	6.77
53	14.32	17.33	14.32

* Ürünlele ait fiyat değlerleri tez çalışmasının incelendiğı 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

EK 2. Tez çalışmasında incelenen 53 ürünün, 02.01.2020 tarihli mevcut fiyat ve PSO ve GenSA algoritmaları ile elde edilen optimum fiyat verileri

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
1	2.53	3.06	2.53
2	6.69 - 9.24	8.09 - 11.18	6.69 - 9.24
3	4.87	5.89	4.87
4	3.69	4.46	3.69
5	9.74	11.79	9.74
6	3.09	3.74	3.09
7	4.66 - 4.94	5.64 - 5.98	4.66 - 4.94
8	6.77	8.19	6.77
9	11.71 - 13.98	14.17 - 16.91	11.71 - 13.98
10	25.85	31.28	25.85
11	29.66 - 33.81	35.81 - 40.81	29.66 - 33.81
12	3.69 - 3.94	4.46 - 4.77	3.69 - 3.94
13	3.73	4.51	3.73
14	3.72 - 4.61	4.50 - 5.58	3.72 - 4.61
15	11.86	14.35	11.86
16	13.98	16.91	13.98
17	3.38	4.09	3.38
18	4.66	5.64	4.66
19	6.57	7.95	6.57
20	36.35	43.87	36.35
21	13.13	15.89	13.13
22	9.74	11.79	9.74
23	11.85	14.34	11.85
24	8.04	9.73	8.04
25	53.3	64.29 - 64.43	53.3
26	45.68	55.11	45.68
27	109.1	131.59	109.1
28	24.49	29.58 - 29.63	24.49
29	6.77	8.19	6.77
30	4.57	5.53	4.57
31	10.59	12.81	10.59
32	24.88	30.05	24.88
33	6.77	8.19	6.77
34	6.77	8.19	6.77
35	6.77	8.19	6.77
36	24.49	29.58	24.49

* Ürünle ait fiyat değeri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
37	6.77	8.19	6.77
38	6.77	8.19	6.77
39	6.77	8.19	6.77
40	37.2	44.89	37.2
41	50.76	61.23	50.76
42	9.31	11.27	9.31
43	6.77	8.19	6.77
44	15.67	18.95	15.67
45	18.51	22.37	18.51
46	40.67	49.07	40.67
47	13.47	16.29	13.47
48	11.44	13.84	11.44
49	14.06	17.01	14.06
50	30.93	37.34	30.93
51	21.19	25.60	21.19
52	6.77	8.19	6.77
53	14.32	17.33	14.32

* Ürünler için fiyat değerleri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

EK 3. Tez çalışmasında incelenen 53 ürünün, 03.01.2020 tarihli mevcut fiyat ve PSO ve GenSA algoritmaları ile elde edilen optimum fiyat verileri

ÜrünNo	Mevcut Fiyat*	Gens* ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
1	2.53	3.06	2.53
2	6.69 - 9.24	8.09 - 11.18	6.69 - 9.24
3	4.87	5.89	4.87
4	3.69	4.46	3.69
5	9.32	11.28 - 11.79	9.32 - 9.74
6	3.38	4.09	3.38
7	4.94	5.98	4.94
8	6.77	8.19	6.77
9	12.08 - 13.98	14.62 - 16.92	12.08 - 13.98
10	25.85	31.28	25.85
11	29.66 - 33.81	35.81 - 40.81	29.66 - 33.81
12	3.69 - 3.94	4.46-4.77	3.69 - 3.94
13	3.73	4.51	3.73
14	3.72 - 4.61	4.50 - 5.58	3.72 - 4.61
15	11.86	14.35	11.86
16	13.98	16.91 - 16.92	13.98
17	3.18 - 3.38	3.85 - 4.09	3.18 - 3.38
18	4.66	5.64	4.66
19	6.3 - 6.57	7.62 - 7.95	6.3 - 6.57
20	36.35	43.87	36.35
21	13.13	15.89	13.13
22	9.74	11.79	9.74
23	11.85	14.34	11.85
24	8.04	9.73	8.04
25	53.3	64.29 - 64.43	53.3
26	45.68	55.11 - 55.18	45.68
27	105.92	127.69	105.92
28	23.72 - 24.49	28.65 - 29.63	23.72 - 24.49
29	6.77	8.19	6.77
30	4.57 - 5	5.53 - 6.05	4.57 - 5
31	10.59	12.81	10.59
32	24.49	29.63	24.49
33	6.77	8.19	6.77
34	6.77	8.19	6.77
35	6.77	8.19	6.77
36	24.49	29.58	24.49

* Ürünlere ait fiyat değerleri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

ÜrünNo	Mevcut Fiyat*	GenSA* ile Elde Edilen Fiyat	PSO* ile Elde Edilen Fiyat
37	6.77	8.19	6.77
38	6.77	8.19	6.77
39	6.77	8.19	6.77
40	37.2	44.89 - 44.96	37.2
41	50.76	61.23	50.76
42	9.31	11.27	9.31
43	6.77	8.19	6.77
44	15.67 - 16.86	18.96 - 20.38	15.67 - 16.86
45	18.51	22.37 - 22.40	18.51
46	40.67	49.07	40.67
47	13.47	16.30	13.47
48	11.44	13.84	11.44
49	14.06	17.01	14.06
50	30.93	37.41	30.93
51	21.19	25.60	21.19
52	6.77	8.19	6.77
53	14.32	17.33	14.32

* Ürünle ait fiyat değeri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

EK 4. Tez çalışmasında incelenen 53 ürünün, 04.01.2020 tarihli mevcut fiyat ve PSO ve GenSA algoritmaları ile elde edilen optimum fiyat verileri

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
1	2.53	3.06	2.53
2	6.69 - 9.24	8.09 - 11.18	6.69 - 9.24
3	4.87	5.89	4.87
4	3.52 - 3.69	4.26 - 4.46	3.52 - 3.69
5	9.74	11.79	9.74
6	3.09 - 3.38	3.74 - 4.09	3.09 - 3.38
7	4.94	5.98	4.94
8	6.77	8.19	6.77
9	11.71 - 13.98	14.17 - 16.91	11.71 - 13.98
10	25.85	31.28	25.85
11	29.66 -33.81	35.81 - 40.91	29.66 -33.81
12	3.69 - 3.94	4.46 - 4.77	3.69 - 3.94
13	3.73	4.51	3.73
14	3.72 - 4.61	4.50 - 5.58	3.72 - 4.61
15	11.86	14.35	11.86
16	13.98	16.91 -16.92	13.98
17	3.38	4.09	3.38
18	4.66	5.64	4.66
19	6.57	7.95	6.57
20	36.35	43.87 - 43.94	36.35
21	13.13	15.89	13.13
22	9.74	11.79	9.74
23	11.85	14.34	11.85
24	8.04	9.73	8.04
25	53.3	64.29 -64.43	53.3
26	45.68	55.11 - 55.25	45.68
27	105.92	127.69	105.92
28	23.72 - 24.49	28.65 - 29.63	23.72 - 24.49
29	6.77	8.19	6.77
30	4.57 - 5	5.53 - 6.05	4.57 - 5
31	10.59	12.81	10.59
32	22.67 - 24.49	27.38 -29.58	22.67 - 24.49
33	6.77	8.19	6.77
34	6.77	8.19	6.77
35	6.77	8.19	6.77
36	24.49	29.58	24.49

* Ürünlere ait fiyat değerleri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
37	6.77	8.19	6.77
38	6.77	8.19	6.77
39	6.77	8.19	6.77
44	15.67 - 16.86	18.95- 20.38	15.67 - 16.86
45	18.51	22.37 -22.40	18.51
46	40.67	49.07	40.67
47	13.47	16.30	13.47
48	11.44	13.84	11.44
49	14.06	17.01	14.06
50	31.78	38.36	31.78
51	21.19	25.60	21.19
52	6.77	8.19	6.77
53	14.32	17.33	14.32

* Ürünlele ait fiyat değlerleri tez çalışmasının incelendiğı 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

EK 5. Tez çalışmasında incelenen 53 ürünün, 05.01.2020 tarihli mevcut fiyat ve PSO ve GenSA algoritmaları ile elde edilen optimum fiyat verileri

ÜrünNo	Mevcut Fiyat*	GenSA* ile Elde Edilen Fiyat	PSO* ile Elde Edilen Fiyat
1	2.8	3.39	2.8
2	6.69 - 9.24	8.09 - 11.18	6.69 - 9.24
3	4.87	5.89	4.87
4	3.52	4.26	3.52
5	9.74	11.79	9.74
6	3.09 - 3.38	3.74 - 4.09	3.09 - 3.38
7	4.66- 4.94	5.98	4.66- 4.94
8	6.77	8.19	6.77
9	13.98	16.92	13.98
10	25.85	31.28	25.85
11	29.66 -33.81	35.81 - 40.91	29.66 -33.81
12	3.69 - 3.94	4.46 - 4.77	3.69 - 3.94
13	3.73	4.51	3.73
14	3.72 - 4.61	4.50 - 5.58	3.72 - 4.61
15	11.86	14.35	11.86
16	13.98	16.91	13.98
17	3.38	4.09	3.38
18	4.66	5.64	4.66
19	6.57	7.95	6.57
20	36.35	43.87	36.35
21	13.13	15.89	13.13
22	9.74	11.79	9.74
23	11.85	14.34	11.85
24	8.04	9.73	8.04
25	53.3	64.29	53.3
26	45.68	55.11 - 55.18	45.68
27	105.92	127.69	105.92
28	23.72 - 24.49	28.65 - 29.63	23.72 - 24.49
29	6.77	8.19	6.77
30	4.57	5.53	4.57
31	10.59	12.81	10.59
32	22.67 - 24.49	27.38 -29.63	22.67 - 24.49
33	6.77	8.19	6.77
34	6.77	8.19	6.77
35	6.77	8.19	6.77
36	23.7	28.68	23.7
37	6.77	8.19	6.77
38	6.77	8.19	6.77

* Ürnlere ait fiyat deęerleri tez çalışmasının incelendięi 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları bazı durumlarda aralık olarak ifade edilmiştir.

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
39	6.77	8.19	6.77
40	36.35- 37.2	43.94 - 44.89	36.35- 37.2
41	50.76	61.23 - 61.30	50.76
42	9.31	11.27	9.31
43	6.77	8.19	6.77
44	15.67	18.95	15.67
45	18.51	22.37 -22.40	18.51
46	40.67	49.07	40.67
47	13.47	16.30	13.47
48	11.44	13.84	11.44
49	14.06	17.01	14.06
50	31.78	38.43	31.78
51	21.19	25.60	21.19
52	6.77	8.19	6.77
53	14.32	17.33	14.32

EK 6. Tez çalışmasında incelenen 53 ürünün, 06.01.2020 tarihli mevcut fiyat ve PSO ve GenSA algoritmaları ile elde edilen optimum fiyat verileri

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
1	2.8	3.39	2.8
2	9.24	11.18	9.24
3	4.87	5.89	4.87- 5.89
4	3.69	4.46	3.69
5	9.74	11.79	9.74
6	3.09 -3.38	3.74 - 4.09	3.09 - 3.38
7	4.94 -5.15	5.98 - 6.23	4.94 -5.5
8	6.77	8.19	6.77
9	13.98	16.91	13.98
10	25.85	31.28	25.85
11	29.66 -33.81	35.81 - 40.81	29.66- 35.8
12	3.46 - 3.94	4.19 - 4.77	3.46 -3.94
13	3.73	4.51	3.73
14	4.61	5.58	4.61
15	11.86	14.35	11.86
16	13.98	16.92	13.98
17	3.38	4.09	3.38
18	4.66	5.64	4.66
19	6.57 - 6.58	7.95	6.78 -7
20	36.35 -36.66	43.87 -43.94	36.35 - 36.76
21	13.13	15.89	15.88
22	9.74	11.79	9.74
23	11.85	14.34	11.85
24	8.04	9.73	8.04
25	53.3	64.29	53.3
26	45.68	55.11 -55.18	45.68
27	105.92	127.69	105.92
28	23.72 - 24.49	28.65 - 29.63	23.72 - 24.49
29	6.77	8.19	6.77
30	5	6.05	5
31	10.25 - 10.59	12.40 - 12.81	10.25 - 10.59
32	24.49	29.58	24.49
33	6.77	8.19	6.77
34	6.77	8.19	6.77
35	6.77	8.19	6.77
36	24.49	29.58	24.49
37	6.77	8.19	6.77

* Ürünle ait fiyat değeri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları aralık olarak ifade edilmiştir.

ÜrünNo	Mevcut Fiyat*	GenSA ile Elde Edilen Fiyat*	PSO ile Elde Edilen Fiyat*
38	6.77	8.19	6.77
39	6.77	8.19	6.77
40	37.2	44.8 - 44.96	37.2
41	50.76	61.23 - 61.37	50.76 - 61.22
42	9.31	11.27	9.31
43	6.77	8.19	6.77
44	16.86	20.38	16.86
45	18.51	22.37	18.51
46	40.67	49.07	40.67
47	13.47	16.30	13.47
48	11.44	13.84	11.44
49	14.06	17.01	14.06
50	31.78	38.43	31.78
51	21.19	25.60	21.19
52	6.77	8.19	6.77
53	14.32	17.33	14.32

* Ürünle ait fiyat değlerleri tez çalışmasının incelendiği 7 mağaza için farklılık gösterebilmektedir. Bu nedenle ürünlerin Mevcut Fiyat, PSO ile ve GenSA algoritmaları ile elde edilen fiyatları aralık olarak ifade edilmiştir.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Sinem BATMACA

Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Endüstri Mühendisliği
Mezuniyet Yılı	2017

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Endüstri Mühendisliği Anabilim Dalı
Programı	Endüstri Mühendisliği

Makale ve Bildiriler	
Börekçi, D. Y., Kiriş, S. B., & Batmaca, S. (2020). Analysis of enterprise resource planning (ERP) system workarounds with a resilience perspective. <i>Continuity & Resilience Review</i> , 2(2), 131-148.	