



AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



Leyla ATABAY

OTEL İŞLETMELERİNDE MÜŞTERİ YAŞAM BOYU DEĞERİ TAHMİNİ VE
YÖNETİMİ: WEB TABANLI BİR UYGULAMA İLE ENTEGRE YAKLAŞIM

Turizm İşletmeciliği Anabilim Dalı
Doktora Tezi

Antalya, 2025



AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



Leyla ATABAY

OTEL İŞLETMELERİNDE MÜŞTERİ YAŞAM BOYU DEĞERİ TAHMİNİ VE
YÖNETİMİ: WEB TABANLI BİR UYGULAMA İLE ENTEGRE YAKLAŞIM

Danışman

Prof. Dr. Beykan ÇİZEL

Turizm İşletmeciliği Anabilim Dalı

Doktora Tezi

TÜBİTAK 2244- Sanayi Doktora Programı tarafından 119C158 no'lu proje ile
desteklenmiştir.

Antalya, 2025

T.C.
Akdeniz Üniversitesi
Sosyal Bilimler Enstitüsü Müdürlüğüne,

Leyla ATABAY'ın bu çalışması, jürimiz tarafından Turizm İşletmeciliği Anabilim Dalı
Doktora Programı tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Ömür TOSUN (İmza)

Üye (Danışman) : Prof. Dr. Beykan ÇİZEL (İmza)

Üye : Dr. Öğr. Üyesi Edina AJANOVIC (İmza)

Üye : Dr. Öğr. Üyesi Demet CEYLAN (İmza)

Üye : Dr. Öğr. Üyesi Çağla MCKENZIE (İmza)

Tez Başlığı: Otel İşletmelerinde Müşteri Yaşam Boyu Değeri Tahmini ve Yönetimi:
Web Tabanlı Bir Uygulama İle Entegre Yaklaşım

Onay: Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Tez Savunma Tarihi : 05/02/2022

Mezuniyet Tarihi : 27/02./2025

AKADEMİK BEYAN

Doktora Tezi/Yüksek Lisans Tezi/Dönem Projesi olarak sunduğum “Otel İşletmelerinde Müşteri Yaşam Boyu Değeri Tahmini ve Yönetimi: Web Tabanlı Bir Uygulama ile Entegre Yaklaşım” adlı bu çalışmanın, akademik kural ve etik değerlere uygun bir biçimde tarafımdan yazıldığını, yararlandığım bütün eserlerin kaynakçada gösterildiğini ve çalışma içerisinde bu eserlere atıf yapıldığını belirtir; bunu şerefimle doğrularım.

(İmza)

Leyla ATABAY





AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



24/02/2025

TEZ ÇALIŞMASI ORJİNALLİK RAPORU BEYAN BELGESİ

Öğrenci Bilgileri	
Adı-Soyadı	Leyla ATABAY
Öğrenci Numarası	202052004001
Anabilim Dalı	Turizm İşletmeciliği
Programı	Turizm İşletmeciliği Doktora Programı
Danışman Öğretim Üyesi Bilgileri	
Unvanı, Adı-Soyadı	Prof. Dr. Beykan ÇİZEL
Doktora Tez Başlığı	Otel İşletmelerinde Müşteri Yaşam Boyu Değeri Tahmini Ve Yönetimi: Web Tabanlı Bir Uygulama İle Entegre Yaklaşım
Turnitin Bilgileri	
Ödev Numarası	2597117296
Rapor Tarihi	24/02/2025
Benzerlik Oranı	Alıntılar hariç: %5 Alıntılar dahil: %21
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE, Yukarıda bilgileri bulunan öğrenciye ait tez çalışmasının a) Kapak sayfası, b) Giriş, c) Ana Bölümler ve d) Sonuç kısımlarından oluşan toplam 130 sayfalık kısmına ilişkin olarak Turnitin adlı intihal tespit programından Sosyal Bilimler Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esaslarında belirlenen filtrelemeler uygulanarak yukarıdaki detayları verilen ve ekte sunulan rapor alınmıştır. Danışman tarafından uygun olan seçenek işaretlenmelidir: (X) Benzerlik oranları belirlenen limitleri aşmıyor ise: Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporunun doğruluğunu onaylarım. () Benzerlik oranları belirlenen limitleri aşıyor, ancak tez/dönem projesi danışmanı intihal yapılmadığı kanısında ise: Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporunun doğruluğunu onaylar ve Uygulama Esaslarında öngörülen yüzdelik sınırlarının aşılmasına karşın, aşağıda belirtilen gerekçe ile intihal yapılmadığı kanısında olduğumu beyan ederim.	
Gerekçe:	
Benzerlik taraması yukarıda verilen ölçütlere uygun olarak tarafımca yapılmıştır. İlgili tezin orijinallik raporunun uygun olduğunu beyan ederim.	
Danışman Öğretim Üyesi Unvanı, Adı-Soyadı Prof. Dr. Beykan ÇİZEL İmza	

İÇİNDEKİLER

ŞEKİLLER LİSTESİ	iv
TABLOLAR LİSTESİ	vi
KISALTMALAR LİSTESİ	vii
ÖZET	ix
SUMMARY	x
TEŞEKKÜR / ÖNSÖZ.....	xi
GİRİŞ.....	1

BİRİNCİ BÖLÜM

MÜŞTERİ YAŞAM BOYU DEĞERİ'NİN KAVRAMSAL VE TARİHSEL AÇIDAN DEĞERLENDİRİLMESİ

1.1. Müşteri Yaşam Boyu Değeri Tanımları	3
1.2. CLV Gelişim Süreci	4
1.2.1. 1990'lar: Temel Modellerin Oluşumu	4
1.2.2. 2000'lerin Başı: CLV'nin Ölçülmesi ve Uygulama Alanlarının Kullanılması	5
1.2.3. 2005-2007: CLV'nin Dönüşümü Yönlendiren Stratejik Yaklaşımlar ve Sektörel Derinleşme	5
1.2.4. 2008-2010: Operasyonel Uygulamalar ve İleri Düzey Segmentasyon	6
1.2.5. 2011-2015: Makine Öğrenmesi ve Büyük Veri Etkisi.....	7
1.2.6. 2016-2020: Yapay Zeka ve Dijitalleşme ile Yeni Yönelimler.....	7
1.2.7. 2021 ve Sonrası: Sosyal Medya, Mobil Teknoloji ve Açıklanabilir Yapay Zeka ..	7
1.3. Otel Sektöründe CLV'nin Önemi	8
1.4. CLV Modelleri ve Yaklaşımları	10
1.4.1. Basit CLV Modeli	11
1.4.2. Deterministik Modeller	11
1.4.3. Stokastik Modeller	12
1.4.4. Regresyon Modelleri.....	12
1.4.5. Makine Öğrenmesi Modelleri	13
1.4.6. LTV (Yaşam Boyu Değer) Modelleri	13

1.5. CLV Bileşenleri.....	14
1.5.1. Müşteri Edinme Maliyeti	14
1.5.2. Müşteri Kârlılığı.....	15
1.5.3. Müşteri Sadakati ve Müşteri Tutma Oranı.....	16
1.5.4. Ortalama Satın Alma Değeri.....	17
1.5.5. Satın Alma Sıklığı.....	17
1.5.6. Müşteri Ömrü.....	18
1.5.7. İndirim Oranı.....	18
1.5.8. Kar Marjı.....	19

İKİNCİ BÖLÜM

RFM VE CLV'NİN ENTEGRASYONU ÜZERİNE SİSTEMATİK BİR DERLEME

2.1. RFM ve CLV'nin Entegrasyonu	20
2.2. SPAR-4-SLR Protokolü	22
2.2.1. Toplama.....	23
2.2.2. Düzenleme.....	24
2.2.3. Değerlendirme.....	24
2.3. Derleme Sonuçları	25

ÜÇÜNCÜ BÖLÜM

MÜŞTERİ YAŞAM BOYU DEĞERİ TAHMİNİ VE SEGMENTASYONU İÇİN RFM VE MAKİNE ÖĞRENİMİNİN ENTEGRE EDİLMESİ: OTEL SEKTÖRÜ İÇİN WEB TABANLI BİR UYGULAMA

3.1. Çalışmanın Amacı ve Önemi.....	45
3.2. Araştırma Tasarımı.....	46
3.2.1. Veriseti	49
3.2.2. Ön İşleme	51
3.3. Makine Öğrenmesi Modelleri.....	57
3.3.1. RFM Segmentasyon Analizi	57
3.3.2. CLV Segmentasyon Analizi.....	58
3.3.3. CLV'nin Makine Öğrenmesi ile Tahmini	59
3.4. Değişken Önem Derecesi	61

3.5. Performans Ölçütleri	62
3.5.1. RFM Segmentasyon Performansı	62
3.5.2. CLV Segmentasyon Performansı	63
3.5.3. CLV'nin Tahmin Performansı	65
3.6. Bulgular	66
3.6.1. Tanımlayıcı Analiz Sonuçları	66
3.6.2. CLV Tahmin Bulguları	68
3.6.3. SHAP (SHapley Additive ExPlanations) Analiz Bulguları	69
3.6.4. RFM ve CLV Segmentasyon Bulguları	70
3.7. Gerçeğe Alma- Web Uygulama ve Dağıtımı	78
3.7.1. Uygulamanın ve Teknolojik Altyapısının Geliştirilmesi	78
3.7.2. CLV Modelinin Web Uygulamasına Entegrasyonu	79
3.7.3. Kullanıcı Arayüzü ve İşlevleri	80
SONUÇ	90
KAYNAKÇA.....	97
ÖZGEÇMİŞ	113

ŞEKİLLER LİSTESİ

Şekil 2.1 SPAR-4-SLR metodolojisi	23
Şekil 2.2 Anahtar Kelime Trendleri: Yıllara Göre Alan Grafiği	28
Şekil 2.3 Anahtar Kelime İlişkileri ve Kümelenmesi	30
Şekil 2.4 Uluslararası İş Birlikleri	33
Şekil 2.5 Üniversiteler Arasındaki Uluslararası İş Birlikleri	34
Şekil 2.6 RFM-CLV Alanında Çalışan Akademisyenler Arasındaki Uluslararası İşbirliği	35
Şekil 2.7 RFM-CLV konusunda öne çıkan akademisyenlerin yayın performanslarının yıllara göre değişimini	36
Şekil 3.1 Araştırma Tasarımı	47
Şekil 3.2 Rezervasyon ve POS işlem verilerinin filtreleme, eksik veri ayıklama ve tutarsız kayıtların çıkarılması adımlarıyla analiz için temizlenme süreci	52
Şekil 3.3 Her Bir Müşteri İçin Hesaplanan Müşteri Yaşam Boyu Değeri	59
Şekil 3.4 Lorenz eğrisi üzerinden hesaplanan Gini katsayısı, CLV dağılımındaki eşitsizliği 0.7380 olarak göstermektedir. Segment ortalamaları, A segmenti (23.82), B (1.90) ve C (1.11)	64
Şekil 3.5 Normalize Edilmiş CLV Bileşenlerinin Karşılaştırılması	65
Şekil 3.6 SHAP analiz çıktısı: Her bir özellik, tahmin üzerindeki pozitif veya negatif etkisiyle renklendirilmiş ve sıralanmıştır.	69
Şekil 3.7 CLV ve bileşenleri arasındaki korelasyon matrisi, Pearson korelasyon yöntemi kullanılarak oluşturulmuştur.	72
Şekil 3.8 Web Uygulama Modeli	79
Şekil 3.9 Uygulamaya Kullanıcı Adı ve Şifre ile Giriş Ekranı	80
Şekil 3.10 Tarih Filtreleme Alanı	81
Şekil 3.11 Rapor Filtreleme Alanı	82
Şekil 3.12 Main Sekmesi Seçiliyken CLV Kümelerine Ait Genel Durumu Gösteren Analiz Raporu Örneği	83
Şekil 3.13 Kümelerin Rezervasyonların Giriş Tarihine Göre Rezervasyon Penceresinin Ortalamasını Gösteren Grafik	83
Şekil 3.14 CLV Kümelerinin Acentalara Göre Dağılımını Gösteren Çubuk Grafik	84
Şekil 3.15 CLV Kümelerinin Pazar Segmentlerine Göre Dağılımını Gösteren Çubuk Grafik	84
Şekil 3.16 CLV Kümelerinin Seyahat Eşlikçisine Göre Dağılımını Gösteren Çubuk Grafik	85
Şekil 3.17 Giriş Tarihlerine Göre Beklenen Ortalama Kar Sıcaklık Haritası	85

Şekil 3.18 CLV Kümelerinin Oda Gelirine Göre Açılır Menüden Seçmeli Temel İstatistiki Dağılımını Gösteren Grafik	86
Şekil 3.19 CLV Kümelerinin Oda Gelirinin Solda Pansiyon Durumu Sağda Aylara Göre Dağılımını Gösteren Çubuk Grafik	86
Şekil 3.20 CLV Kümelerinin Oda Gelirine Göre RFM Kümeleri, Pazar Segmenti, Acenta, Ülke ve Seyahat Eşkeniğine olan Dağılımını Gösteren Ağaç Grafiği.....	87
Şekil 3.21 CLV Kümelerinin En Çok Rezervasyonu Olan İlk 20 Ülkenin Numerik Değişkenlere Göre Dağılım Tablosu	87
Şekil 3.22 CLV Kümelerinin Ülkelere Göre Yüzdesel Dağılımı.....	88
Şekil 3.23 CLV Kümelerinin Oda Gelirine Göre Farklı Değişkenler Üzerinde Dağılımını Gösteren Ağaç Grafiği.....	88
Şekil 3.24 Filtrelenebilir İnteraktif Tablo.....	89

TABLOLAR LİSTESİ

Tablo 1.1 Otelcilik Sektörüne Müşteri Yaşam Boyu Değeri (CLV) Yönelik Araştırmalar.....	8
Tablo 2.1 RFM ve CLV'nin Entegrasyonu Üzerine Sistematiik Literatür Taraması	38
Tablo 3.1 Rezervasyon ve Pos işlem Veri Setlerinde Yer Alana Değişkenler.....	50
Tablo 3.2 K-Means Kümeleme Performans Değerlendirme Metrikleri.....	63
Tablo 3.3 Kategorik Değişkenlerin Dağılımı ve Frekansları	67
Tablo 3.4 Numerik Değişkenlerin Tanımlı İstatistikleri	67
Tablo 3.5 XGBoost, LightGBM ve CatBoost Algoritmaları ile CLV Tahmini Performans Karşılaştırması.....	68
Tablo 3.6 RFM Segmentasyonu Sonuçları ve Küme Karakteristikleri	70
Tablo 3.7 CLV Segmentasyonu Sonuçları ve Küme Karakteristikleri	73
Tablo 3.8 CLV Kümelerine Göre Müşteri Segmentlerinin Özellikleri	75

KISALTMALAR LİSTESİ

AHP:	Analitik Hiyerarşi Süreci (Analytic Hierarchy Process)
APV:	Ortalama Satın Alma Değeri (Average Purchase Value)
AS:	Araştırma Sorularına
B2B:	İşletmeden İşletmeye
B2C:	İşletmeden Müşteriye
CAC:	Müşteri edinme maliyeti (Customer Acquisition Cost)
CatBoost:	Categorical Boosting
CL:	Müşteri Yaşam Süresi (Customer Lifetime):
CLV:	Müşteri Yaşam Boyu Değeri
CRM:	Müşteri İlişkileri Yönetimi
CV :	Cross Validation
DR:	İskonto Oranı (Discount Rate):
EFB:	Özel Özellik Paketleme
GBDT:	Gradient Boosting Karar Ağacı
GOSS:	Gradyan Tabanlı Tek Taraflı Örnekleme
K-Means:	K-ortalamlar
LightGBM:	Light Gradient Boosting Machine
LTV:	Yaşam Boyu Değer
MAE:	Ortalama Mutlak Hata (Mean Absolute Error)
ML:	Makine Öğrenmesi
OWA:	Sıralı Ağırlıklı Ortalama
Pareto/NBD:	Pareto/Negatif Binom Dağılımı
PF:	Satın Alma Frekansı (Purchase Frequency):
PM:	Kar Marjı (Profit Margin)
PSO:	Parçacık Sürüsü Optimizasyonu
RFM:	Recency-Yenilik, Frequency-Sıklık, Monetary-Parasal Değer)
RMSE:	Kök Ortalama Karesel Hata (Root Mean Squared Error)
ROI:	Yatırımların Geri Dönüşü (Return of Investments)
ROMI:	Pazarlama Yatırımlarının Geri Dönüşü
SHAP:	Shapley Additive Explanations

SPAR-4-SLR:	Sistemik Literatür İncelemelerinde Alaka Düzeyini Uygulamak İçin Yapılandırılmış Protokol
WCSS:	Küme İçi Kareler Toplamı
XAI:	Açıklanabilir yapay zeka
XGBoost:	eXtreme Gradient Boosting
YZ:	Yapay zeka



ÖZET

Bu tez çalışması, otel sektöründe müşteri davranışlarını analiz etmek amacıyla müşteri yaşam boyu değeri (CLV) ve RFM (Recency-Yenilik, Frequency-Sıklık, Monetary-Parasal Değer) modelini bir araya getiren yenilikçi bir yaklaşım sunmaktadır. Çalışmada makine öğrenmesi (ML) tekniklerini kullanarak CLV'yi davranışsal ve finansal verilerle tahmin edip açıklanabilir çözümler üretilmektedir. Böylece, rezervasyon verileri ve otel içi ekstra harcamaların entegre edilmesiyle müşteri segmentasyonu gerçekleştirilmiş ve bu segmentlere dayalı stratejik öneriler geliştirilmiştir. CLV tahminleri için XGBoost, LightGBM ve CatBoost ML algoritmaları kullanılarak karşılaştırmalı sonuçlar sunulmuştur. Model açıklanabilirliği için SHAP (Shapley Additive Explanations) analizi kullanılmıştır. Denetimsiz (RFM kümeleri için) segmentasyon teknikleri kullanılmıştır. Çalışmada CatBoost (0,93) en iyi tahmin modeli olarak öne çıkmıştır. Modele en çok katkıyı yapan özellikler ise SHAP analizi sonucunda Yenilik ve Parasal Değer gibi değişkenler olmuştur. Analizlerin görselleştirilmesi için Python Plotly ile interaktif bir görselleştirme altyapısı oluşturulmuş ve oluşturulan aplikasyon web ortamında gerçeğe alınmıştır.

Araştırmanın bulguları, yüksek değerli müşterilerin tespit edilmesi, yeni müşterilerin sadık müşterilere dönüştürülmesi ve otel içi harcamaların artırılması konularında yönetim kararlarına önemli katkılar sunmaktadır. Özellikle, Lead Time (Satın alma ve rezervasyon varış tarihi arasındaki süre), Length of Stay (konaklama süresi) ve Season (mevsim) gibi değişkenlerin müşteri davranışlarına etkisi incelenmiş ve segmentlere özgü stratejiler önerilmiştir. Ayrıca, çalışmada geliştirilen web tabanlı uygulama, otel yöneticilerine gerçek zamanlı analiz yapma ve veriye dayalı karar alma olanağı sağlayarak sektörel yeniliklere katkıda bulunmaktadır.

Bu çalışmanın sonuçları hem teorik hem de uygulamalı alanlarda önemli katkılar sağlamış olup, otelcilik sektöründe müşteri analizi ve gelir yönetimi süreçlerinde yeni bir bakış açısı sunmaktadır. Gelecekteki araştırmalarda daha geniş örneklem grupları, farklı bağlamlar ve yenilikçi teknolojilerin turizm araştırmalarına entegre edilmesi önerilmektedir.

Anahtar Kelimeler: CLV; RFM; Müşteri Yaşam Boyu Değeri; Otel Sektörü; Web Tabanlı Uygulama

SUMMARY

CUSTOMER LIFETIME VALUE PREDICTION AND MANAGEMENT IN HOTEL ORGANIZATIONS: AN INTEGRATED APPROACH WITH A WEB-BASED APPLICATION

This thesis presents an innovative approach that combines customer lifetime value (CLV) and RFM model to analyze customer behavior in the hotel industry. The study uses machine learning techniques to predict CLV with behavioral and financial data and generate explainable solutions. Thus, by integrating reservation data and in-hotel extra spending, customer segmentation is realized and strategic recommendations are developed based on these segments. Comparative results are presented using XGBoost, LightGBM and CatBoost machine learning algorithms for CLV predictions. SHAP analysis is used for model explainability. Supervised and unsupervised (for RFM clusters) segmentation techniques are used. CatBoost (0.93) emerged as the best model in the study. The features that contributed the most to the model were variables such as Recency and Monetary as a result of SHAP analysis. For the visualization of the analyses, an interactive visualization infrastructure was created with Python Plotly and the application created was taken into reality in the web environment.

The findings of the research provide important contributions to management decisions on identifying high-value customers, converting new customers into loyal customers and increasing in-hotel spending. In particular, the impact of factors such as Lead Time, Length of Stay and Season on customer behavior is examined and segment-specific strategies are proposed. In addition, the web-based application developed in the study contributes to sectoral innovations by enabling hotel managers to perform real-time analysis and make data-driven decisions.

The results of this study have made significant contributions in both theoretical and applied fields and offer a new perspective on customer analysis and revenue management processes in the hospitality industry. Future research is recommended to integrate larger sample groups, different contexts and innovative technologies into tourism research.

Key Words: CLV; RFM; Customer Lifetime Value; Hotel Industry; Web-based Application

TEŞEKKÜR / ÖNSÖZ

Bu doktora tezi ile otel sektöründe müşteri davranışlarını analiz etmek için CLV ve RFM modellerini makine öğrenmesi teknikleriyle birleştirerek davranışsal ve finansal verilerle açıklanabilir tahminler sunan ve otel sektörüne gerçek zamanlı analiz imkânı sağlayan web tabanlı bir uygulama geliştirilmiştir.

Doktora eğitimim ve tez sürecimi en verimli şekilde planlamam, titizlikle ilerletmem ve en iyi sonuca ulaştırmam konusunda bana rehberlik eden değerli danışmanım Prof. Dr. Beykan ÇİZEL'e sonsuz teşekkürlerimi sunarım.

Tez izleme sürecindeki değerli önerileri ve yapıcı yönlendirmeleriyle çalışmama değer katan Doç. Dr. Ömür TOSUN ve Dr. Öğr. Üyesi Edina AJANOVIC hocalarıma değerli katkılarından dolayı teşekkür ederim. Ayrıca tezimin savunma toplantısına katılmayı kabul eden ve olumlu katkı ve öneriler sunan Dr. Öğr. Üyesi Demet CEYLAN ve Dr. Öğr. Üyesi Çağla MCKENZIA hocalarıma en içten teşekkürlerimi sunarım.

Bu zorlu süreçte her anımda yanımda olan hem akademik yoldaşım hem de hayat arkadaşım sevgili eşim Eniser ATABAY'a, desteğinden dolayı sonsuz minnet ve sevgilerimi sunarım. Tez çalışmam süresince anlayışlarını daima hissettiren, en büyük motivasyon kaynağım olan sevgili kızlarım Alya Lina ve Fatma Gül'e en sonsuz sevgilerimi sunuyor ve doktora tezimi onlara ithaf ediyorum.

Turizm sektöründe faaliyet gösteren konaklama tesisleri ve turizm acentelerinin ihtiyaçlarına yönelik dijital işletme anlayışının altyapısını oluşturacak yazılımlar geliştiren Kod Yazılım'a, özellikle tezimin web tabanlı uygulamaya dönüştürülmesi sürecinde sağladıkları maddi ve manevi destekler için teşekkür ederim.

Prof. Dr. Şükrü Özen'e yoğun akademik ve idari görevlerine rağmen göstermiş olduğu derin anlayış ve sabrı için teşekkürü bir borç bilirim.

Doktora tezime vermiş oldukları destekten dolayı TÜBİTAK 2244- Sanayi Doktora Programı'na teşekkür ederim (Proje No: 119C158).

GİRİŞ

Dijital teknolojilerin hızla yaygınlaşması ve veri odaklı karar alma süreçlerinin iş dünyasıyla bütünleşmesi, birçok sektörde olduğu gibi konaklama sektöründe de önemli değişimlere yol açmaktadır. Bu dönüşüm, müşteri ilişkilerinin daha etkin yönetilmesini, operasyonel verimliliğin artırılmasını ve müşteri deneyimlerinin kişiselleştirilmesini mümkün kılar. Bu noktada, müşteri yaşam boyu değeri (CLV- Customer Lifetime Value), işletmelerin stratejik kararlarını yönlendiren hassas bir ölçüm olarak ön plana çıkmaktadır. CLV, bir müşterinin işletme ile kurduğu ilişki süresince sağlayabileceği toplam finansal değeri ifade etmektedir. İşletmenin amaçlarına uygun parametrelerle hesaplanan CLV, işletmelerin pazarlama stratejilerini optimize etmelerini, müşteri elde tutma oranlarını artırmalarını ve kaynak tahsisini daha verimli hale getirmelerini sağlar.

Konaklama sektöründe, müşteri beklentileri ve pazar dinamikleri hızla değişmektedir. Bu durum, CLV'nin finansal bir metrik olmanın yanında, müşteri odaklı stratejik planlamanın odağına yerleşmesini sağlamıştır. Ancak, CLV'nin doğru hesaplanması ve işletme süreçlerine entegre edilmesi durumu hem veri kalitesi hem de analitik yöntemlerin etkinliği açısından uygulamada önemli zorlukları içermektedir. Geleneksel yöntemler, karmaşık müşteri davranışlarını tam olarak yansıtmakta kısıtlı kalırken, makine öğrenmesi (ML) gibi yenilikçi yaklaşımlar bu boşluğu doldurma potansiyeline sahiptir.

Bu tez çalışması, konaklama sektörü özelinde bir CLV tahmin modeli geliştirmeyi amaçlamaktadır. Model, ML tekniklerini kullanarak müşteri davranışlarını analiz etmekte ve CLV'yi yüksek doğrulukla tahmin etmeyi hedeflemektedir. Tez kapsamında geliştirilen model, teorik bir çerçeve sunmakla kalmayıp, aynı zamanda otel işletmelerine özel olarak tasarlanmış bir web uygulaması üzerinden pratik ve dinamik bir çözüm sunmaktadır. Bu uygulama, işletmelerin müşteri segmentasyonunu iyileştirmelerine, hizmetlerini daha kişiselleştirilmiş bir şekilde sunmalarına ve gelir potansiyellerini en üst düzeye çıkarmalarına yardımcı olacaktır.

Modelde, geçmiş müşteri verilerinin analizi ve davranışsal örüntülerin tespit edilmesi yer almaktadır. Örneğin, bir müşterinin rezervasyon sıklığı, harcama tutarları ve ek hizmetleri kullanma düzeyi gibi faktörler, CLV tahminlerinde önemli rol oynamaktadır. Bununla birlikte, modelin doğruluğunu artırmak için, yalnızca finansal veriler değil, aynı zamanda müşteri demografik bilgileri ve etkileşim geçmişi gibi çeşitli veri kaynakları da dikkate alınmıştır. Bu, müşterilerin farklı segmentlere ayrılmasını ve her bir segmente özgü stratejilerin geliştirilmesini mümkün kılmıştır.

Bu tez çalışması, üç temel katkı sağlamayı amaçlamaktadır. Öncelikle, makine öğrenmesi tabanlı bir CLV tahmin modeli geliştirerek sektördeki yöntemlere yenilikçi bir alternatif sunmaktadır. İkinci olarak, bu modeli bir web uygulaması üzerinden otel işletmelerinin kullanımına sunarak teoriyi uygulama ile birleştirmektedir. Son olarak da müşteri segmentasyonunun etkinliğini artırarak, işletmelere daha stratejik ve kişiselleştirilmiş hizmetler sunma imkânı tanımaktadır.



BİRİNCİ BÖLÜM

MÜŞTERİ YAŞAM BOYU DEĞERİ'NİN KAVRAMSAL VE TARİHSEL AÇIDAN DEĞERLENDİRİLMESİ

1.1. Müşteri Yaşam Boyu Değeri Tanımları

Müşteri değeri, bir müşterinin ürün veya hizmetten maliyetine göre elde ettiği algılanan faydaları temsil eder. Müşteri yaşam boyu değeri, çalışmanın bağlamına, araştırmanın odak noktasına ve kullanılan belirli metodolojiye bağlı olarak çeşitli şekillerde tanımlanmıştır. Fornell vd.'e (2016) göre CLV, müşterilerin uzun vadeli kârlılığını vurgular ve net kâr yönüne odaklanır. Bir şirketin bir müşteriden elde ettiği gelecekteki değerin kritik bir husus olduğunu vurgulayan Fornell vd. (2016), CLV'yi bir firmanın tüm ilişkileri boyunca belirli bir müşteriden elde ettiği toplam net kârın ölçümü olarak tanımlamıştır. Birbirlerinin yerine de kullanılabilen “müşteri sermayesi” hakkında kapsamlı ve derinlemesine (Villanueva ve Hanssens, 2007) çalışmalar yapılmıştır. Kumar (2008), CLV'yi, bir müşterinin gelecekte sağlayacağı kâr akışlarının, müşterinin işlemlerine devam etme olasılığı ve hizmet maliyetleri göz önünde bulundurularak bugünkü değerine indirgenmiş hali olarak tanımlamıştır.

Yapay zeka (YZ) destekli müşteri ilişkileri bakış açısıyla daha etkili stratejiler geliştirmek için önemli bir ölçüt olarak kullanan Huang ve Rust (2024), CLV'yi bir müşteriden gelecekte elde edilmesi beklenen toplam gelirlerin bugünkü net değeri şeklinde tanımlamıştır. Bu bakış açısı, hem bir müşteriden elde edilen geliri hem de o müşteriyi edinme ve elde tutma maliyetlerini dikkate alarak CLV'nin karlılık odaklı yönüne vurgu yapmaktadır. Müşteri davranışını tahmin etmek ve pazarlama stratejilerini optimize etmek için veri analitiğini kullanan modern CLV modellerinin tahmini üzerinde çalışan Bradlow vd. (2017) CLV'den gelecekteki davranışları ve sonuçları tahmin etmek için geçmiş verileri kullanarak müşterilerin uzun vadeli değerini belirlemeye yardımcı olan bir ölçü şeklinde bahsetmiştir.

CLV'nin uzun vadeli ilişki yönetimindeki stratejik değerini vurgulayan Casas-Arce vd. (2017) ise CLV'nin sadece kısa vadeli işlemlere odaklanmak yerine müşteri ilişkisinin tüm yaşam döngüsü boyunca değeri üst düzeye çıkarmaya odaklanarak müşteri ilişkilerini yönetmek için önemli bir ölçüt olduğunu ileri sürmüştür. Doğrudan satın alımlara ek olarak müşteri etkileşimini ve kulaktan kulağa değeri de içeren genişletilmiş CLV anlayışını yansıtan Sunder vd. (2016) daha geniş bir bakış açısı sunarak CLV'yi bir müşterinin yalnızca satın alımları değil aynı zamanda yönlendirme, geri bildirim ve etkileşim potansiyelini de içeren ilişkisinin toplam süresi boyunca firmaya getirdiği değer olarak tanımlamıştır. Olivares vd. (2018), CLV'yi, bir müşterinin elde tutulma olasılığına göre ayarlanmış, ilişkiyi sürdürme ile

ilgili olası maliyetler veya olumsuzluklar dikkate alınarak hesaplanan beklenen gelecekteki gelir olarak tanımlanmış ve bu ölçütü müşteri ilişkilerinde olasılıksal tutma ve maliyet unsurlarının önemine vurgu yapmıştır.

1.2. CLV Gelişim Süreci

CLV'nin gelişim süreci, müşteri değerinin ölçülmesi ve yönetimi üzerine yapılan çalışmaların gelişimiyle ayrılmıştır. Bu süreç, temel kavramsallaştırmalardan başlayarak ML ve yapay zekâ gibi yenilikçi yaklaşımların dahil edilmesiyle zenginleşmiştir. Her dönemde, müşteri bağlılığı ve işletme stratejileri arasında bağlar kuran modeller üzerinde gelişmiştir. Bu bölüm CLV'nin gelişim sürecini, referans alınan çalışmalara dayanarak dönemlere ayrılmıştır.

1.2.1. 1990'lar: Temel Modellerin Oluşumu

Müşteri ilişkilerini yönetmede işlemsel yaklaşımdan ilişkisel yaklaşıma geçiş ihtiyacı müşteri sermayesi olarak da adlandırılan CLV, kavramsal olarak daha geniş pazarlama kavramı olan müşteri sermayesini nicelleştirmek ve ölçmek için kullanılmıştır (Berger ve Nasr, 1998). Bu dönemde uzun vadede fayda sağlamak adına kısa vadede müşterilere yatırım yapmak ve çeyreklikler veya yıl sonu karına odaklanmaktan ziyade müşteri ilişkilerine uzun vadeli bir bakış açısı benimsenmeye başlanmıştır. Bu bakış açısıyla 1990'ların sonlarına doğru pazarlamada öncelikli olarak müşterileri elde tutmaya odaklanılmış ve ek hizmetler çapraz satışlar yoluyla değer yaratmanın müşteri ilişkileri yönetiminin önemli bir yönü olduğunun farkına varılmıştır (Verhoef vd., 2001).

1990'lı yıllarda, müşteri odaklı pazarlama yaklaşımlarının yükselişiyle birlikte, özellikle ilişki pazarlaması (relationship marketing) paradigması, müşteri memnuniyeti ile elde tutma arasında bir bağlantının araştırılması ihtiyacı uyandırmıştır (Bolton, 1998). Böylece ilişki pazarlamasında CLV'nin müşteri elde tutmanın uzun vadeli faydalarını vurgulayan Bolton'un (1998) dinamik modeli, uzun süreli müşteri ilişkilerinde memnuniyetinin önemini belirterek CLV ölçümü için temel oluşturmuştur.

Rust vd. (1999) CLV kavramını bir adım daha ileriye taşıyarak sadece bir memnuniyet göstergesi olmaktan ziyade aynı zamanda gelir elde etme potansiyeliyle bağlantılı olarak değerlendirilmesi gerektiğini öne sürmektedir. Bununla birlikte, Rust vd. (1999) müşteri beklentilerini gelir elde etmeyle ilişkilendirerek CLV kavramını finansal boyuta daha da yaklaştırmıştır.

Bu dönemdeki araştırmacıların CLV'nin kavramsal çerçevesinin belirlenmesi üzerinde çalıştıkları görülmektedir. CLV müşteri sermayesi kavramından ayrılmaya başlayıp, ilişki

pazarlamasında odağında kendine yer edinmiştir. Bunlara ek olarak bu dönemde CLV çalışmalarında en önemli çabalardan biri de CLV'nin hesaplanması üzerinedir.

1.2.2. 2000'lerin Başı: CLV'nin Ölçülmesi ve Uygulama Alanlarının Kullanılması

CLV ölçülebilir bir ölçüt haline 2000'lerin başında gelmiştir. Berger ve Bechwati (2001), bu dönemde yöneticilerin yargılarını ve tahminlerini gerçek modellemeye girdi olarak kullanmış; edinme ve elde tutma arasındaki promosyon miktarının tahsisine ve her harcama kategorisi için farklı promosyon seçeneklerine odaklanmıştır. Ayrıca, müşteri getirisini en üst düzeye çıkarmak için stratejiler geliştirmiştir.

Verhoef vd. (2001) çapraz satın almaların CLV'yi olumlu etkilediğini ortaya koymuştur. Stahl vd. (2003) CLV'yi paydaşların değerine bağlayarak stratejik karar alma mekanizmasında kullanmıştır. Müşteri sadakati kavramının, her yerde bulunmasını dikkat çekici bulan Kumar ve Shah (2004), sadakati karlılığa ve müşteri yaşam boyu değeri gibi ileriye dönük metriklere bağlamaya, bireysel müşteri düzeyinde eş zamanlı olarak sadakat ve karlılık oluşturmak ve bunu sürdürmek için kavramsal bir çerçeve önermiştir.

CLV araştırmalarının segmentasyon ve kişiselleştirilmiş pazarlamaya yönelmesiyle birlikte, Hwang vd. (2004), bir müşterinin geçmiş kâr katkısını (cari değer), potansiyel faydasını ve ayrılma olasılığını (müşteri sadakati) dikkate alarak müşteri değerini analiz etmiş ve müşterileri değerlerine göre segmentlere ayırmayı önerdiği modelini telekom sektöründe uygulamıştır.

1.2.3. 2005-2007: CLV'nin Dönüşümü Yönlendiren Stratejik Yaklaşımlar ve Sektörel Derinleşme

Önceki dönemlerde CLV'nin kavramsal çerçevesi ve ölçülmesine yönelik bileşenlerin üzerinde durulmuş ve sınırlı uygulamalarla bu ölçümler denenmiştir. 2005-2007 dönemi ise CLV'nin karmaşık, çalışılan sektöre özgü ve çok yönlü yaklaşımlarla ele alındığı bir süreç olarak ön plana çıkmaktadır. Bu dönemde, CLV finansal bir metrik olmanın ötesinde, müşteri ilişkileri yönetimi (CRM- Customer Relationship Management), ürün öneri sistemleri ve müşteri segmentasyonu gibi stratejik alanlarda kilit bir aracı rolü üstlenmiştir.

Ryals ve Knox (2005), CLV'nin risk ayarlı bir versiyonu olan ekonomik değer kavramını geliştirip, risk yönetimini CLV'ye entegre ederek müşteri ilişkileri yönetimine farklı ve yenilikçi bir boyut getirmiştir. Roemer (2007) ise çevresel riskleri ve tedarikçilerin bu risklere karşı esnekliklerini dikkate alan bir CLV sınıflandırması önermiştir. Liu ve Shih (2005), yenilik, sıklık ve parasal değer (RFM) değişkenlerinin sektöre özgü ağırlıklandırmalarını kullanarak, Analitik Hiyerarşi Süreci (AHP- Analytic Hierarchy Process)

ile veri madenciliği tekniklerini birleştirmiş ve CLV tabanlı ürün öneri sistemleri geliştirmiştir. Wang ve Hong (2006) ise müşteri kârlılığını yönetmek için dinamik bir veri madenciliği sistemiyle, müşteri davranışındaki değişimleri gerçek zamanlı olarak gözlemleyerek pazarlama stratejileri anlık optimizasyonuna olanak sağlamıştır.

Fader vd. (2007), Pareto/Negatif Binom Dağılımı (Pareto/NBD) modelini kullanarak toplu verilerle CLV hesaplama yöntemlerini geliştirmiş, müşteri yaşam döngüsü süreçlerini daha ayrıntılı bir şekilde analiz ederek şirketlerin uzun vadeli müşteri ilişkileri yönetimine çözüm sunmuştur. Kim vd. (2006), telekomünikasyon şirketi üzerinden CLV tabanlı müşteri segmentasyonu ile kârlı müşterilere yönelik özelleştirilmiş stratejilerin şirket performansına katkısını ortaya koyarken, Haenlein vd. (2006) tarafından geliştirilen “kârsız müşterilerden vazgeçme opsiyonu” gibi iddialı bir yaklaşımla esneklik unsurlarıyla, CLV hesaplamalarını daha stratejik hale getirmiştir. Kumar (2007), CLV'nin tanımı, ölçüm yöntemleri ve müşteri odaklı stratejilerdeki rolünü inceleyerek hem işletmeden işletmeye (B2B) hem de işletmeden müşteriye (B2C) bağlamında CLV'nin uygulanabilirliğini çalışarak, bu süreçte karşılaşılan zorluklara değinmiştir.

1.2.4. 2008-2010: Operasyonel Uygulamalar ve İleri Düzey Segmentasyon

Bu aralıktaki önemli ilerleme, müşteri segmentasyonunda çok faktörlü modellerin geliştirilmesidir. Kumar vd. (2008) ve Fader ve Hardie (2009) çalışmalarıyla CLV'nin operasyonel önemine işaret ederken Shih ve Liu (2008) ise kişiselleştirilmiş öneriler için segmentasyon ve işbirlikçi filtreleme ile CLV uygulamalarını zenginleştirmiştir. Benzer şekilde, Li vd. (2011), segmentasyonda öngörücü analitiği vurgulayarak müşteri yönetim stratejilerini kişiselleştirmek için kümeleme algoritmaları uygulamıştır. İşbirlikçi filtrelemeyi CLV ölçümleriyle entegre eden Albadvi ve Shahbazi (2010), müşteri kârlılığıyla uyumlu ürünleri önermek için derecelendirmeye dayalı işbirlikçi filtrelemeyi CLV ile modellemiştir. Bu yaklaşım, müşteri değerini iş hedefleriyle ilişkilendirerek ürün öneri sistemlerini geliştirdiği için önemli bir değişimi göstermektedir.

Bu gelişmelere paralel olarak CLV'nin bağlamsal kapsamı da genişlemiştir. Söz gelimi, Kim vd. (2010), Kore'de lüks markalara yönelik müşteri tutumları ile CLV arasındaki bağlantıyı incelerken, Li ve Chang (2010) CLV'yi Tayvan'ın bankacılık (kredi) sektörü üzerinde çalışmıştır. Bu çalışmalar, CLV'nin farklı endüstriler ve araştırma alanlarında uygulanabilirliğini göstererek, uygulamasını geleneksel pazarların ötesine taşımıştır.

1.2.5. 2011-2015: Makine Öğrenmesi ve Büyük Veri Etkisi

ML'in yükselişi, CLV araştırmalarını önemli ölçüde etkilemiştir. Tsai vd. (2013), CLV tahmini için hibrit ML tekniklerini performansını karşılaştırırken, Jing ve Lewis (2011) veri odaklı yaklaşımların uyarlanabilirliğini göstermiştir. Büyük verinin iş problemlerini çözmek için kullanılması anlayışının yaygınlaşmasıyla büyük veri kümelerinden içgörüler üretmesi, CLV'nin tahmin gücünü artırmıştır. Bu gelişmeler araştırmacıların CLV çerçevelerini, karar alma sürecinde kullanmasında daha da aktif hale getirmiştir.

Chan vd. (2011) ürün geliştirmede müşteri değerini tahmin etmek için bir sistem geliştirirken, Safari ve Safari (2012) CLV'yi bankacılık sektöründe uygulayarak pazarlama stratejilerini uzun vadeli iş hedefleriyle uyumlu hale getirmedeki önemini göstermiştir. Chen ve Chen (2014) ise CLV çalışmalarını yüksek öğrenim sektöründe uygulayarak, geleneksel iş bağlamlarının ötesindeki önemini vurgulamıştır.

2015 yılında, müşteri segmentasyonu ve öngörücü analiz için daha gelişmiş yöntemler çalışılmıştır. Moro vd. (2015) banka mevduat aboneliklerinin tahminini geliştirmek için sinir ağlarını kullanırken, Permana vd. (2015) ise Markov Zinciri modellerini sağlık sigortası verilerine uygulayarak, dinamik modellerin zaman içinde CLV'yi nasıl tahmin edebileceğini göstermiştir. Sunder vd. (2016), özel tüketimde CLV tahminlerini iyileştirmek için RFM (Yenilik, Sıklık, Parasal değer) analizini ML birleştirmiştir.

1.2.6. 2016-2020: Yapay Zeka ve Dijitalleşme ile Yeni Yönelimler

CLV tahminindeki yenilikçi gelişmeler, ML'in, büyük veri analitiği ve YZ'nin entegrasyonu ile yönlendirilmiş ve sektörler genelinde CLV tahminlerini geliştirmiştir. Söz gelimi, hedeflenen pazarlama için yüksek değerli müşterileri belirleyerek müşterilerini büyük veriyi, pazar segmentasyonunda CLV kümelemeyle birleştirilmesinin, müşteri hedeflemesini nasıl iyileştirdiği gösterilmiştir (Yoseph vd., 2020; Hasheminejad vd., 2020). Büyük veri ile pazar segmentasyonunun birleştirilmesi CLV'de etkili müşteri hedeflemesi stratejilerini geliştirmiştir.

AI, CLV tahmininde devrim yaratarak daha doğru müşteri davranışı tahminine olanak sağlamıştır. Kivrak ve Akar (2020) çalışmalarında, telekomünikasyon alanında AI odaklı müşteri kaybı tahmin modellerinin işletmelerin müşteri elde tutmayı tahmin etmesine ve yönetmesine nasıl yardımcı olduğunu aktarmıştır.

1.2.7. 2021 ve Sonrası: Sosyal Medya, Mobil Teknoloji ve Açıklanabilir Yapay Zeka

Açıklanabilir yapay zeka (XAI) alanındaki gelişme, CLV modellerini daha şeffaf hale getirerek işletmelerin müşteri sadakatini etkileyen faktörleri daha iyi anlamalarını sağlamıştır.

(De Marco vd., 2021). Bu gelişmeler, CLV modellerinin karar alma süreçlerinde daha etkin kullanılmasını olanak tanımıştır.

CLV modelleri, müşteri sermayesi gibi diğer temel performans göstergeleriyle (KPI'ler) entegre edilerek stratejik karar almayı desteklemiştir. Örneğin, Dandis vd. (2022) tarafından önerildiği gibi, CLV'yi davranışsal ve tutumsal verilerle birleştirmek, müşteri sadakati hakkında daha derin bir anlayış sağlamaktadır. Ayrıca bu yaklaşım uzun vadeli değer oluşturmada müşteri katılımının önemini vurgulamaktadır.

Araştırmalar daha sofistike analitik araçları benimsedikçe, kişiselleştirilmiş pazarlama ve gerçek zamanlı veri entegrasyonu gibi trendler, CLV modellemesinin geleceğini şekillendirecektir (Feng vd., 2024; Sood ve Sharma, 2021). Bu bağlamda, CLV'nin yalnızca gelir tahmininden ziyade, müşteri ilişkilerinin optimize edilmesi ve marka değeri üzerinde önemli etkiler yaratan bir stratejik araç olarak kullanımı da giderek daha fazla değer kazanacaktır.

1.3. Otel Sektöründe CLV'nin Önemi

Otel sektörü, uzun vadeli müşteri ilişkileri kurma, kişiselleştirilmiş deneyimleri önceliklendirme ve tekrarlanan rezervasyonları en üst düzeye çıkarma konusundaki çabalarıyla benzersiz konumdadır. Bu bağlamda, CLV, otelcilerin bireysel misafirlerinin ekonomik potansiyelini anlama ihtiyacının yanı sıra pazarlama, operasyonlar ve gelir yönetimi genelinde stratejileri optimize etmelerine de yardımcı olan önemli bir ölçüttür.

Tablo 1.1 Otelcilik Sektörüne Müşteri Yaşam Boyu Değeri (CLV) Yönelik Araştırmalar

Yazar	Başlık	Ana Bulgu	Araştırma Çıkarımları
Wu vd., (2018)	Co-creating value with customers: A study of mobile hotel bookings in China	- Dijital platformlar, müşteriyle ortak değer yaratmada ve CLV'yi artırmada etkilidir. - Mobil uygulamalarda kişiselleştirme, müşteri sadakatini güçlendirmektedir.	Dijital araçlar, otel işletmeleri için müşteri etkileşimlerini artırmada ve uzun vadeli değer yaratmada stratejik avantaj sağlayabilir.
Kim vd., (2018)	Calculating tourists' customer equity and	- CLV, otel yatırım getirilerini (ROI) maksimize etmek için	Gelir yönetimi stratejilerinde CLV odaklı yaklaşımlar, işletmelere

	maximizing the hotel's ROI	etkili bir araçtır. - Yüksek gelir getiren müşterilere hedefli kampanyalar, finansal performansı artırır.	müşteri değerini artırma ve segmentasyon konusunda rehberlik eder.
Manosuthi vd. (2021)	Causal-predictive model of customer lifetime/influence value: mediating roles of memorable experiences and customer engagement in hotels and airlines	Unutulmaz deneyim, çalışan bağlılığı ve hizmet inovasyonu ile müşteri bağlılığı arasındaki ilişkiye tam aracılık etmektedir. Hizmet inovasyonu ve müşteri bağlılığı, CLV ve müşteri etki değeri üzerinde en güçlü belirleyicilerdir.	Müşteri bağlılığını ve finansal değeri artırmak için işletmelerin hizmet inovasyonu ve çalışan bağlılığını, unutulmaz deneyimler yaratacak şekilde yönetmeleri gerekmektedir.
Chung vd. (2022)	Mining Consumer Minds: Downstream Consequences of Host Motivations for Home-Sharing Platforms	- CLV, müşteri memnuniyeti ve sadakatini artıran stratejiler geliştirmede önemlidir. - Müşteri etkileşimleri, uzun vadeli değer yaratımı sağlar.	CLV, sadece otelcilik değil, ev paylaşımı gibi alternatif konaklama sektörlerinde de müşteri ilişkilerini güçlendirmek için kullanılabilir.
Valentini vd. (2024)	From redesign to revenue: Measuring the effects of servicescape remodeling on customer lifetime value	- Hizmet ortamındaki stratejik değişiklikler, müşteri sadakatini ve gelirleri artırır. - Hizmet tasarımı, CLV ile uyumlu stratejiler geliştirmenin bir yolu olabilir.	Hizmet ortamı iyileştirmeleri, müşteri deneyimini artırarak işletmelerin uzun vadeli sadakat ve kârlılık hedeflerine ulaşmasına yardımcı olur.

Otel işletmeleri, misafir sadakati ve uzun vadeli ilişkilerin öneminin farkına varmakta, bu bağlamda CLV, pazarlama stratejilerinin temelini oluşturmakta ve rekabetçi pazarda sürdürülebilir büyümenin çözümünü sunmaktadır (Manosuthi vd., 2021). Özellikle artan sosyal medya etkileşimleri ve misafir geri bildirimleri gibi veri kaynakları, CLV modellerinin otel işletmelerinin misafir ilişkilerini kişiselleştirmesine olanak tanımaktadır.

Tablo 1.1’de Otel işletmeleri özelinde yapılmış örnek çalışmalar incelendiğinde bu alanda yapılmış çalışmaların yeni ancak sayısının oldukça kısıtlı olduğu görülmüştür. Wu vd. (2018) çalışmalarında, mobil otel rezervasyonları bağlamında CLV'nin misafir değeri yaratmada önemli bir araç olduğunu vurgulanmış ve araştırma, misafir etkileşimi ve geri bildirimleri ile değer yaratma sürecini modelleyerek, otellerin hizmetlerini daha fazla misafir dostu hale getirmeleri gerektiğini önermiştir.

Kim vd. (2018) otel yatırımlarının geri dönüşünü (ROI- Return of Investments) maksimize etmeye yönelik çalışmaları, CLV'nin ekonomik faydalarına değinmekte ve CLV odaklı stratejilerin otel gelirlerini artırabileceğinin ve pazarlama yatırımlarının etkinliğini optimize edebileceğinin altını çizmektedirler. Özellikle, yüksek gelir potansiyeline sahip misafirlere yapılan hedefli pazarlama kampanyaları, otel işletmelerine uzun vadede hem misafir memnuniyeti hem de finansal verimlilik sağlamaktadır. CLV'nin sadece pazarlama kararlarında değil, aynı zamanda fiziksel hizmet tasarımı da önemli bir kriter olduğunu ortaya koyan Valentini vd. (2024) hizmet ortamının yeniden tasarımının CLV üzerindeki etkilerini incelemiş ve hizmet ortamındaki iyileştirmelerin misafir sadakatine ve gelir artışına doğrudan katkı sağladığını tespit etmiştir. Chung vd. (2022)'nin, ev paylaşım platformlarına yönelik araştırması ise ev sahiplerinin motivasyonları ve misafir davranışları, CLV'nin farklı konaklama türlerinde nasıl optimize edilebileceğine dair değerli bilgiler açığa çıkarmıştır. Çavdar ve Ferhatosmanoğlu (2018)'nin çalışması, havayolu sektöründe yapılan misafir verilerini analiz ederek sosyal ağ bilgilerinin CLV hesaplamalarına dahil ederek farklı bir bakış açısı kazandırmaktadır. Bu çalışma Otelcilik sektörüne uyarlandığında, bu metodoloji, müşteri segmentasyonu ve hedefleme stratejilerini daha etkin hale getirebilir.

1.4. CLV Modelleri ve Yaklaşımları

CLV, müşteri ilişkilerini anlamak ve optimize etmek amacıyla farklı modellerle geliştirilmektedir. Bu modeller, basit hesaplamalardan karmaşık stokastik ve ML temelli yöntemlere kadar geniş bir şekilde incelenmektedir. Bu bölümde, farklı CLV modelleme yaklaşımları ele alınacaktır.

1.4.1. Basit CLV Modeli

Basit CLV modelleri, müşteri değerini tahmin etmek için kullanılan en temel yaklaşımlar arasında yer almaktadır. Bu modeller, müşteri ilişkilerinden kaynaklanan finansal değeri öngörmek amacıyla temel metrikler üzerine inşa edilmiştir. Gelir, maliyet ve müşteri kayıp oranı gibi ölçütleri temel alarak, müşterinin yaşam süresi boyunca sağladığı toplam getiriden, kazanım ve operasyonel maliyetler düşülerek kolay bir hesaplama yapılmaktadır (Berger ve Nasr 1998). Özellikle veri altyapısının kısıtlı olduğu işletmeler için başlangıç seviyesinde bir araçtır.

Berger ve Nasr (1998) tarafından önerilen temel basit CLV modeli, müşteri başına ortalama gelir ve elde tutma oranının bir çarpımı şeklinde hesaplanır. Formül şu şekildedir:

$$CLV = \frac{Gelir \times Elde Tutma Oranı}{1 - Kayıp Oranı} - Müşteri Edinme Maliyeti$$

Bu formülasyonda, müşteri başına düşen ortalama gelir, elde tutma oranı ve kayıp oranı gibi değerlerin sabit olduğu varsayılır. Ancak, modelde müşteri davranışlarının dinamikliği ve zaman içindeki değişkenliği göz ardı edilerek basit bir tahmin mekanizması oluşturulmuş olmaktadır. Berger ve Nasr (1998)'ın çalışması, bu tür modellerin genelleştirilebilirliğini artırma konusundaki önemi vurguladığı gibi CLV'nin hesaplama yönüyle ilgili çalışmaların eksikliğine de değinmiştir.

Basit CLV modelleri, karmaşık veri altyapısına ihtiyaç duymazken müşteri değerini hızlı ve pratik bir şekilde tahmin edebilen yöntemlerdir. Özellikle sınırlı veri toplama imkanına sahip alanlar için düşük maliyet avantajı sunar. Genellikle perakende sektöründe ürün bazlı gelir tahminleri ya da abonelik modellerinde müşteri başına düşen ortalama gelir hesaplamalarında kullanılır. Sood ve Sharma (2021), Hindistan telekom hizmetlerinde dijital etkileşim ve CLV ilişkisini araştırırken basit modellerden yaralandığı görülmüştür. Benzer şekilde, Valentini vd. (2024), hizmet alanlarının yeniden tasarımı çevresel değişikliklerin CLV üzerindeki etkisini bu modellerle çalışmıştır.

Bu modellerin hızlı sonuç üretme ve kolay uygulanabilirlik gibi avantajları bulunsa da genelleştirme sorunları ve bireysel müşteri farklılıklarını dikkate alamazlar. Bu bağlamda Gupta vd. (2006), basit CLV modellerinin uzun vadeli stratejik kararlarda yetersiz kalabileceğini belirtmiştir.

1.4.2. Deterministik Modeller

Deterministik modeller, CLV tahmin etmek için sabit parametrelere ve varsayımlara dayalı bir yaklaşım benimseyen yöntemlerdir. Bu modeller, genellikle müşteri davranışını öngörmek ve stratejik kararlar almak için kullanılır.

CLV analizi bağlamında deterministik modellerin kullanımına yönelik örnek çalışmaların literatürde yer aldığı görülmektedir. Mirzaei vd. (2016), marka sağlığı ile müşteri değerini sabit parametrelerle ilişkilendiren çalışmalarında regresyon analizleri uygulamıştır. Estrella-Ramon vd. (2013), bankacılık sektöründe müşteri segmentasyonu için ortalamalara dayalı hesaplama tekniklerinden yararlanmıştır. Casas-Arce vd. (2017), sabit metrikler üzerinden ileriye dönük tahminler üzerinde çalışırken Huang ve Rust (2017), teknoloji temelli hizmetlerin etkisini sabit parametrelerle modellemiştir. Olivares vd. (2018) ise fiyatlandırma stratejilerinin sadakat üzerindeki etkisini deterministik teknikler kullanarak analiz etmiştir.

1.4.3. Stokastik Modeller

Stokastik modeller, CLV hesaplamalarında belirsizlik ve değişkenliği modellemek için kullanılmaktadır. Bu modeller, müşteri davranışlarının rastgele doğasını dikkate alarak gelecekteki değerlerin tahmin edilmesine olanak sağlamaktadır. Özellikle müşteri bağlılığı, segment dinamikleri ve sözleşmesiz ortamlardaki müşteri etkileşimleri gibi belirsiz senaryolarla ele alınmaktadır. Literatürde CLV’de stokastik modellerle çalışan makalelere rastlanmaktadır.

Stokastik modellere sahip CLV analizlerinde belirsizlikleri ele alarak daha hassas tahminler elde edilmek amaçlanır. Örneğin, Lemmens ve Gupta (2020), müşteri kaybını ve bunun kârlılık üzerindeki etkilerini analiz ederken Bekamiri vd. (2020) ise bankacılık sektöründe müşterilerin gelecekteki davranışlarını tahmin etmek için stokastik süreçleri modellemiştir. Bu tür modeller, özellikle müşteri davranışlarının öngörülemez olduğu durumlarda kullanılmaktadır. Mosaddegh vd. (2021) müşteri segmentleri arasındaki CLV dinamiklerini öngörmek için stokastik modeller kullanırken, Matsuoka (2021) ise Markov zinciri modelini kullanarak müşteri sermayesindeki varyansı zaman içinde değerlendirmiştir. Xue vd. (2020) mobil ödeme gibi sözleşmesiz ortamlarda müşteri eşitliğini difüzyon modellemeleri ile çalışmıştır.

1.4.4. Regresyon Modelleri

Regresyon modelleri, CLV’yi tahmin etmek için kullanılan istatistiksel yöntemlerdir. Bu modeller, bağımlı değişken olan CLV’yi bağımsız değişkenlerle açıklayarak gelecekteki müşteri değerini belirlemeye yardımcı olmaktadır. Regresyon modelleri, veri yoğunluğu ve doğrusal ilişkileri modelleme kabiliyeti nedeniyle özellikle tercih edilmektedir.

Yu vd. (2020), promosyonel ödüllerin müşteri davranışlarını nasıl etkilediğini analiz etmek için regresyon analizi kullanmışlardır. Seyedin vd. (2021), bankacılık sektöründe marka değeri ve CLV arasındaki ilişkiyi incelemiş ve regresyon modelleriyle bu etkileşimi

değerlendirmiştir. Heldt vd. (2021), geleneksel RFM modellerini genişleterek ürün bazlı CLV tahminine odaklanmış, regresyon analiziyle ürünlerin müşteri değeri üzerindeki etkisini ölçmüştür. Meire vd. (2019) ise pazarlama içeriğinin müşteri etkileşimi ve CLV üzerindeki rolünü analiz etmiştir. Son olarak, Kivrak ve Akar (2020) sosyal medya etkileşimlerinin telekomünikasyon sektöründeki CLV üzerindeki etkilerini değerlendirmek için regresyon modelleri kullanmıştır.

1.4.5. Makine Öğrenmesi Modelleri

ML modelleri, gelişmiş veri işleme teknikleriyle CLV'yi tahmin ve analiz etmektedir. Bu modeller, dinamik, büyük ölçekli ve karmaşık veri kümelerini işleme yetenekleri nedeniyle özellikle büyük veri analitiği için uygundur. Finansal ve finansal olmayan verilerdeki gizli kalıpları keşfetmek güçlü yanlarındandır.

ML modellerine örnek olan çalışmalardan, Kumar vd. (2018), paylaşım ekonomisinde müşterilerin gelecekteki değerini tahmin etmek için ML algoritmalarıyla çalışmıştır. Çavdar ve Ferhatosmanoğlu (2018), sosyal ağ verilerini bütünleştirerek havacılık sektöründe müşteri değerini analiz etmek için ML tekniklerini kullanmıştır.

Müşteri etkileşimlerini derinlemesine anlamak ve kişiselleştirilmiş stratejiler oluşturmak için ML önemli yöntemdir. Bu amaçlar doğrultusunda ML modellerini, Chiang vd. (2018), marka kişiliği ve menşe ülkenin müşteri davranışlarına etkisini araştırmak için kullanırken, Yang vd. (2018) ise müşteri yorumlarını veri madenciliği yöntemiyle analiz ederek tekrar satın alma davranışını tahmin etmek için kullanmıştır. E-ticaret sektöründe, Jasek vd. (2019) finansal olmayan verilerle CLV tahmin etmek için ML tekniklerini uygulamıştır.

1.4.6. LTV (Yaşam Boyu Değer) Modelleri

LTV (Yaşam Boyu Değer) modelleri, müşterilerin bir işletme için uzun vadede sağlayacağı toplam değeri tahmin etmeyi amaçlamaktadır. Bu modeller, müşteriyle olan ilişkinin gelecekteki kazançlarını hesaplayarak stratejik kararlar için önemli içgörüler elde etmeyi amaçlamaktadır.

Müşteri eşitliği tahmini çalışan Silveira vd. (2017), alternatif yaklaşımları karşılaştırmış ve bu süreçte uzun vadeli müşteri değerine odaklanmıştır. LTV, CLV'ye stratejik bir perspektifle yaklaşmaktadır. Bu bağlamda, Drea vd. (2017), Baseball sezon biletleri üzerinden müşteri değerini ölçerken CLV yaklaşımını uygulayarak, müşteri ilişkilerinin uzun dönemli karlılığına dikkat çekmiştir. İki taraflı pazarların kullanıcı davranışlarını ve uzun vadeli etkilerini anlamak için Zhou vd. (2020) LTV modellemesini benimsemiştir. Buy-till-you-die modeli ile dikkat çeken Kim vd. (2024) ise mobil müşterilerin uzun vadeli değerini tahmin

etmiştir. Majid vd. (2022), CLV'yi, pazarlama stratejilerinde uzun vadeli değeri maksimize eden bir ölçüt olarak kullanmıştır.

1.5. CLV Bileşenleri

CLV müşteri ilişkilerini anlamak ve optimize etmek amacıyla kullanılan çok boyutlu bir ölçümdür (Kumar ve Shah, 2004). CLV, müşteri edinme maliyeti, karlılık, müşteri elde tutma ve satın alma davranışını birleştirerek işletmelere müşteri katkılarını bütünsel bir şekilde sunmaktadır (Venkatesan ve Kumar, 2004). Bu bileşenlerin analizi, kaynakları verimli bir şekilde tahsis etmeyi, müşteri memnuniyetini artırmayı ve uzun vadeli karlılığı maksimize etmeyi sağlamaktadır (Blattberg vd., 2009). Müşteri edinme ve elde tutma stratejilerinin dengelenmesi, işletmelerin hem maliyetler hem de müşteri değeri açısından önemli kararlar almalarını sağlamaktadır (Venkatesan ve Kumar, 2004). Bu bileşenlerin bir araya gelmesi, işletmelere etkili, sürdürülebilir müşteri ilişkileri kurma fırsatı sunmaktadır.

1.5.1. Müşteri Edinme Maliyeti

Müşteri edinme maliyeti (CAC- Customer Acquisition Cost), potansiyel müşteriye çekmek ve aktif bir alıcıya dönüştürmek için gereken toplam harcamayı ifade etmektedir. İşletme özelinde değişen bu maliyetler, pazarlama, reklamcılık, satış faaliyetleri, operasyonel giderler ve hatta teknolojik altyapı dahil olmak üzere çok çeşitli maliyetleri kapsayabilmektedir.

Bu alanın öncü çalışmasında Bolton (1998), müşteri edinme maliyetine dair doğrudan bir atıfta bulunmamaktadır; fakat, müşteri ilişkilerinin sürdürülmesi ve memnuniyetin artışı gibi müşteri edinme maliyetlerinin dolaylı etkilerini tartışmaktadır. Benzer şekilde Rust vd. (1999) da müşteri beklentileri ve hizmet kalitesinin dolaylı olarak müşteri edinme maliyetinin nasıl etkilenebileceği konusunda bir model geliştirmiştir. Kumar ve Shah (2004) ise müşteri edinme ve elde tutma stratejileri arasında dengenin sağlanması gerektiğinin önemi üzerinde durmaktadır.

Müşteri edinme maliyetleri, ilişkilerde değer yaratma stratejilerinin bir parçası olarak ele alınmasına rağmen açık bir şekilde CAC'nin ölçümü ve hesaplanması üzerine odaklanılmamış bunun yerine, müşteri ilişkileri yönetiminde, müşteri edinmenin genel etkileri incelenmiştir (Ryals ve Holt, 2007). Roemer (2007) CLV'yi farklı ilişki türleri bağlamında sınıflandırırken, müşteri edinme maliyetlerinin özellikle yüksek değerli müşteriler için önemli olduğuna dikkat çekmiştir. Benzer şekilde Kumar vd. (2010), müşteri yönlendirmeleri üzerine odaklanarak, müşteri edinim maliyetini düşük tutmanın yollarını araştırmış, yönlendirme yoluyla kazanılan müşterilerin çoğunlukla daha yüksek CLV'ye sahip olduğu ve bu yöntemin müşteri edinim maliyetlerini düşürdüğü vurgulanmıştır. Glady vd. (2009), müşteri edinme

maliyetlerinin tahmininin CLV üzerindeki etkisini özellikle, Pareto/NBD modelinin müşteri edinme stratejilerinde maliyet etkinliğini artırmak için nasıl uygulanabileceği araştırmıştır. Petersen ve Kumar (2009) müşteri edinme maliyetlerinin yüksek olduğu senaryolarda ürün iade oranlarının CLV üzerindeki etkisini ölçmüş ve CAC'ı müşteri tutundurma stratejileri için bir metrik olarak ele alınmıştır.

Jamison ve Snow (2014)'a göre müşteri edinme maliyetini optimize etme amacıyla IoT'nin sağladığı hızlı veri toplama ve analiz yetenekleri, yeni müşterilerin daha düşük maliyetle kazanılmasını sağlamaktadır. Kumar ve Pansari (2016), müşteri edinme maliyetinin perakende sektörü bağlamında kültürel ve ekonomik farklılıklar üzerindeki etkilerini değerlendirmiş ve CAC'nin CLV üzerindeki etkilerini analiz ederek daha geniş bir pazarlama stratejisi geliştirilmesine katkı sağlayacak çıkarımlarda bulunmuştur.

CAC, müşteri edinim süreçlerinin toplam maliyeti olarak ele alınmıştır. Böylece bu maliyetin stratejik olarak azaltılmasının uzun vadeli müşteri kârlılığını artırdığı (Ben Rhouma ve Zaccour, 2018) ve hangi müşteri segmentlerinin daha kârlı olduğunu belirlemek için kullanışlı bileşen olduğu vurgulanmıştır (Nemati vd., 2018).

1.5.2. Müşteri Kârlılığı

Müşteri kârlılığı, bir müşterinin bir işletmeye net finansal katkısını, ürettikleri gelirden ilişkili maliyetleri düşerek hesaplanan bir ölçümdür. Sadece brüt geliri ölçen geleneksel ölçümlerin aksine, müşteri kârlılığı net etkiye odaklanır ve her müşterinin organizasyona getirdiği değere dair içgörüler sunmaktadır (Kumar ve George, 2007). Bu bileşen, işletmelerin yüksek değerli müşteri segmentlerine öncelik vermelerine, kaynakların verimli bir şekilde tahsis etmesine ve getirileri en üst düzeye çıkarmak için hedefli pazarlama stratejileri tasarlamasına yardımcı olduğu için CLV'nin odağında yer alır.

Berger ve Bechwati (2001), promosyon bütçelerinin müşteri kârlılığını maksimize edecek şekilde tahsis edilmesi gerektiğini ele almış, Stahl vd. (2003) ise müşteri kârlılığı ile paydaş değeri arasındaki ilişkiyi analiz ederek, bu kârlılığın şirketlerin finansal başarısına etkisini incelemiştir.

Fader vd. (2007), müşteri kârlılığını en kârlı müşteri segmentlerini belirlemek için modeller geliştirirken; Kumar ve George (2007) ise müşteri segmentasyonunun kârlılık üzerindeki etkisine dikkat çekerek, kârlı müşterilerin belirlenmesi ve yönetilmesinin önemini vurgulamıştır. Musalem ve Joshi (2009), müşteri ilişkilerine yapılan yatırımların kârlılığa etkisini analiz ederken, Persson ve Ryals (2010) ise müşteri kârlılığını, müşteri varlıklarının bir parçası olarak ele almıştır.

Moro vd. (2015), müşteri yaşam boyu değerini yapay sinir ağlarıyla iyileştirerek doğru grupların hedeflenmesiyle kârlılığı artırılması konusuna yoğunlaşırken, Silveira vd. (2017), farklı yöntemlerin kârlılık üzerindeki etkilerini karşılaştırmıştır. McCarthy ve Fader (2018), halka açık şirketlerde müşteri bazlı kurumsal değerlendirme çalışmalarında müşteri kârlılığını temel almış, Segarra-Moliner ve Moliner-Tena (2022), müşteri sadakati davranışlarının kârlılığı artırdığını vurgularken, Dandis vd. (2023), marka deneyimi ve müşteri bağlılığının finansal sonuçlara katkısını değerlendirmiştir.

1.5.3. Müşteri Sadakati ve Müşteri Tutma Oranı

Müşteri sadakati ve müşteri elde tutma oranları, CLV'nin temel bileşenlerindendir. Bu unsurlar, müşterilerden sağlanan gelir akışlarının sürdürülebilirliğini ve istikrarını sağlayarak işletmeler için uzun vadeli fayda yaratmaktadır. Yeni müşteri kazanımının genellikle yüksek maliyetli olması, mevcut müşterileri elde tutmanın ekonomik açıdan daha cazip hale gelmesine sebep olmaktadır. Bunu destekleyen araştırmalar, müşteri elde tutmanın kar artışı sağladığını göstermektedir (Stahl vd., 2012). Buna ek olarak mevcut müşterilerin elde tutulması, pazarlama maliyetlerini düşürürken operasyonel süreçlerin verimliliğini artırmakta, bu şekilde şirketlerin kârlılıklarını uzun vadede sürdürülebilir kılmaktadır (Chen vd., 2018).

Bu bağlamda, Verhoef vd. (2001), müşteri sadakati ile çapraz satış stratejilerinin etkileşimini inceleyerek, bu stratejilerin müşteri sadakatini artırmadaki rolü üzerinde durmuştur. Benzer şekilde, Donkers vd. (2007), sigorta sektöründe müşteri sadakati ile kârlılık arasında ilişki olduğunu ortaya koymuş ve müşteri tutma oranlarını artırmaya yönelik modeller önermiştir.

Tsao vd. (2009), sadakat programlarının ve promosyonların müşteri tutma oranına etkilerini, uzun vadede CLV'ye sağladıkları katkıyı incelerken; Zhang vd. (2010), tüketici ürünlerinde müşteri sadakatinin CLV üzerindeki etkilerini vurgulamış, sadakati artıracak stratejilerin kârlılığı iyileştirmeye yönelik olası etkilerini incelemiştir.

Permana vd. (2015), sadakatin uzun vadede CLV üzerindeki etkisini Markov Zinciri modelini sağlık sigortası verilerinde uygulayarak müşteri sadakati oranlarını tahmin ederek araştırmıştır. Sadakati artırma programlarının kârlılığa ve CLV'ye etkisinin (Lemmens ve Gupta, 2020) yanı sıra e-ticaret gibi sanal ortamlarda sadakat davranışlarının kârlılığının CLV üzerindeki etkileri sıklıkla incelenmiştir (Yılmaz Benk vd. 2022). Bu tür dinamik yapılarıdaki veri odaklı çalışmaların müşteri sadakati ve tutma oranının kârlılığa ve CLV'ye olan etkileri ML modelleriyle (Choi ve Choi, 2023) analiz edilerek bu alanın uygulama boyutuna yenilik getirilmiştir.

1.5.4. Ortalama Satın Alma Değeri

Ortalama satın alma değeri, müşterilerin işlem başına harcadığı parasal tutarı niceliksel olarak belirlediği için CLV'nin temel bir belirleyicisidir. Toplam satın almanın belirli bir dönemde yapılan satın alma sayısına bölünerek hesaplanır. Bu ölçüm harcama modellerini anlamak ve hedeflenen stratejiler aracılığıyla geliri artırma imkanını belirlemek için önemlidir.

Fader vd. (2005), RFM modelini kullanarak, müşterilerin satın alma değerleri ve sadakatleri arasındaki ilişkiyi incelemiştir. Ortalama satın alma değeri, müşterilerin değerini belirlemede önemli bir faktör olarak ele alınmaktadır. Bu yaklaşım, müşteri segmentasyonunda, özellikle kârlı segmentleri belirlemede kullanılmaktadır. Benzer şekilde Kumar ve Venkatesan (2008), CLV analizlerinde ortalama satın alma değerinin önemini vurgulamış ve doğru müşteri segmentasyonu yaparak bu değer artırılabilirliğini savunmuştur.

Ortalama satın alma değerinin, müşteri ilişkileri yönetiminde stratejik fiyatlandırma ve tekliflerden müşteri bağlılığı (Ryals, 2008) ve hissedar değeri üzerindeki etkilerine (Li, 2010), otel tercihleri bağlamında CLV tahminine bir değişken olarak ele alınırken (Wu ve Li, 2011) ve pazarlama yatırımlarının geri dönüşünü (ROMI) ölçmede bir metrik olarak kullanımına (Lee ve Yoo 2012) kadar geniş bir yelpazede önemli bir role sahip olduğu görülmektedir.

Glady vd. (2015), müşteri harcamaları ve terk etme davranışları arasındaki ilişkinin CLV'ye katkısını incelerken Zhang vd. (2016) ise, reklam stratejilerinin ürün yeniliği üzerindeki etkilerini değerlendirirken, ortalama satın alma değerinin CLV tahminindeki önemine değinmiştir. Marisa vd. (2019), küçük ve orta ölçekli işletmelerde LRFM modelinde bu değeri segmentasyon ve strateji geliştirme sürecinde önemli bir değer olarak kullanmıştır. Heldt vd. (2021), ortalama satın alma değerini ürün bazlı müşteri değer tahminlerinde anahtar bir bileşen olarak ele alırken Ahmed vd. (2023), lüks markaların sosyal medya pazarlaması bağlamında, bu değer müşterinin satın alma niyetini üzerindeki etkisi üzerinde durmuştur.

1.5.5. Satın Alma Sıklığı

Satın alma sıklığı, bir müşterinin belirli bir zaman diliminde (haftalık, aylık veya yıllık) gerçekleştirdiği alışveriş sayısını ifade eden bir metrik olup, CLV hesaplamasında kullanılmaktadır. Yüksek satın alma sıklığı, müşteri ömrü boyunca daha fazla gelir elde etme potansiyeline işaret etmekte ve müşterilerin davranış kalıplarını anlamada, tekrarlayan işlemleri artırma fırsatlarının belirlenmesinde ve müşteri katılım stratejileri geliştirmesinde önemlidir. Bu çerçevede, Hogan vd. (2004), satın alma sıklığını kulaktan kulağa pazarlama ve reklam etkinliğini değerlendirme aracı olarak kullanmışken, Shih ve Liu (2008), müşteri talebindeki

değişiklikleri modellemek için satın alma sıklığını ele almış ve CLV hesaplamalarında bu ölçümün değerli bir değişken olduğunu aktarmıştır.

Satın alma sıklığını CLV'nin temel bir bileşeni olarak modellenmiş ve sık satın alma davranışlarının uzun vadeli değer yaratma potansiyelini artırdığı dile getirilmiştir (Heitz vd. 2011). Bu bileşen RFM modelinde de önemli bir parametre olarak analizlere katkı sağlamıştır (Safari vd., 2016). Ma vd. (2015) müşteri reaktivasyonu (canlandırma) için doğru zamanlamayı belirlemede bu metriğin etkisini göstermiştir. Daha yeni çalışmalarda, Dahana vd. (2019), moda perakende sektöründe değer segmentasyonunda satın alma sıklığını kullanarak yüksek CLV'ye sahip müşteri segmentlerini tanımlamıştır. Cambra-Fierro vd. (2021) ise sürdürülebilir müşteri değerini tahmin etmek için bu metriği kullanırken, Jabr vd. (2023), çevrimiçi tekrar ziyaret ve satın alma davranışlarını optimize etmek için tıklama akışlarına dayalı yöntemler geliştirerek, satın alma sıklığının müşteri davranışını yönlendiren önemli bir faktör olduğunu belirtmiştir.

1.5.6. Müşteri Ömrü

Müşteri ömrü, bir müşterinin bir işletmeyle etkileşimde bulunduğu süreyi, ilk edinimden müşteri kaybına kadar olan süreç olarak ifade etmektedir. Bu metrik, CLV hesaplamalarında daha uzun bir müşteri ömrü, daha fazla tekrar eden satın alma ve etkileşim anlamına gelir ve zaman içinde daha yüksek gelir elde edilmesi ile sonuçlanır.

Müşteri ömrünü CLV ile ilişkilendirerek, müşteri segmentasyonu ve strateji geliştirme çerçevesi incelenmiştir (Kim vd., 2006). Ayrıca, müşteri ömrünün uzun vadeli müşteri değerine etkileri incelendiğinde, müşteri segmentasyonu ve CLV tahminlerinde bu sürenin doğru şekilde değerlendirilmesinin, yüksek değerli müşteri portföylerini yönetmede önemli bir rol oynadığı görülmüştür (Venkatesan vd., 2007).

Singh vd. (2009), müşteri ömrünün doğrudan gözlemlenemediği durumlar için tahmin yöntemleri geliştirmiş, Van Oest ve Knox (2011) ise BG/NBD modeliyle müşteri ömrü tahmin ederek, bu sürenin şikayet yönetimi ve CLV üzerindeki etkilerini araştırmıştır. Rust vd. (2011), müşteri ömrünün gelecekteki karlılık tahminlerinde temel bir değişken olduğunu ve uzun müşteri ömrüne sahip müşterilerin daha kârlı olduğunu ortaya koymuştur.

Sektörel bazda bakıldığında, Ravasan ve Mansouri (2018) sigorta sektöründe müşteri ömrünü RFM modeli ile tahmin etmiş, Bansal vd. (2020), telekom sektöründe müşteri ömrü tahmini için hayatta kalma analizi (survival analysis) uygulamıştır.

1.5.7. İndirim Oranı

İndirim oranı, CLV hesaplanmasında, gelecekteki nakit akışlarını bugünkü değerlerine indirgemeyi sağlamaktadır. Bu oran, paranın zaman değerini dikkate alarak gelecekte elde

edilecek gelirin bugünkü değerden daha düşük olduğunu kabul etmektedir. İndirim oranının doğru belirlenmesi, işletmelerin gelecekteki müşteri gelirlerini gerçekçi bir şekilde yansıtmaya ve müşteri ilişkilerinin gerçek değerini hesaplamalarına olanak tanır.

Haenlein vd. (2006), CLV hesaplamalarında kârsız müşterilerin ayrılmasının etkisini analiz ederken, indirim oranının bu süreçteki rolünü araştırmıştır. Ambler ve Roberts (2008) ise müşteri sadakatini iyileştirmek ve sürdürülebilir değer yaratma stratejilerinde indirim oranlarının kullanımını ele almıştır.

Fader vd. (2010), farklı indirim oranlarının müşteri davranışları üzerindeki etkisini incelerken, Braun ve Schweidel (2011), müşteri yaşam süresi modellemelerinde indirim oranını gelecekteki gelir tahminlerinin önemli bir faktörü olarak değerlendirmektedir. Ferrentino vd. (2016) ise matematiksel yaklaşımla optimal indirim oranlarının belirlenmesini araştırırken, Marbach vd. (2019), online ortamlardaki müşteri katılımını incelemiştir.

1.5.8. Kar Marjı

Kâr marjı, şirketlerin kârlılığını ölçmek için kullanılan göstergedir ve işletmenin toplam gelirinden maliyetlerin çıkarılmasından sonra kalan kârın yüzdesini ifade etmektedir. CLV bağlamında, kâr marjı, bir müşteriden elde edilen gelirin işletme kârına katkısını belirleyen bir metriktir. Yüksek kâr marjı, müşterinin işletme için daha değerli olduğu anlamına gelir bu doğrultuda CLV hesaplamalarını doğrudan etkilemektedir.

Ryals ve Knox (2005), kâr marjını risk ayarlı CLV hesaplamalarında kullanırken benzer şekilde, Parracho Sant'Anna ve Ribeiro (2009) ise kâr marjının CLV ile doğrudan ilişkisini analiz ederek, kârlılığı artırma stratejileri geliştirmiştir. Albadvi ve Koosha (2011), pazarlama bütçesinin yüksek kâr marjına sahip müşteri segmentlerini belirlemek için CLV'nin optimize edilebileceğini öne sürerken; Audzeyeva vd. (2012), çok hizmetli finansal kuruluşlarda müşteri segmentasyonu ve kârlılık analizlerinde kâr marjını önemini vurgulamıştır.

Clempner ve Poznyak (2014), kâr marjlarını iyileştirmek amacıyla temel politika yaklaşımları geliştirmiş, Huang ve Rust (2017) ise dijital hizmet stratejilerinin kâr marjına olan katkısını araştırmıştır. Akbari ve Moradipour (2021), B2B satış performansında kâr marjının sürdürülebilirliğin anahtarı olduğunu vurgulamıştır. Dong vd. (2022) ile Chouaten vd. (2024) ise, kâr marjını müşteri kayıp modelinin ve yüksek değerli müşteri segmentlerinin tanımlanmasında kullanmıştır.

İKİNCİ BÖLÜM

RFM VE CLV'NİN ENTEGRASYONU ÜZERİNE SİSTEMATİK BİR DERLEME

2.1. RFM ve CLV'nin Entegrasyonu

Müşteri yaşam boyu değeri (CLV) ve RFM (Yenilik, Sıklık, Para) analizinin entegrasyonu, işletmelere müşteri katılımını en üst düzeye çıkarma, kaynak tahsisini optimize etme ve karlılığı artırma yeteneği sunarak çağdaş pazarlama stratejilerinde önemli bir araç olarak kullanılmaktadır (Fader vd., 2005; Liu ve Shih, 2005). Hem CLV hem de RFM, müşteri davranışını anlamak için bağımsız olarak etkili araçlar olduklarını kanıtlamış olmalarına rağmen, bunların birleşik uygulaması müşteri segmentasyonu ve değer tahmini için daha kapsamlı bir çerçeve sağlamaktadır (Fader vd., 2005; Liu ve Shih, 2005).

RFM, müşterilerin geçmiş davranışlarını ölçmek için bir çerçeve sunarken, CLV gelecekteki müşteri değerini tahmin etmeye odaklanır. Bu iki yöntem birlikte kullanıldığında, müşteri davranışlarını daha derinlemesine analiz etmek ve daha etkili pazarlama stratejileri geliştirmek mümkün hale gelmektedir. Bulanık mantık (Ravasan ve Mansouri, 2018) ve kararsız bulanık teori (Yan vd., 2018) kullanımı gibi hibrit modelleme yaklaşımlarındaki son gelişmeler, bu tekniklerin sektörler genelinde segmentasyon stratejilerinin hassasiyetini ve uygulanabilirliğini iyileştirme potansiyelini göstermiştir.

RFM ve CLV'nin entegre kullanımının farklı alanlarda incelendiği görülmektedir. Örneğin, Cao vd. (2015), e-ticarete müşteri kaybını tahmin etmek için Sıralı Ağırlıklı Ortalama (OWA) ve veri madenciliğini kullanmış ve elde tutma zorluklarına çözüm üretmek için analitik yöntemleri birleştirmenin etkinliğini vurgulamıştır. Geleneksel ve modern metodolojileri harmanlayan Kanchanapoom ve Chongwatpol (2023), CLV modellerinin göç davranışlarını dahil ederek müşteri segmentasyonunu nasıl iyileştirebileceğini göstermiştir.

İşletmeler giderek daha fazla veriye dayalı karar alma süreçlerini hayata geçirdikçe, RFM ve CLV'nin entegrasyonu, gelecekteki davranışları tahmin etmek için müşteri verilerinin daha etkili bir şekilde kullanılmasını sağlamaktadır. RFM ile entegre edildiğinde CLV, yalnızca geçmiş davranışları değil aynı zamanda gelecekteki etkileşim potansiyelini de dikkate alarak müşteri değerinin daha dinamik ve gerçek zamanlı bir şekilde anlaşılmasına yardımcı olmaktadır. Pazarlama literatüründe, RFM ve CLV'nin entegrasyonu, kişiselleştirilmiş pazarlama stratejileri oluşturmak adına temel bileşenler olarak görülmüştür (Hosseini ve Mohammadzadeh, 2016; Shim vd., 2012).

Literatürde CLV ve RFM birlikteliğini ele alan kapsamlı araştırmaların eksikliği gözlemlenmiştir. Tezin bu bölümünde yapmış olduğumuz sistematik inceleme, mevcut çalışmaları sentezleyerek ve bu modelleri birleştirmedeki zorlukları ve fırsatları belirleyerek bu boşluğu doldurma potansiyeline sahiptir. Böyle bir çaba, mevcut yaklaşımlardaki sınırlamaları da ortaya çıkarmak ve gelecekteki araştırma yönelimlerini geliştirmek adına faydalı olacağı düşünülmektedir. Bu sınırlamaları ele almak için, bilim insanlarının mevcut literatürü sistematik olarak keşfetmeleri, mevcut çalışma gövdesini değerlendirmeleri ve araştırma konularının nasıl geliştiğini anlamaları gerekmektedir. Benzer şekilde, literatür hakkında daha sistematik ve organize bir incelemeye olan ihtiyaç da mevcuttur. Bu bakımdan organize çerçeveler sunan PRISMA (Page vd., 2021) ve SPAR-4-SLR (Paul vd., 2021) gibi sistematik incelemeler yürütme prosedürlerine de ihtiyaç olduğu düşünülmektedir. Ayrıca SPAR-4-SLR (Sistematik Literatür İncelemelerinde Alaka Düzeyini Uygulamak İçin Yapılandırılmış Protokol), çalışmasında Paul vd. (2021)'in ADO (Paul ve Benito, 2018), TCM (Paul vd., 2017), TCCM (Paul ve Rosado-Serrano, 2019), ya da 5N1K (Lim, 2020) gibi çerçevelere uyulmasını şiddetle tavsiye etmektedir. Söz gelimi Lim'in (2020) 5N1K çerçevesi yazarlara literatür incelemelerinin 'ne', 'neden', 'ne zaman', 'nerede', 'kim' ve 'nasıl' yönlerini sistematik olarak ele almalarında rehberlik eden yapılandırılmış bir çerçeve sağlamaktadır. Böylece bu uygulamalar literatürlerin sistematik olarak incelenmesinde yön ve destek sunmaktadır. Ayrıca bu yapılandırılmış yapıyı desteklemek için sistematik inceleme yaklaşımının, bibliyometrik analizle birlikte kullanıldığında, daha kapsamlı bir yorumlama sağlayabileceği düşünülmektedir. RFM-CLV birlikteliği üzerine yapılan bu çalışma, aşağıda listelenen araştırma sorularına (AS) yanıtlar elde etme amacıyla bibliyometri destekli sistematik bir inceleme kullanmıştır.

AS1: Farklı sektörlerde RFM ölçümlerini Müşteri Yaşam Boyu Değeri (CLV) ile bütünleştirmek için kullanılan metodolojiler nelerdir?

AS2: Müşteri segmentasyonu ve elde tutma stratejileri için RFM analizini CLV ile birleştirmenin faydaları nelerdir?

AS3: RFM ölçümlerinin CLV ile bütünleştirilmesi müşteri segmentasyonunu, müşteri kaybı tahminini ve pazarlama stratejilerini iyileştirmek için neden önemlidir?

AS4: Neden bazı endüstriler (örneğin, e-ticaret, perakende, bankacılık ve telekomünikasyon) RFM-CLV modellerini diğerlerinden daha kapsamlı bir şekilde benimsedi?

AS5: RFM-CLV entegrasyonunda önemli gelişmeler ne zaman gerçekleşti ve bunlar zaman içinde nasıl evrimleşti?

AS6: Müşteri Yaşam Döngüsünde (Örneğin, Edinme, Elde Tutma veya Müşteri Kaybını Önleme) RFM-CLV modellerini ne zaman benimsenmektedir?

AS7: RFM-CLV Modelleri nerede (hangi ülke ve üniversitelerin iş birliğinde) araştırılmaktadır?

AS8: RFM-CLV Entegrasyonunu nerede (hangi araştırma alanlarında) mevcuttur?


AS9: RFM-CLV Entegrasyonuna ilişkin araştırmaya katkıda bulunan önde gelen yazarlar, kimlerdir?

AS10: RFM ölçümleri CLV tahminlerinin doğruluğunu ve uygunluğunu nasıl artırır?

AS11: Gelecekteki araştırmalar mevcut RFM-CLV entegrasyon metodolojilerinin sınırlamalarını nasıl ele alabilir?

2.2. SPAR-4-SLR Protokolü

Paul vd. (2021) tarafından geliştirilen Sistematik Literatür İncelemeleri için Bilimsel Prosedürler ve Gerekçeler (SPAR-4-SLR) protokolü olarak bilinen yerleşik bir inceleme yaklaşımı, işletme yönetimi alanında büyük bir ilgi görmektedir. Çalışmada kullanılan protokol Paul vd. (2021) tarafından geliştirilen SPAR-4-SLR'nin süreçlerini izlemektedir. Paul vd. (2021)'nin önerdiği gibi Lim'in (2020) ne, neden, nerede, ne zaman, kim ve nasıl (5N1K) sorularından oluşan sorgulayıcı çerçevesini kullanılarak sistematik literatür taraması ile RFM ve CLV'nin Entegrasyonu açıklanmaya çalışılmaktadır. SPAR-4-SLR yönergelerinde yer alan "Toplama", "Düzenleme" ve "Değerlendirme" basamaklarından oluşan üç aşamalı süreci izleyerek RFM-CLV'nin entegrasyona odaklanan akademik bir inceleme gerçekleştirilmiştir. SPAR-4-SLR, mevcut literatürün nitel sentezine vurgu yaparak yapılandırılmış ancak esnek bir yaklaşımla sistematik literatür incelemeleri yürütmeye odaklanan bir metodolojidir (Paul vd., 2021). Buna karşılık, tezin bu bölümünde kullanılan bibliyometrik analiz, bir bibliyografik veri koleksiyonundaki kalıpları ve eğilimleri analiz eden, yayınların akademik etkisi ve birbirleriyle bağlantıları hakkında içgörüler sağlayan ancak SPAR-4-SLR tarafından vurgulanan nitel yönü görece eksik olan nicel bir yöntemdir. SPAR-4-SLR yönergeleri, aynı alandaki araştırmacılar için daha alakalı olan alan-spesifik çalışmaları nitel olarak daraltmayı hedeflemektedir (Paul vd, 2021). Şekil 2.1'de SPAR-4-SLR metodolojisi şematize edilmiştir.



Şekil 2.1 SPAR-4-SLR metodolojisi

2.2.1. Toplama

SPAR-4-SLR protokolünün ilk aşaması olan “toplama” kısmında, ilgili araştırmaları bulur, toplar ve filtreleriz. Toplama kısmı, planlama ve edinme aşamalarını içerecek şekilde ikiye ayrılmaktadır (Paul vd., 2021). Bu protokolün başarılı bir şekilde yürütülebilmesi için, öncelikle ilgili araştırma makalelerini bulma araçlarını tasarladığımız "planlama" alt aşamasını tamamlamak gerekmektedir. Tez çalışmasının bu bölümünde yer alan protokoldeki planlama aşamasının temeli RFM ve CLV'nin birlikte geçtiği ilgili tüm çalışmaları “kabaca” yakalamak için kurgulanmıştır. Birden fazla aramanın ve özet tarama süreçlerinin ardından, uygun anahtar kelimelerin “customer life time value”, “customer life time”, “customer lifetime value” ve “RFM” olduğu değerlendirilmiştir. Bu tezde belirli kategorik kalite kriterlerine daha uygun

olacağı düşünüldüğü için Web of Science veritabanı kullanılmaya karar verilmiştir (Martin-Martin vd., 2018). Ayrıca, toplama aşamasında yayın türü, index türü gibi çeşitli kriterlere göre makaleleri filtrelenmiştir (Paul vd., 2021). Son yıllarda, birçok disiplinde yağmacı dergilerin yaygınlaşması (Rice vd., 2021), planlamamıza dahil edilen dergilerin bu kategoride değerlendirilmediğini anlamak adına kalite süzgecinden geçirilmiştir (Kumar vd., 2022; Mukhopadhyay vd., 2023; Muldoon vd., 2024). Bir sonraki toplama aşaması olan "edinme", arama mantığıyla uyumlu literatüre erişmek için yazılacak arama parametresinin temel öğelerini belirlemeyi içermektedir (Şekil 1). 1 Ağustos 2024'te yapılan Web of Science aramasında şekilde belirtilen arama parametresi kullanarak 97 dokümana erişilmiştir.

2.2.2. Düzenleme

Düzenleme aşaması, organizasyon ve sadeleştirme adımlarını içeren kritik bir süreçtir. SPAR-4-SLR protokolüne (Paul vd., 2021) uygun olarak, ilk aşamada toplanan 97 belge, çalışmanın hedeflerine uygun olmayanları elemek amacıyla sıralanmış ve elenmiştir. Organizasyon aşamasında, analiz için yalnızca dergi makaleleri seçilmiş, dil tercihi olarak İngilizceye odaklanılmış ve hakemli dergilerde yayınlanmış makalelerin dahil edilmesi sağlanmıştır. Bu aşamada makale sayısı 54'e indirilmiştir. Bu tercih, hakemli dergilerin daha sıkı kalite standartlarına sahip olmasından kaynaklanmaktadır (Randolph vd., 2007). Ayrıca, literatür taramasında hakemli makalelerin seçilmesi birçok çalışmada önerilmektedir (Mukhopadhyay vd., 2023; Prabhu ve Srivastava, 2023).

Sadeleştirme aşamasında, çalışma kapsamına uygun olmayan makaleler farklı nedenlerle elenmiştir. Öncelikle, çalışmanın ana konusunu oluşturan RFM ve CLV'nin birlikte kullanımına odaklanmayan makaleler çıkarılmıştır. Ayrıca, RFM kullanımını sadece sonuç ve öneriler kısmında ele alan makaleler dahil edilmemiştir. Bunun yanında, kalite kriterlerini karşılamayan makaleler (meta verileri eksik olan, konuyla doğrudan ilişkisi olmayan vb.) ve İngilizce dışında yazılmış olan yayınlar da sadeleştirme sürecinin bir parçası olarak elenmiştir. Ek olarak, yalnızca ücretli olarak erişilebilen makalelere ulaşım sağlanamaması, bu makalelerin çalışma dışında bırakılmasına neden olmuştur. Bu düzenleme ve sadeleştirme süreçleri sonunda, SSCI, SCI, SCI-E ve ESCI indekslerinde yer alan ve çalışmanın belirlediği kriterlere uygun toplam 38 makale ile bir sonraki basamağa geçilmiştir.

2.2.3. Değerlendirme

"Değerlendirme" olarak adlandırılan üçüncü aşama, bibliyografik bilgileri analiz etmeye ve bulguları raporlamaya odaklanmasının yanında literatürün sistematik bir derlemesini içermektedir (Paul vd., 2021). Çalışmanın bu kısmında yer alan araştırma sorularına cevap

vermek için bilim haritalama analizinin yanı sıra derin literatür okumaları gerçekleştirilmiştir. Bilimsel haritalama sürecinde R'nin bibliometrix ve ggplot paketleri tercih edilmiştir (Aria ve Cuccurullo, 2017; Donthu vd., 2021). Eş kelime ağı (AS5), Trend konu analizi (AS5), Ülke ve Üniversite İş Birliği Ağları (AS7), Yazar Üretkenlik Görseli (AS9) ve Yazar İş Birliği Ağı (AS9), R bibliometrix paket yazılımı kullanılmıştır (Aria ve Cuccurullo, 2017; Donthu vd., 2021). Literatürün sistematik bir derlemesi yapılarak da tüm araştırma soruları (AS1, AS2, AS3, AS4, AS5, AS6, AS7, AS8, AS9, AS10, AS11) kendi içerisinde zenginleştirilmiştir. Bu bakımdan sonuçların raporlanması sistematik bir süreci takip ederek, haritalar tablolar ve sentezlerle zenginleştirilmiştir. Her ne kadar inceleme sürecimiz SPAR-4-SLR kriterlerine ve WoS veritabanında yer alan kaliteli indeksleme kurallarına uygun olarak gerçekleştirilse de doğası gereği bazı sınırlılıkları bulunmaktadır.

2.3. Derleme Sonuçları

Ne

AS1: Farklı sektörlerde RFM ölçümlerini Müşteri Yaşam Boyu Değeri (CLV) ile bütünleştirmek için kullanılan metodolojiler nelerdir?

RFM ölçümlerini CLV ile bütünleştirmek için çeşitli sektörlerde farklı metodolojiler geliştirilmiştir. Örneğin, Chan vd. (2008), segmentasyon modelleme tekniklerini kullanarak, otomobil perakende sektöründe kampanya yönetimi için akıllı değer tabanlı müşteri segmentasyonu oluşturmak üzere bir vaka çalışması yaklaşımı kullanmıştır. Liu ve Shih (2005), CLV tabanlı işbirlikçi filtreleme yoluyla ürün öneri sistemlerini geliştirmek için Analitik Hiyerarşi Sürecini (AHP) veri madenciliğiyle bütünleştirmiştir. E-ticarette, Cao vd. (2015), müşteri kaybını analiz etmek için OWA ile veri madenciliği tekniklerini birleştirmiştir; Zhang vd. (2015) ise müşteri değerini tahmin etmek için RFMC temelli kümelenme ölçümlerini kullanarak öngörücü modelleme tekniklerini uygulamıştır. Benzer şekilde, Zoeram vd. (2018) bulanık çıkarım sistemlerini, müşteri segmentasyonu için LRFM tabanlı kümelemeyi iyileştirmek için kullanılmıştır. Hibrit ve sinir ağı tabanlı modelleme gibi diğer yaklaşımlar, De Marco vd. (2021) bilişsel analitik ve Moro vd. (2015), telepazarlama kampanyaları üzerine yaptığı çalışmalarda, CLV'yi öngörücü analitikle entegre kullanımının etkili olduğu kanıtlanmıştır. Bu metodolojiler, sektöre özgü çözümlerin ele alınmasında RFM ve CLV'nin entegre edilmesinin çok yönlülüğünü vurgulamaktadır.

AS2: Müşteri segmentasyonu ve elde tutma stratejileri için RFM analizini CLV ile birleştirmenin faydaları nelerdir?

RFM analizini CLV ile entegre etmek, müşteri segmentasyonu ve elde tutma stratejileri için birçok sektörün faydalandığı görülmektedir. Örneğin, Heldt vd. (2021), geleneksel RFM'den RFM/P modellemesini geliştirerek yüksek değerli müşterileri belirlemede ürün tabanlı değerlemenin avantajını göstermiştir. Oto sigorta sektöründe, Ravasan ve Mansouri (2018), müşteri segmentasyonunu iyileştirmek için bulanık ANP aracılığıyla ağırlıklı RFM modellemesinin kullanımını uygulamış ve daha iyi hedefleme ve elde tutma stratejilerine yol sağlamıştır. Benzer şekilde, Yan vd. (2018), tereddütlü bulanık teorinin (Hesitant fuzzy theory) RFM modellemesiyle birleştirilmesinin sigorta müşterileri için segmentasyonu ve yaşam boyu değeri belirlemesini nasıl iyileştirebileceğini çalışmıştır. Veri madenciliği ve kümeleme tekniklerinden yararlanarak, Yoseph vd. (2020) ve Hasheminejad vd. (2020), CLV'nin büyük veri analitiğinin bankacılık ve finans alanında pazar segmentasyonunu geliştirme ve müşteri sadakatini anlamadaki rolünü vurgulamışlardır. Ek olarak, olasılıksal ve hibrit yaklaşımlar gibi gelişmiş modeller, Safari vd. (2016) sadakat ölçümü ve Martinez vd. (2021) perakende işletmeleri için özelleştirilebilir RFM analizi üzerine yaptığı çalışmalarla, müşteri merkezli pazarlama stratejilerini iyileştirmede etkili olduğunu vurgulamıştır.

Neden

AS3: RFM ölçümlerinin CLV ile bütünleştirilmesi müşteri segmentasyonunu, müşteri kaybı tahminini ve pazarlama stratejilerini iyileştirmek için neden önemlidir?

RFM ve CLV'nin sektörün ihtiyaçları doğrultusunda farklı tekniklerle birleşimi, işletmelerin yüksek değerli müşterileri belirlemesine, risk altındaki segmentleri tanımasına ve pazarlama çabalarını buna göre uyarlamasına olanak tanımaktadır. RFM'nin müşteri davranışlarına (satın alma yeniliği, sıklık ve parasal değer gibi) odaklanmasından yararlanarak bunu CLV ile entegre etmek, şirketlerin uzun vadeli ürün veya müşteri değerini tahmin edebilir ve müşteri/ürün merkezli stratejileri geliştirebilir. Buna örnek olarak, Chouaten vd. (2024) ve Liu vd. (2005) gibi çalışmaların, RFM-CLV modellerinin müşteri yaşam boyu değerine odaklanarak kampanya yönetimini ve ürün önerilerini iyileştirmeye nasıl yardımcı olduğunu ve bunun daha verimli kaynak tahsisi ve hedefli pazarlama çabalarıyla sonuçlandığını göstermektedir.

AS4: Neden bazı endüstriler (örneğin, e-ticaret, perakende, bankacılık ve telekomünikasyon) RFM-CLV modellerini diğerlerinden daha kapsamlı bir şekilde benimsedi?


E-ticaret, perakende, bankacılık ve telekomünikasyon gibi sektörler, kişiselleştirilmiş pazarlama ve elde tutma stratejileri için dinamik müşteri verilerine güvenmeleri nedeniyle RFM-CLV modellerini benimsemeye daha meyillidir. Bu sektörler büyük miktarda işlemsel ve davranışsal veri üretmektedir ve bu da tahmin edici modellerden yararlanmak için idealdir. E-

ticarete, Cao, vd. (2015) tarafından müşteri kaybı tahmini ve ürün öneri sistemleri için geliştirilen modeller veya De Marco vd. (2021) tarafından CLV modellemesi için yapay sinir ağları kullanılarak keşfedilen modeller, RFM-CLV'nin müşteri elde tutmayı iyileştirmedeki gücünü göstermektedir. Benzer şekilde, tekrarlayan müşteri ilişkilerine ve uzun vadeli değere odaklanan bankacılık ve telekomünikasyon sektörleri, Cao vd. (2015) ve Moro vd. (2015) gibi çalışmalarda vurgulandığı gibi, müşteri kaybını tahmin etmek, müşterileri segmentlere ayırmak ve sadakat programlarını optimize etmek için RFM-CLV modellerini kullanılmaktadır. Bu sektörlerde veri kullanılabilirliği ve müşteri yaşam boyu ilişkilerine olan ihtiyaç, RFM ve CLV'nin entegrasyonunu müşteri elde tutmayı ve karlılığı iyileştirmek için özellikle etkili ve önemli hale getirir.

Ne Zaman

AS5: RFM-CLV Entegrasyonunda Önemli Gelişmeler Ne Zaman Gerçekleşti ve Bunlar Zaman İçinde Nasıl Evrimleşti?

RFM ve CLV bütünleşmesi, ilk aşamalarda 2005–2010 döneminde, müşteri segmentasyonunu ve tahmin modellemelerini güçlendirme amacıyla birlikte kullanılmaya başlanmıştır. Öneri sistemlerinin gelişmesiyle Liu ve Shih (2005), CLV veya sadakatini değerlendirmede RFM değişkenlerinin göreceli ağırlıklarını belirlemek için analitik hiyerarşi süreci (AHP) uygulanan yanında, müşterileri ağırlıklı RFM değerine göre gruplandırmak için kümeleme teknikleri kullanarak, her müşteri grubuna ürün önerileri sağlamak için bir ilişki kuralı madenciliği yaklaşımı uygulamıştır. Aynı dönemde Fader ve Hardie (2005), müşteri tabanı analizi için RFM modeline probabilistik bir yaklaşım getirerek CLV'yi daha hassas ölçmeye yönelik çalışmasıyla katkıda bulunmuşlardır.



Şekil 2.2 Anahtar Kelime Trendleri: Yıllara Göre Alan Grafiği

Şekil 2.2 incelendiğinde, 2005'ten itibaren anahtar kelimelerin genelinde düzenli bir artış olduğunu görülmüştür. Bu, CLV ve RFM'in akademik çalışmalarda giderek daha fazla incelendiğini ve ilgi gördüğünü ortaya koymaktadır. Özellikle 2015 sonrası büyüme hızının arttığı anlaşılmaktadır. "Customer Lifetime Value (CLV)" en yüksek değere ulaşan kategori olarak öne çıkmıştır. Bu durum, müşteri değerini ölçmenin, işletme stratejilerinde uzun vadeli müşteri bağlılığını anlamada merkezi bir rol oynadığının göstergelerinden biridir. RFM (Recency, Frequency, Monetary) modeli, CLV'nin yanında literatürde önemli bir yer edinmiştir. Bu, temel düzeyde ama etkili bir müşteri segmentasyon modeli olan RFM'in pratik uygulamalar için literatürde tercih edildiğine bir işarettir. "Data mining (Veri Madenciliği)" ve "clustering (kümeleme)" özellikle 2010'dan itibaren yükseliş göstermiştir. Bu eğilim, veri analiz tekniklerinin müşteri davranışlarını anlamada artan önemini yansıtmaktadır. CLV ve RFM çalışmalarının teknik temellerini destekleyen bu iki anahtar kelime, dijitalleşmenin etkisini de ortaya koymaktadır. "Customer segmentation (müşteri segmentasyonu)" ve "collaborative filtering (işbirlikçi filtreleme)" gibi kavramların yükselişi, müşteri segmentasyonu ve öneri sistemlerinin akademik ve pratik anlamda daha fazla ilgi gördüğünü işaret etmiştir. Bu kavramlar, işletmelerin bireysel müşteri ihtiyaçlarına yönelik kişiselleştirilmiş stratejiler geliştirmesi için temel araçlardır. Şekilden yola çıkarak 2005-2010 "Başlangıç Döneminde" CLV ve RFM temel teorik çalışmalarla ele alınmıştır. 2010-2015 "Uygulama Döneminde" veri madenciliği ve kümeleme gibi uygulamalı analiz yöntemleri literatüre entegre edilmiş ve segmentasyon odaklı çalışmalar artmıştır. 2015 ve sonrası


“Dijitalleşme ve İleri Analitik” dönemde ise dijitalleşmenin etkisiyle CLV ve RFM daha geniş bir bağlamda (örneğin, öneri sistemleri) ele alınmış ve ileri veri analitiği yöntemleri popüler hale gelmiştir.

2010–2015 döneminde, entegrasyon çalışmaları daha karmaşık tekniklerle genişlemiştir. Albadvi ve Shahbazi (2010), derecelendirme temelli işbirlikçi filtreleme ve WRFM-CLV'nin entegrasyonu ile yeni ürün öneri tekniklerini geliştirmiştir. Cao vd. (2015), müşteri kaybını analiz etmek için OWA ve veri madenciliğini birleştirerek e-ticarette müşteri değerine hizmet eden öngörüler sağlamıştır. Bu dönem aynı zamanda Moro vd. (2015) yapay sinir ağları yöntemlerini kullanarak CLV tahminleriyle telemarketing kampanyalarında uygulamasıyla öne çıkar.

2016–2020 döneminde, segmentasyon ve tahmin modellemeleri ağırlıklı olarak YZ ve bulanık mantık teknikleriyle ön plana çıkmıştır. Yoseph vd. (2018), büyük veri analizine dayalı segmentasyon ve kümeleme tekniklerini kullanarak müşteri gruplarını daha doğru şekilde analiz etmek üzerine çalışmıştır. Aynı yıl, Zoeram ve Mazidi (2018), LRFM modeli ve bulanık mantık sistemlerini kullanarak müşteri segmentasyonuna yenilikçi bir yaklaşım getirmiştir. Bu dönemde ayrıca Hiziroglu vd. (2018), CLV modelleme çalışmalarını veri madenciliği ile destekleyerek müşteri değer analizlerine katkı sağlamışlardır.

2021 sonrası dönemde, geliştirilen modeller daha özelleştirilebilir ve çok boyutlu hale gelmiştir. Kanchanapoom ve Chongwatpol (2023), müşteri göç modelleri ile RFM-CLV'yi entegre ederek segmentasyon tekniklerini geliştirmiştir. Aynı zamanda, Chouaten vd. (2024), spor pazarlamasında müşteri segmentasyonu ve CLV'yi birleştirerek futbol taraftarlarını değerlerine göre segmentlemiştir.

Anahtar Kelimeler



Şekil 2.3 Anahtar Kelime İlişkileri ve Kümelenmesi

Şekil 2.3'te yer alan ağ, CLV ve RFM analizlerinin birlikte kullanımına yönelik literatürün anahtar kelimeler bazında ilişkilerini göstermektedir. Ağda yer alan kırmızı küme, daha çok CLV kavramının baskın olduğu çalışmaları içermektedir. “Customer lifetime value” “data mining (veri madenciliği)”, “modelling (modelleme)” ve “recommender system (öneri sistemi)” gibi anahtar kelimeler, bu alandaki çalışmaların müşteri değerini tahmin etme, müşteri davranışlarını anlamak için veri madenciliği tekniklerini kullanma ve müşteri sadakatini artırmayı amaçlayan öneri sistemleri geliştirmeye odaklandığını göstermektedir. Bu kümedeki anahtar kelimelerin yoğunluğu, CLV'nin teorik altyapısının daha geniş ve farklı bağlamlarda ele alındığını işaret etmektedir. Yeşil küme ise RFM ve CRM odaklıdır. RFM analizinin müşteri ilişkileri yönetimi (CRM) bağlamında kullanımına odaklanmıştır. “RFM model” “customer value (müşteri değeri)” ve “customer relationship management (müşteri ilişkileri yönetimi)” gibi terimler, işletmelerin müşteri değerini optimize etmek ve müşteri sadakatini artırmak için RFM modelini öncelendiği çalışmaları ele almıştır. Yeşil kümede, daha operasyonel ve uygulamaya yönelik çalışmaların temsil edildiği anlaşılmaktadır. Mavi Küme (Segmentasyon ve Karar Verme Odaklı) “customer segmentation”, “PCA” ve “decision making” gibi anahtar kelimeler ön plandadır. Bu durum, müşteri segmentasyonuna yönelik tekniklerin (ör. kümeleme algoritmaları) ve çok kriterli karar verme süreçlerinin (ör. AHP) önemini vurgulamıştır. Segmentasyonun yoğun olduğu bu kümede, CLV ve RFM'in uygulamalarını daha spesifik müşteri gruplarına odaklamada önemli bir araç olarak kullanıldığı görülmüştür. Mor Kümeye (Fuzzy ve İleri Analiz Yöntemleri) “fuzzy c-means”, “self-organizing maps” ve “association rules” gibi anahtar kelimeler hâkimdir. Kümede CLV ve RFM'in daha gelişmiş ve esnek analitik yöntemlerle desteklendiği anlaşılmaktadır. Böylece CLV ve RFM'in bulanık mantık tabanlı modellerle zenginleştirildiği tespit edilmiştir. Kümeler incelendiğinde, erken aşamaları temsil eden kırmızı kümeye bakıldığında, CLV'nin teorik çerçevesi ve müşteri davranışlarını anlamaya yönelik veri madenciliği teknikleri ile başladığı görülmektedir. Bir ileri aşamayı temsil eden yeşil kümede, CLV ile RFM'in CRM bağlamında uygulanması dikkat çekmiştir ve bu durum teoriden pratiğe geçişi göstermektedir. Daha ileriki aşamaları gösterdiği düşünülen, mavi ve mor kümeler, segmentasyon ve gelişmiş analitik yöntemlerin entegrasyonu hakkında fikir vermektedir. CLV ve RFM'in daha spesifik ve sofistike bağlamlarda kullanımı bu aşamalarda gerçekleşmiştir.

AS6: Müşteri Yaşam Döngüsünde (Örneğin, Edinme, Elde Tutma veya Müşteri Kaybını Önleme) RFM-CLV Modellerini Ne Zaman Benimsenmektedir?

RFM-CLV modelleri, şirketlerin müşteri yaşam döngüsünü farklı aşamalarında işletme hedeflerine yönelik stratejik kararlar almalarını kolaylaştıran araçlardır. Çoğunlukla müşteri edinme, elde tutma ve müşteri kaybını önleme gibi önemli noktalarda kullanılır.

Müşteri Edinme Aşaması: Bu aşamada, modeller kampanya yönetiminde ve yeni müşteri kazanımı için hedef kitle segmentasyonunda önem kazanır. Chan ve Chu'nun (2008) otomotiv sektöründe yaptığı çalışmada, değer bazlı müşteri segmentasyonu ile kampanya etkinliklerinin artırıldığı gözlenmiştir. Albadvi ve Shahbazi (2010) ise, yeni ürün önerisi süreçlerinde ağırlıklandırılmış RFM ile CLV'yi entegre ederek potansiyel müşteri segmentlerine uygun öneriler sunmanın önemini vurgulamıştır.

Müşteri Elde Tutma Aşaması: RFM-CLV modelleri, mevcut müşterilerin davranışlarını anlamak ve bağlılığı artırmak için sıklıkla kullanılmaktadır. Özellikle e-ticaret ve bankacılık gibi sektörlerde, churn analizleriyle müşteri kaybını önleme stratejileri geliştirilmektedir. Cao vd. (2015), OWA ve veri madenciliğini entegre ederek e-ticarete müşteri kaybını analiz etmiştir. Moro vd. (2015) ise, telefonda pazarlama kampanyalarında yapay sinir ağları yardımıyla CLV tahminleri yaparak müşteri bağlılığını artırmaya çözüm üretmiştir.

Müşteri Kaybını Önleme Aşaması: Bu aşamada, müşterilerin kaybını tahmin etmek ve önlemek için RFM-CLV modelleri kullanılmaktadır. Yoseph vd. (2020), veri madenciliği ve kümeleme tekniklerini büyük veri setlerinde uygulayarak müşteri segmentlerini analiz etmiştir. Benzer şekilde, Kanchanapoom ve Chongwatpol (2023), müşteri göç modelleri ile CLV'yi birleştirerek müşteri kaybını önlemek amacıyla, müşteri segmentasyonunu üzerine çalışmıştır.


Bu modeller müşteri edinme aşamasında hedef kitle belirlemek için, elde tutma aşamasında sadakat stratejileri oluşturmak için ve kayıp aşamasında proaktif önlemler geliştirmek için uygulanmaktadır. Modellerin esnekliği, sektörel gereksinimlere ve amaçlara göre farklı analitik tekniklerle bütünleşik kullanım sağlar.

Nerede

AS7: RFM-CLV Modelleri nerede (hangi ülke ve üniversitelerin iş birliğinde) araştırılmaktadır?

Şekil 2.4 RFM-CLV konularında çalışan akademisyenler arasındaki uluslararası iş birliklerini yansıtmaktadır. Grafik, belirli ülkelerin bu alanlarda nasıl etkileşimde bulunduğunu ve akademik üretimdeki merkezi rollerini göstermektedir. ABD ve Birleşik Krallık, ağda en etkili merkezler olarak öne çıkmakta, geniş bir uluslararası iş birliği ağına sahip olduklarını göstermektedir. Bu durum, RFM ve CLV çalışmalarında liderlik ettiklerini ve bu alandaki bilgi paylaşımına önemli katkılar sunduklarını ortaya koymaktadır. Hollanda ve İspanya gibi ülkeler


ise ağdaki farklı kümeleri birbirine bağlayan köprüler olarak işlev görmektedir. Bu ülkeler hem Avrupa içindeki hem de Avrupa dışındaki iş birliklerini güçlendirmektedir. Öte yandan, İran ve Yeni Zelanda gibi ülkeler, daha izole bir konumda bulunmakta ve diğer kümelerle sınırlı etkileşim göstermektedir. Bu, bu ülkelerdeki akademik çalışmaların daha yerel odaklı olduğunu veya uluslararası görünürlüğünün daha düşük olduğunu düşündürmektedir. Genel olarak ağ, RFM ve CLV araştırmalarının giderek küreselleştiğini ve farklı coğrafyalardaki akademisyenler arasında iş birliği ihtiyacının arttığını ortaya koymaktadır.



Şekil 2.4 Uluslararası İş Birlikleri

Şekil 2.5 üniversiteler arasındaki uluslararası iş birliklerini şematik olarak göstermektedir. Ağ yapısı, belirli alanlarda (örneğin, işletme, mühendislik, fen bilimleri) çalışan akademisyenler ve araştırma grupları arasındaki bağlantıları temsil ediyor gibi görünmektedir. Örneğin, Birleşik Krallık'taki London Business School, ABD'deki üniversiteler ve belli başlı Avrupa üniversiteleriyle (örneğin, Barselona'daki Univ Politecn Catalunya) yoğun etkileşim içindedir. Bu durum, CLV-RFM alanlarındaki araştırmalarda üniversitelerin rollerine işaret etmektedir. Benzer şekilde, Hollanda'daki University of Amsterdam ve Malezya'daki University of Sains Malaysia gibi üniversiteler, ağdaki farklı kümeleri birbirine bağlayan "köprü" konumunda yer almaktadır. Diğer yandan, İran'daki Sharif Univ Technol ve Yeni Zelanda'daki Univ Waikato gibi üniversiteler daha izole bir konumda yer almışlardır. Genel olarak, bu görsel CLV-RFM çalışmaları bağlamında üniversiteler arası iş birliklerinin giderek küreselleştiğini ve disiplinler arası çalışmanın öneminin coğrafyalar arasındaki sınırları azalttığını göstermiştir.

Üniversite İşbirliği



Şekil 2.5 Üniversiteler Arasındaki Uluslararası İş Birlikleri

AS8: RFM-CLV Entegrasyonunu nerede (hangi araştırma alanlarında) mevcuttur?

Literatürde, çeşitli sektörlerde RFM ve CLV entegrasyonu üzerine yapılan çalışmaların belirli alanlarda yoğunlaştığı ancak bazı önemli boşlukların olduğu görülmektedir.

Öncelikle, otomotiv sektörü gibi spesifik endüstrilerde yapılan kampanya yönetimi ve müşteri segmentasyonu üzerine çalışmalar (örneğin, Chan, 2008), sektör odaklı stratejilerin geliştirilmesine katkıda bulunmuş ancak bu yöntemlerin diğer sektörlerde uygulanabilirliği bazı sektörlerde daha az ele alınmıştır. Konaklama sektörü gibi müşteri akışının ve etkileşiminin yoğun olduğu bir alanda ise bu bütünlük kullanıma hiç rastlanmamıştır. Benzer şekilde, telekomünikasyon (Moro et al., 2015) ve perakende sektöründe (Martinez et al., 2021) CLV tahmin modellerinin uygulanması yaygın olduğu görülmektedir ancak bu modellerin özellikle sağlık sektörü veya spor pazarlaması gibi daha az çalışılmış alanlarda uygulanabilirliği sınırlı kalmıştır.


Ayrıca, YZ ve veri madenciliği yaklaşımları ile CLV ve RFM entegrasyonunun gelecekteki potansiyel kullanım alanları hala tam olarak yaygınlaşmamıştır. Örneğin, Liu ve Shih (2005) ve De Marco et al. (2021), müşteri segmentasyonu ve ürün öneri sistemlerinde hibrit ve sinir ağları tabanlı yaklaşımları çalışmıştır. Ancak, bu tekniklerin platform işletmeleri veya çok kanallı hizmet sağlayıcıları gibi dinamik pazar koşullarına sahip sektörlerde nasıl optimize edilebileceği üzerine araştırmalar ve uygulamalar sınırlı kalmıştır.

Daha spesifik bir boşluk, farklı pazarlar arasındaki varyasyonları ve kültürel faktörlerin etkisini ele alan çapraz-kültürel karşılaştırmalı çalışmalardır. Örneğin, Ascarza ve Hardie (2013) ve Liao vd. (2014), belirli pazarlar için müşteri davranışı ve sadakat modelleri çalışmışlardır fakat bu modellerin küresel ölçekteki uygulaması veya farklı demografilerdeki performansı sınırlı bilgi vardır.

Kim

AS9: RFM-CLV Entegrasyonuna İlişkin Araştırmaya Katkıda Bulunan Önde Gelen Yazarlar, Kimlerdir?


Şekil 2.6, RFM-CLV alanında çalışan akademisyenler arasındaki uluslararası iş birliği ağını göstermektedir. Ağ yapısı, araştırmacılar ve çalışma grupları arasındaki etkileşim ve bağlantıları temsil etmektedir. Şekil 2.6’da düğümlerin büyümesi yazarların yayın sayısı, bağlantıların büyümesi ise iş birliği sayısı ile ilişkilidir. Genel olarak iş birliklerinin geçişken olduğu gözlemlense de Fader ve Hardie’nin daha izole bir konumda kaldığı anlaşılmaktadır.



Şekil 2.6 RFM-CLV Alanında Çalışan Akademisyenler Arasındaki Uluslararası İşbirliği

Şekil 2.7 ise, RFM-CLV konusunda öne çıkan akademisyenlerin yayın performanslarının yıllara göre değişimini göstermektedir. Grafikte, her bir yazarın makale sayısındaki artış veya azalış trendi görselleştirilmiştir. Örneğin, Hardie, B. G. ve Fader P.S.'nin daha uzun bir süreyle makale ürettiği, Liu D.R. ve Shih Y.Y.'nin daha önceki yıllarda yayın faaliyetleri yürüttüğü anlaşılmaktadır. Diğer RFM-CLV konusunda birçok yazarın ise 2010’lu yıllardan sonra yayın hayatına başladığı görülmektedir.

Authors' Production over Time



Şekil 2.7 RFM-CLV konusunda öne çıkan akademisyenlerin yayın performanslarının yıllara göre değişimini

Nasıl

AS10: RFM ölçümleri CLV tahminlerinin doğruluğunu ve uygunluğunu nasıl artırır?

Tablo 2.1’de RFM ve CLV’nin entegrasyonuna örnek olan çalışmalar incelendiğinde farklı alanlardaki çalışmalar, RFM ölçümlerini öngörücü modellemeye entegre etmenin segmentasyon hassasiyetini artırdığını ve müşteri değeriyle uyumlu hedefli stratejilere geliştirilmesine olanak sağladığını göstermektedir. Buna örnek olarak, Chan (2008) bir otomobil perakende kampanyasında RFM ölçümlerini kullanarak yüksek değerli müşteri segmentlerini belirlemiş ve kampanya yönetimindeki etkinliğini artırmıştır. Benzer şekilde, RFM analizini kümeleme süreçleri ile işbirlikçi filtrelemeyle birleştirmiş ve CLV’e göre uyarlanmış müşteri segmentlerine ürün önerileriyle sonuçlanmıştır (Lin vd., 2021; Liu ve Shih, 2005)

RFM modellerinin uyarlanabilirliği, Delta modeli (Hajipour ve Esfahani, 2019) ve bulanık çıkarım sistemleri (Zoeram ve Mazidi, 2018) gibi uygulamalarda açıktır; bunlar, müşteri göçünü ve sadakatini hesaba katmak için geleneksel RFM yaklaşımlarını bir üst düzeye taşımıştır. Bu örnekler, RFM ölçümlerinin hem geleneksel hem de gelişmiş CLV modelleri için temel görevi gördüğünü, kuruluşların müşterileri doğru bir şekilde segmentlere ayırmasını ve gelecekteki davranışları tahmin etmesini sağlamıştır. Bununla birlikte pazarlama çabalarını kişiselleştirmesini sağlayarak daha iyi müşteri elde tutma ve değer optimizasyonuna geliştirdiğini göstermiştir.

AS11: Gelecekteki arařtırmalar mevcut RFM-CLV entegrasyon metodolojilerinin sınırlamalarını nasıl ele alabilir?

Gelecekteki arařtırmalar, mevcut metodolojilerde bulunan çeřitli sınırlamaları ele alarak RFM-CLV entegrasyonunu geliřtirebilir. Öncelikle, bağlamsal çeřitlilik daha fazla arařtırılmalıdır. Mevcut çalışmalar genellikle e-ticaret, sigorta veya bankacılık gibi belirli sektörlerle odaklanmıştır fakat bu metodolojilerin saėlık, spor, konaklama pazarlaması gibi daha az çalışılmış alanlara uygulanmasında sınırlı kalmıştır. İkinci olarak, biliřsel analitik (De Marco vd., 2021) ve sinir aėları (Moro vd., 2015) dahil olmak üzere hibrit modelleme yaklaşımları gibi metodolojik geliřmeler, öngörücü doėruluėu ve segmentasyon ayrıntısını geliřtirmek için ıřık tutmaktadır. Gelecek çalışmalarda, varyasyonel otokodlayıcılar (Hasumoto ve Goto, 2022) veya kümelenme ölçümleri (Zhang vd., 2015) gibi ML tekniklerinin müşteri yařam boyu deėer tahminlerini nasıl iyileřtirebileceėi arařtırılabilir.

Son olarak, Yan vd. (2018) ve Singh ve Singh (2016) tarafından önerilen demografik, davranıřsal ve bağlamsal verileri RFM ölçümleriyle entegre eden çok boyutlu analizler, mevcut modellerin hızla deėiřen tüketici davranıřına uyum saėlama yeteneėindeki boşlukları keřfedip geliřtirebilir. Örnek olarak, Tarokh ve EsmaeiliGookeh (2019) tarafından gösterildiėi gibi, müşteri etkileřimlerinden türetilen gizli deėiřkenleri dahil etmek, modellerin tahmin derinliėini geliřtirebilir. Ölçeklenebilirlik ve gerček zamanlı adaptasyon bu bağlamda önem arz etmektedir. Yoseph vd. (2018) çalışmaları gibi, dinamik veri yapıları ve uygulama alanları için ML modelleriyle genişletilebilen büyük veri kümelerini segmentlere ayırmada kümeleme tekniklerinin yetenekleri kullanılabilir.

Tablo 2.1 RFM ve CLV'nin Entegrasyonu Üzerine Sistemik Literatür Taraması

Yazar(lar)	Çalışma Başlığı	Araştırma Alanı	Model/ Yaklaşımı	RFM ve CLV Entegrasyonu Nasıl Kullanılmış	Segmentasyon Var/Yok
Cao, J., Yu, X., ve Zhang, Z. (2015)	Integrating OWA and data mining for analyzing customers churn in E-commerce	E-ticaret	OWA ve veri madenciliği	CLV için OWA ağırlıkları belirlenmiş ve müşterilerin terk davranışları analiz edilmiş	Var
Albadvi, A., ve Shahbazi, M. (2010)	Integrating rating-based collaborative filtering with customer lifetime value: New product recommendation technique	Öneri Sistemleri	Derecelendirme tabanlı iş birliği filtresi ile CLV	CLV değerleri kullanılarak öneri sistemine entegre edilmiş	Yok
Zhang, Y., Bradlow, E. T., ve Small, D. S. (2015)	Predicting customer value using clumpiness: From RFM to RFMC	Pazarlama	RFMC modeli	"Clumpiness" metriği ile RFM analizini genişletmiş	Yok
Heldt, R., Silveira, C. S., ve Luce, F. B. (2021)	Predicting customer value per product: From RFM to RFM/P	Perakende	RFM/P modeli	Ürün başına müşteri değerini hesaplamak için genişletilmiş bir RFM modeli	Var
De Marco, M. vd. (2021)	Cognitive analytics management of the customer lifetime value: an artificial neural network approach	Yapay Zeka ve Pazarlama	Yapay Sinir Ağları	CLV tahmini için kognitif analitik yönetim modeli kullanılmış	Var

Moro, S., Cortez, P., ve Rita, P. (2015)	Using customer lifetime value and neural networks to improve the prediction of bank deposit subscription	Bankacılık	Yapay Sinir Ağları	CLV değerleri tele-pazarlama kampanyalarının iyileştirilmesi için kullanılmış	Yok
Hızıroğlu, A. Vd. (2018)	An empirical assessment of customer lifetime value models within data mining	Veri Madenciliği	CLV modellerinin ampirik değerlendirmesi	Veri madenciliği yöntemleri ile müşteri segmentasyonu ve CLV analizi yapılmış	Var
Kanchanapoom, K., ve Chongwatpol, J. (2023)	Integrated customer lifetime value (CLV) and customer migration model to improve customer segmentation	Müşteri Segmentasyonu	CLV ve Müşteri Göç Modeli	CLV ve müşteri göçü birlikte analiz edilerek segmentasyon yapılmış	Var
Binh, T. V. vd. (2021)	Measure of CLV toward market segmentation approach in the telecommunication sector (Vietnam)	Telekomünikasyon	CLV ve Pazar Segmentasyonu	CLV ölçümleri segmentasyon için kullanılmış	Var
Liu, D. R., ve Shih, Y. Y. (2005)	Hybrid approaches to product recommendation based on customer lifetime value and purchase preferences	Ürün Öneri Sistemleri	Hibrit Yaklaşım	CLV ve müşteri tercihleri birlikte analiz edilerek ürün önerisi yapılmış	Yok
Ravasan, A. Z., ve Mansouri, T. (2018)	A fuzzy ANP based weighted RFM model for customer segmentation in auto insurance sector	Sigortacılık	Bulanık ANP ile ağırlıklandırılmış RFM	RFM ağırlıkları belirlenerek müşteri segmentasyonu yapılmış	Var
Hasheminejad, S. M. H., ve Khorrami, M. (2020)	Clustering of bank customers based on lifetime value using data mining methods	Bankacılık	Veri Madenciliği	Banka müşterileri CLV bazlı segmentasyon ile gruplandırılmış	Var
Lin, R. H. vd. (2021)	Applied big data analysis to build customer product recommendation model	Büyük Veri ve Öneri Sistemleri	Büyük Veri Analizi	CLV ve müşteri tercihleri birleştirilerek ürün öneri modeli geliştirilmiş	Yok

Alizadeh Zoeram, A., ve Karimi Mazidi, A. R. (2018)	New approach for customer clustering by integrating the LRFM model and fuzzy inference system	Müşteri Kümelenendirme	LRFM ve Bulanık Mantık	LRFM modeli ve bulanık çıkarım sistemi kullanılarak müşteri grupları oluşturulmuş	Var
Fader, P. S., Hardie, B. G., ve Lee, K. L. (2005)	RFM and CLV: Using iso-value curves for customer base analysis	Pazarlama	İzodeğer Eğrileri	CLV analizi için RFM isodeğer eğrileri kullanılmış	Yok
Martínez, R. G. vd. (2021)	An RFM model customizable to product catalogues and marketing criteria using fuzzy linguistic models	Perakende	Bulanık Dilsel Modeller	Ürün kataloglarına uyarlanabilir RFM modeli geliştirilmiş	Var
Qiasi, R. vd. (2012)	Developing a model for measuring customer's loyalty and value with RFM technique and clustering algorithms	Sadakat ve Değer Analizi	RFM ve Kümeleme Algoritmaları	RFM ve kümeleme algoritmaları ile müşteri sadakati ve değeri ölçülmüş	Var
Yan, C. vd. (2018)	An integrated method based on hesitant fuzzy theory and RFM model to insurance customers' segmentation and lifetime value determination	Sigortacılık	Bulanık Mantık ve RFM	Bulanık teoriler ve RFM modeli birleştirilerek müşteri değerleri belirlenmiş	Var
Jamal, Z., ve Zhang, A. (2009)	2008 DMEF customer lifetime value modeling (Task 2)	CLV Modelleme	CLV Modelleme	2008 DMEF yarışması verileriyle CLV analizi yapılmış	Yok

Walsh, G. vd. (2018)	Assessing the effects of multichannel service provider corporate reputation on customer new product adoption and RFM value	Çok Kanallı Pazarlama	RFM Analizi	Şirket itibarı ile müşteri değerleri ve yeni ürün benimseme ilişkisi incelenmiş	Yok
Chouaten, K. vd. (2024)	Unlocking high-value football fans: unsupervised machine learning for customer segmentation and lifetime value	Spor Pazarlaması	Denetimsiz Makine Öğrenmesi	CLV ve segmentasyon spor pazarlamasında yüksek değerli taraftarları belirlemek için kullanılmış	Var
Hajipour, B., ve Esfahani, M. (2019)	Delta model application for developing customer lifetime value	CLV Geliştirme	Delta Model	Delta modeli kullanılarak müşteri yaşam boyu değerleri geliştirilmiş	Yok
Safari, F., Safari, N., ve Montazer, G. A. (2016)	Customer lifetime value determination based on RFM model	Pazarlama Zekası ve Planlama	RFM tabanlı CLV modeli	RFM metrikleri üzerinden müşteri değer analizi	Var
Fader, P. S., ve Hardie, B. G. (2009)	Probability models for customer-base analysis	Etkileşimli Pazarlama	Olasılık tabanlı modeller	CLV hesaplamasında olasılık modelleri kullanılmış	Yok

Yang, T., Feng, X., Wu, Y., Wang, S., ve Xiao, J. (2018)	Human dynamics in repurchase behavior based on comments mining	İnsan Dinamikleri	Yorum madenciliği ile davranış modelleme	CLV ile doğrudan bağlantı belirtilmemiş	Yok
Liu, F., Zhao, S., ve Li, Y. (2017)	How many, how often, and how new? A multivariate profiling of mobile app users	Tüketici Hizmetleri	Çok değişkenli modelleme	RFM ile kullanıcı davranış profillemesi	Yok
Singh, S., ve Singh, S. (2016)	Accounting for risk in the traditional RFM approach	Yönetim Araştırması	Geleneksel RFM'e risk entegrasyonu	RFM üzerinden risk analizi	Yok
Hosseini, M., Abdolvand, N., ve Harandi, S. R. (2022)	Two-dimensional analysis of customer behavior in traditional and electronic banking	Dijital İşletme	İki boyutlu analiz modeli	RFM tabanlı müşteri davranış analizi	Var
Hasheminejad, S. M. H., ve Khorrami, M. (2018)	Data mining techniques for analyzing bank customers: A survey	Veri Madenciliği	Veri madenciliği yöntemleri	CLV ve RFM metrikleriyle müşteri analizi	Var
Shim, B., Choi, K., ve Suh, Y. (2012)	CRM strategies for a small-sized online shopping mall based on association rules and sequential patterns	CRM	Öneri sistemleri ve RFM metrikleri	RFM ile müşteri davranış analizi	Var

Fader, P. S., Hardie, B. G., ve Shang, J. (2010)	Customer-base analysis in a discrete-time noncontractual setting	Pazarlama Bilimi	Ayrık zamanlı modeller	CLV ve müşteri davranış analizi	Yok
Parracho Sant'Anna, A., ve Otavio de Araujo Ribeiro, R. (2009)	Statistical modeling and probabilistic composition in the prediction of the customer lifetime value	Benchmarking	İstatistiksel modelleme	CLV hesaplamaları	Yok
Tarokh, M. J., ve EsmaeiliGookeh, M. (2019)	Modeling patient's value using a stochastic approach: An empirical study in the medical industry	Sağlık Sektörü	Stokastik modelleme	Hasta değer analizi	Yok
Kumar, V., Pozza, I. D., Petersen, J. A., ve Shah, D. (2009)	Reversing the logic: The path to profitability through relationship marketing	Etkileşimli Pazarlama	İlişki pazarlaması	CLV'yi karlılık analizi için kullanmış	Yok
Fernández del Río, A., Guitart, A., ve Periánz, Á. (2021)	A time series approach to player churn and conversion in videogames	Akıllı Veri Analitiği	Zaman serisi analizi	CLV'yi oyuncu davranış analiziyle ilişkilendirmiş	Yok

Hosseini, Z. Z., ve Mohammadzadeh, M. (2016)	Knowledge discovery from patients' behavior via clustering-classification algorithms based on weighted eRFM and CLV model: An empirical study in public health care services	Sağlık Hizmetleri	Ağırlıklı eRFM modeli	CLV ile hasta davranışı analizi	Var
Januszewski, F. (2011)	Possible applications of instruments of measurement of the customer value in the operations of logistics companies	Lojistik Yönetimi	CLV ölçüm araçları	CLV'yi lojistik operasyonlarına uyarlamış	Yok
Hasumoto, K., ve Goto, M. (2022)	Predicting customer churn for platform businesses: using latent variables of variational autoencoder as consumers' purchasing behavior	Platform İşletmeleri	Değişken Otomatik Kodlayıcı	CLV ve müşteri davranış analizi	Var
Ascarza, E., ve Hardie, B. G. (2013)	A joint model of usage and churn in contractual settings	Pazarlama Bilimi	Kullanım ve ayrılma analizi modeli	CLV ile müşteri kaybı analizi	Yok
Liao, Y. W., Wang, Y. S., ve Yeh, C. H. (2014)	Exploring the relationship between intentional and behavioral loyalty in the context of e-tailing	E-Ticaret	Niyet ve davranış sadakati	CLV ile doğrudan bağlantı belirtilmemiş	Yok

ÜÇÜNCÜ BÖLÜM

MÜŞTERİ YAŞAM BOYU DEĞERİ TAHMİNİ VE SEGMENTASYONU İÇİN RFM VE MAKİNE ÖĞRENİMİNİN ENTEGRE EDİLMESİ: OTEL SEKTÖRÜ İÇİN WEB TABANLI BİR UYGULAMA

3.1. Çalışmanın Amacı ve Önemi

Bu tez çalışmasının temel amacı, otel sektörüne özel olarak uyarlanmış gelişmiş ML tekniklerini kullanarak CLV için bir öngörücü model geliştirmektir. Çalışma, otel işletmelerinin yüksek değerli müşterilerinin belirlenmesine, pazarlama stratejilerinin geliştirilmesine ve genel müşteri deneyimlerini iyileştirmelerine yardımcı olmayı amaçlamaktadır. Bununla birlikte, bu araştırma CLV modelini kullanıcı dostu bir web uygulamasına dahil ederek otel yöneticilerinin karar alma süreçlerinde 5 önemli özelliği olan hacim (volume), hız (velocity), çeşitlilik (variety), doğruluk (veracity) ve değeri (value) efektif bir şekilde kullanmayı amaçlamaktadır (Centobelli ve Ndou, 2019).

Çalışmanın önemi, özellikle veri odaklı stratejilere duyulan ihtiyaç bağlamında otel sektöründeki çeşitli zorlukları ele alma becerisidir. Çalışma, otel işletmelerine müşteri tabanlarını öngörülen CLV'lerine göre etkili bir şekilde segmentlere ayırmaları için araçlar sağlamaktadır. Bu segmentasyon, kişiselleştirilmiş ve hedefli pazarlama stratejilerine imkân tanıma ve pazarlama çabalarının hem ilgili hem de etkili olmasını sağlama potansiyeline sahiptir. Müşteri davranışını detaylı olarak anlayarak oteller, belirli müşteri gruplarının ihtiyaç ve tercihlerine daha iyi hitap edebilir ve böylece etkileşimi ve memnuniyeti artırabilir.

CLV'yi tahmin etmek, otel işletmelerinin kaynaklarını daha stratejik bir şekilde önceliklendirmelerine olanak tanımaktadır. Yüksek değerli müşteriler, sadakat programları, özel teklifler veya kişiye özel deneyimler aracılığıyla elde tutulabilirken, pazarlama çabaları uzun vadeli değer olasılığı en yüksek olan potansiyel müşterileri edinmeye yönlendirilebilir. Bu ikili odak müşteri memnuniyetini artırmakla kalmaz, aynı zamanda sürdürülebilir büyümeye de katkıda bulunur. Kaynak tahsisi, özellikle rekabetçilik seviyesi yüksek otelcilik sektöründeki pazarlama süreçlerine önemli bir rol oynamaktadır (Lin ve Wu, 2008). Çalışma, yatırım getirisini en yüksek seviyede üretme olasılığı olan müşteri segmentlerini belirleyerek otellerin pazarlama bütçelerini daha etkili bir şekilde tahsis etmelerine yardımcı olacaktır. Bu, pazarlamaya harcanan her parasal birimin daha yüksek rezervasyonlar, artan elde tutma veya gelişmiş marka sadakati gibi somut sonuçlara katkıda bulunmasını sağlamaktadır (Vives, Jacob ve Payeras, 2018). CLV modelinin web tabanlı bir uygulamaya entegre edilmesi, otel

yöneticilerinin karar alma süreçlerinde gerçek zamanlı müşteri verilerinden yararlanmalarını sağlama potansiyeli taşımaktadır. Uygulama, uygulanabilir içgörüler ve öngörücü analizler sağlayarak otellerin dinamik fiyat ayarlamaları, kişiselleştirilmiş hizmet teklifleri ve sadakat programı geliştirmeleri gibi bilinçli kararlar almalarına olanak tanıyacaktır. Bu veriye dayalı yaklaşım, operasyonel ve stratejik kararların gelir büyüme hedefleriyle uyumlu olmasını sağlayacaktır (Vidal vd., 2024).


3.2. Araştırma Tasarımı

Bu araştırmada, otel sektöründe CLV tahmini için ML modelleri, müşteri davranışlarının analizine dayalı olarak kapsamlı bir yaklaşımla entegre edilmiştir. Modelleme süreci hem denetimli hem de denetimsiz öğrenme tekniklerini bir araya getirerek CLV tahmininde yüksek doğruluk ve ölçeklenebilirlik sağlamayı amaçlamıştır. Çalışma boyunca veri hazırlama, veri analizi, modelleme ve değerlendirme gibi işlemler Şekil 3.1'deki gibi yapılandırılmıştır.

Bu bağlamda, Recency (son alışveriş tarihi üzerinden geçen süre), Frequency (alışveriş sıklığı) ve Monetary (toplam harcama) bileşenlerini temel alan RFM analizi, müşteri segmentasyonu ve CLV tahmini için uygun bir temel oluşturmuştur. RFM segmentlerini üreten değişkenler, CLV tahmini için oluşturulan değişken seti arasında yer almış ve müşterilerin gelecekteki davranışlarını anlamada kritik bir rol oynamıştır.

ML modellerinin entegrasyonunda, denetimli öğrenme algoritmaları olarak XGBoost, CatBoost ve LightGBM, büyük değişken setlerinde yüksek performans sergilemesi nedeniyle tercih edilmiştir (Szczepek, 2022). Bu modeller, RFM skorları, müşteri demografik bilgileri, rezervasyon sıklığı ve harcama alışkanlıkları gibi değişkenlerle eğitilmiş; parametre optimizasyonu aracılığıyla doğruluk artırılmıştır. Aynı zamanda, denetimsiz öğrenme tekniği olan K-Means algoritması ile müşteri segmentasyonu gerçekleştirilmiş ve RFM skorlarının yanı sıra müşteri davranışlarını temsil eden diğer özellikler değerlendirilmiştir. Kümelenme analizi, farklı müşteri gruplarının özelliklerini ortaya koyarak, her segmentin CLV üzerindeki etkilerini anlamayı mümkün kılmıştır.

Bu süreçte, RFM analizi ile ML modelleri arasında çift yönlü bir ilişki kurulmuş, RFM skorları CLV tahmini için girdiler olarak kullanılırken, tahmin edilen CLV değerleri farklı müşteri segmentlerini analiz etmek için geri besleme sağlamıştır. Bu yaklaşımla, müşteri segmentasyonunun doğruluğunun artırılması ve her segment için özelleştirilmiş stratejiler geliştirilmesine olanak tanınacağı düşünülmüştür.



Şekil 3.1 Araştırma Tasarı

Geliştirilen model ve segmentasyon sonuçları, otel yöneticilerinin karar alma süreçlerini desteklemek amacıyla kullanıcı dostu bir web uygulamasına entegre edilmiştir. Bu web tabanlı uygulamasıyla, müşteri segmentleri ve tahmin edilen CLV değerlerine dayalı gerçek zamanlı analizler sunulmuş; kaynak tahsisi, fiyatlandırma stratejileri ve müşteri etkileşimi gibi stratejik kararların alınmasını kolaylaştırması amaçlanmıştır. Ayrıca, uygulama aracılığıyla yüksek değerli müşterilerin belirlenmesi ve elde tutulması, pazarlama stratejilerinin optimize edilmesi ve müşteri memnuniyetinin artırılması hedeflenmiştir.

Bu bütünleşik yapılandırma, CLV tahmini ve müşteri segmentasyonu arasındaki sinerjiyi güçlendirerek, otel sektöründe müşteri değerinin maksimize edilmesi ve gelir artırıcı stratejilerin uygulanması için bir çerçeve sunmaktadır.

Aşağıda çalışmayı yönlendirmek ve amaçlara ulaşmak için, araştırmanın temelini oluşturan araştırma sorularını içermektedir.

S1: ML modelleri, otel sektöründe CLV'yi yüksek doğrulukla tahmin etmek için uygulanabilir mi?

S2: Otel müşterileri için CLV'yi etkileyen en önemli faktörler nelerdir ve bu faktörler çeşitli müşteri segmentlerinde nasıl farklılık gösterir?

S3: Tahmin edilen CLV, müşteri edinimi, elde tutma çabaları ve kişiselleştirilmiş hizmet teklifleri dahil olmak üzere pazarlama stratejilerini optimize etmek için hangi şekillerde kullanılabilir?

S4: Bir CLV tahmin modelini web tabanlı bir uygulamaya entegre etmek, otel yöneticileri için karar alma süreçlerinde ne şekilde kullanılır?

Araştırmanın amaçlarına yönelik hazırlanan sorular doğrultusunda otel yönetim sistemlerinden elde edilen veri, müşteri rezervasyon bilgileri, harcama kalıpları ve demografik özellikleri içermektedir. Verilerin toplanması sürecinde, doğruluk ve bütünlük sağlamak amacıyla eksik, tutarsız veya hatalı kayıtlar tespit edilerek temizlenmiştir. Veri ön işleme aşaması, modelleme sürecinin temelini oluşturmuş ve ML algoritmalarının etkin bir şekilde uygulanabilmesi için özenle tasarlanmıştır. Eksik değerlerin yönetimi, aykırı verilerin düzeltilmesi, gereksiz sütunların çıkarılması, kategorik değişkenlerin sayısal değerlere dönüştürülmesi, değişkenlerin ölçeklendirilmesi gibi süreçler detaylandırılmıştır. Değişken mühendisliği sürecinde, RFM skorlarının türetilmesi de bu aşamanın önemli bir parçası olarak, müşteri segmentasyonu ve CLV tahmini için gerekli temel bileşenler oluşturulmuştur. Bu işlemler ilerleyen bölümlerde detaylı olarak anlatılacaktır.

3.2.1. Veriseti

Araştırmada kullanılan veriler, Antalya’da (Türkiye) bulunan 5 yıldızlı bir otelden toplanmıştır. Araştırmanın amacı kapsamında veri setleri ortak “GuestId” değişkenine sahip misafir konaklama verisi ve otelde bulunulan ücretli hizmet kullanımlarından oluşmaktadır. Toplamda 103.433 müşteri konaklama ve 2.127.856 ekstra kullanım kaydını içermektedir. Gerekli ön işlemler tamamlandıktan sonra nihai veri 16.399 müşteri konaklama ve 2.037.986 ekstra kullanım kayıtları POS (Point of Sale) analize sokulmuştur. Çalışmada kullanılan veri, otel işletmesinin 2021 yıllık rezervasyon verileri ile müşteri etkileşimlerini içeren büyük bir veri kümesinden elde edilmiştir. Veriler, otelin rezervasyon yönetim sistemi, satış veri tabanları ve müşteri etkileşimlerini üzerinden sağlanmıştır. Veri setinde yer alan değişkenler arasında müşteri demografik bilgileri, rezervasyon geçmişi, ödeme geçmişi ve otel içindeki harcama alışkanlıkları bulunmaktadır. Çalışma, verilerin anonimleştirilmiş olmasına özen göstererek müşteri gizliliğini korumaktadır.

Rezervasyon geçmişini yer aldığı veri seti, 'GuestId', 'Nationality', 'Repeat', 'Res_Id', 'Rez_Status', 'Res_RecordDate', 'Res_CINDate', 'Board', 'Res_Market', 'Res_RoomType', 'Res_Pax', 'Res_FreeChild', 'Res_PaidChild', 'Res_Baby', 'RoomRevenue', 'TotalNights' gibi değişkenlerden oluşmaktadır. 'GuestId', 'Repeat', 'Res_Id', 'Res_Pax', 'Res_FreeChild', 'Res_PaidChild', 'Res_Baby', 'RoomRevenue', 'TotalNights' değişkenleri sayısal değerler, 'Res_RecordDate', 'Res_CINDate' değişkenleri tarih değeri ve 'Nationality', 'Repeat', 'Rez_Status', 'Board', 'Res_Market', 'Res_RoomType' değişkenleri ise kategorik değerli değişkenlerdir.

Otel içindeki harcama alışkanlıklarını içeren pos verileri seti ise 'GuestId', 'RoomRevenue', 'ExtraRevenue', 'POS_ReservationId', 'POS_Quantity', 'POS_NetAmount' sayısal değerli değişkenleri, 'POS_Date' değişkeni tarih değerli değişken ve 'DepartName', 'POS_Department', 'POS_MainGroup', 'POS_SubGroup' değişkenleri ise kategorik değişkenleri içermektedir.

Veri setinde bulunan değişkenleri demografik, davranışsal, coğrafi vb. olarak sınıflandırmak her değişkenin müşteriye tanımadaki veya davranış kalıplarını anlamadaki rolünü ortaya koymaktadır. Demografik değişkenler, müşterilerin bireysel özelliklerini veya kişisel durumlarını tanımlayan verilerdir. Davranışsal değişkenler, müşterilerin otel hizmetlerini nasıl kullandığını veya rezervasyon davranışlarını yansıtmaktadır. Coğrafi değişkenler, müşterinin bulunduğu veya geldiği konumlarla ilgili bilgiler içermektedir. Tarih değişkenleri ise işlemlerin ve davranışların gerçekleştiği zaman ve zaman aralığı hakkında bilgi

vermektedir. Bu bağlamda veri setinde yer alan değişkenleri Tablo 3.1'deki gibi sınıflandırabiliriz.

Tablo 3.1 Rezervasyon ve Pos işlem Veri Setlerinde Yer Alana Değişkenler


Değişken Kategorisi	Değişken Adı	Açıklama
Demografik Değişkenler	Nationality	Müşterinin uyruk bilgisi.
	Res_Pax	Rezervasyondaki toplam kişi sayısı.
	Res_FreeChild	Rezervasyondaki ücretsiz çocuk sayısı.
	Res_PaidChild	Rezervasyondaki ücretli çocuk sayısı.
	Res_Baby	Bebek sayısı.
Davranışsal Değişkenler	Repeat	Müşterinin tekrarlayan bir müşteri olup olmadığını gösterir (sadakat).
	Rez_Status	Rezervasyon durumu (örneğin, tamamlanmış, iptal edilmiş).
	Res_Market	Rezervasyonun pazar segmenti (örneğin, bireysel, grup).
	Res_RoomType	Müşterinin seçtiği oda tipi.
	Board	Seçilen yemek planı (örneğin, yalnızca oda, yarım pansiyon).
	RoomRevenue	Oda gelirleri.
	ExtraRevenue	Ek harcamalar (örneğin, restoran, spa).
	POS_ReservationId	Harcamaların rezervasyon kimliğiyle ilişkisi.
	POS_Quantity	Yapılan satın alımın miktarı.
	POS_NetAmount	Satın alımın toplam net tutarı.
	POS_DepartmanName	Satın alınan ürünün ait olduğu departman.
	POS_Product	Satın alınan ürün.
Coğrafi Değişkenler	Nationality	Müşterinin uyruğu, aynı zamanda coğrafi bir özellik olarak da değerlendirilebilir.
Tarih Değişkenleri	Res_RecordDate	Rezervasyonun yapıldığı tarih.
	Res_CINDate	Rezervasyonun check-in tarihi.
	POS_Date	POS işleminin gerçekleştiği tarih.

3.2.2. Ön İşleme

Tezin bu aşaması, veri temizleme ile başlamaktadır. Ardından eksik verilerin kontrol edilmesi, aykırı değerlerin tespiti, verilerin normalize edilmesi ve uygun formatlara dönüştürülmesi gibi adımları içermektedir. Böylece yapılan analizlerle ilgili muhtemel sorunların önüne geçmek mümkündür. Söz gelimi bir aykırı değer ya da kayıp verinin sonuçları istenilmeyen şekilde etkilemesi ve analiz sonuçlarının yanlış yorumlanması istenmeyen bir sonuç olarak karşımıza çıkma potansiyeli taşımaktadır. Benzer şekilde verilerin dönüşümü olmadan kategorik ya da sayısal verilerin uygun analizlerde kullanımı da mümkün olmayacaktır.

3.2.2.1. Veri temizleme

Veri analizi sürecinin kritik adımlarından biri olan veri temizliği, verilerin doğruluğunu ve analiz için uygunluğunu sağlamak amacıyla gerçekleştirilir. Bu süreçte (Şekil 3.2), eksik veriler uygun yöntemlerle doldurulur ya da analiz açısından anlamlı bir katkı sunmuyorsa veri setinden çıkarılır. Eksik veri yönetimi, veri kümesinin genel bütünlüğünü korumak için dikkatle yapılır. Ayrıca, hatalı veya tutarsız değerler tespit edilerek, gerektiğinde bu değerler düzeltilir ya da yeniden yapılandırılır. Veri temizliği, analiz sonuçlarının güvenilirliğini artırmak ve doğru çıkarımlar elde etmek için temel bir adımdır. Bu çalışma kapsamında, eksik veri doldurma işlemleri için istatistiksel yöntemler kullanılmış, tutarsızlıklar ise manuel veya otomatik doğrulama süreçleriyle giderilmiştir.



Şekil 3.2 Rezervasyon ve POS işlem verilerinin filtreleme, eksik veri ayıklama ve tutarsız kayıtların çıkarılması adımlarıyla analiz için temizlenme süreci

3.2.2.2. Veri Dönüşümü

Bu bölümde, ham verilerin analiz için uygun hale getirilmesi amacıyla gerçekleştirilen dönüşüm işlemleri ele alınmıştır. Kategorik veriler sayısal değerlere dönüştürülmüş (bkz. 3.2.2.2.3. Etiketleme), veri ölçeklendirilmiş (bkz. 3.2.2.2.4. Normalizasyon ve Standardizasyon İşlemleri) ve CLV hesaplanmasını ve tahminine katkı sağlayacak yeni değişkenler türetilmiştir (bkz. 3.2.2.2.1. CLV Bileşenlerinin Hesaplanması; 3.2.2.2.2. Değişken Mühendisliği). Bu adımlar, modelin doğruluğunu artırmak için önemlidir.

3.2.2.2.1. CLV Bileşenlerinin Hesaplanması

Bu bölümde, CLV hesaplaması için kullanılan bileşenler açıklanmıştır ve hesaplanmıştır. Bu üç bileşen, her müşterinin CLV skorunu hesaplamak adına birleştirilmiş ve modelleme sürecinde kullanılmak üzere analiz edilmiştir.

- **Müşteri Edinme Maliyeti (CAC):** Müşteri kazanımı için yapılan toplam pazarlama ve satış maliyetlerinin, kazanılan yeni müşteri sayısına bölünmesiyle hesaplanmıştır.

Hesaplama veri setinde bulunan GuestId (Eşsiz müşteri numaraları) değişkeni kullanılmıştır.

$$CAC = \frac{\text{Toplam Pazarlama Maliyeti} + \text{Toplam Satış Maliyeti}}{\text{Yeni Müşteri Sayısı}}$$

Örneğin;

Pazarlama maliyeti: 10,000 TL (Bu değişken hesaplama dahil edilen varsayımsal sabit bir değerdir)

Satış maliyeti: 5,000 TL (Bu değişken hesaplama dahil edilen varsayımsal sabit bir değerdir.)

Yeni müşteri sayısı: Benzersiz 'GuestId' 'nin bir kere yer almasıdır.

- Müşteri Kârlılığı: Müşteriden elde edilen toplam gelirden, müşteriye hizmet etmenin maliyetinin çıkarılmasıdır. Hesaplanmasında veri setinde yer alan RoomRevenue (Oda gelirleri) ve POS_NetAmount (Ekstra gelirler) değişkenleri kullanılmıştır.

$$\text{Müşteri karlılığı} = \text{Toplam Gelir} - \text{Servis Maliyetleri}$$

- Müşteri Sadakati ve Müşteri Tutma Oranı: Belirli bir süre içinde birden fazla satın alma gerçekleştiren müşterilerin oranıdır. Veri setinde bulunan GuestId ve POS_ReservationId (Adisyon numarası) değişkenleri hesaplama kullanılmıştır.

$$\text{Müşteri Sadakati ve Tutma Oranı} = \frac{\text{Birden Fazla Satın Alma Yapal Müşteri sayısı}}{\text{Toplam Müşteri Sayısı}}$$

- Ortalama Satın Alma Değeri: Ortalama bir satın alma işleminde harcanan değeri temsil eder. Bu değişkenin oluşturulmasında veri setinde bulunan TotalRevenue ve POS_ReservationId değişkenleri kullanılmıştır.

$$APV = \frac{\text{Toplam Gelir}}{\text{Toplam Rezervasyon Sayısı}}$$

- **Satın Alma Sıklığı:** Satın alma sıklığı, müşterilerin belirli bir dönemde yaptıkları ortalama satın alma sayısını ifade eder. Veri setinde bulunan GuestId ve POS_ReservationId değişkenleri hesaplamada kullanılmıştır.

$$\text{Satın Alma Sıklığı} = \frac{\text{Toplam Rezervasyon Sayısı}}{\text{Toplam Müşteri Sayısı}}$$

- **Müşteri Yaşam Süresi:** Müşteri yaşam süresi (Customer Lifetime), bir müşterinin ilk ve son satın alma tarihi arasındaki süre olarak tanımlanmaktadır. Çalışmada, POS_Date (Satın alma tarihi) bu değişkenin oluşturulmasında kullanılmıştır.

$$\text{Müşteri Ömrü (Gün)} = \text{Son Satın Alma Tarihi} - \text{İlk Satın Alma Tarihi}$$

- **İndirim Oranı:** Gelecekteki nakit akışlarını bugünkü değerine indirmek için kullanılan indirim oranı, çoğunlukla yıllık olarak %10 gibi sabit bir oran alınır.
- **Kar Marjı:** Toplam gelirden, maliyetler çıkarıldıktan sonra kalan orandır. Bu oran aşağıdaki şekilde hesaplanmaktadır:

$$\text{Kar Marjı} = \frac{\text{Toplam Gelir} - \text{Maliyetler}}{\text{Toplam Gelir}}$$

3.2.2.2.2. Değişken mühendisliği

Değişken mühendisliği, verilerin analiz için uygun hale getirilmesidir. Yeni değişkenler oluşturma, veriyi dönüştürme ve anlamlı ilişkiler keşfetmek, modelin performansının etkinliğini arttırmada çok önemlidir. Bu çalışmanın amacına göre çıkardığımız değişkenler detaylı bir şekilde anlatılmıştır.

Rezervasyon penceresi (Leadtime), rezervasyon ile check-in tarihi arasındaki gün sayısını ifade etmektedir. Bu değişkenin amacı rezervasyonun, giriş tarihinden ne kadar önce yapıldığını belirlemektir. Rezervasyon veri setinde bulunan CheckinDate (Giriş Tarihi) ile SalesDate (Rezervasyon Tarihi) değişkenlerinin gün farkı alınarak oluşturulmuştur.

Seyahat Eşlikçisi (Travel Companion), müşterinin kiminle seyahat ettiğini sınıflandırır. Örneğin, yalnız, çift, aile ya da bir grup olarak seyahat edebilirler. Değişkenin oluşturulmasında rezervasyon veri setinde bulunan, Pax (Toplam Yolcu Sayısı), PaidChild (Ücretli Çocuk Sayısı), FreeChild (Ücretsiz Çocuk Sayısı), Baby (Bebek Sayısı) değişkenleri kullanılmıştır.

Rezervasyonda ücretli veya ücretsiz çocuk, bebek yer alıyor ise "WithChildren" olarak etiketlenmiştir. Eğer rezervasyonda ücretli veya ücretsiz çocuk, bebek yok ise rezervasyon kişi sayısına (Pax) göre 1 kişi 'Single', 2 kişi 'Couple', 3 kişi Triple, 4 kişi Quadruple, daha fazla kişi sayısı ise Group olarak etiketlenmiştir.

Sezon Değişkeni, rezervasyon yapılan ayları otel sezonuna göre sınıflandırmaktadır. Ay bilgisi şu şekilde gruplandırılmıştır:

- Ocak-Şubat ve Kasım-Aralık: Winter,
- Mart-Nisan: Spring,
- Mayıs-Haziran: Early Summer,
- Temmuz-Ağustos: High Summer,
- Eylül-Ekim: Autumn,

RFM (Recency, Frequency, Monetary): Müşterilerin davranışlarını anlamak için RFM segmentasyonunda kullanılan üç metrik rezervasyon veri setinde bulunan SalesDate (Rezervasyon Tarihi), CheckinDate (Giriş Tarihi) Room Amount (Toplam Oda Ücreti) gibi değişkenlerden oluşmaktadır.

- Recency (Son rezervasyonu üzerinden geçen süre): Bir müşterinin son check-in tarihinden itibaren geçen gün sayısı. Referans Tarihi ile Son Check-in Tarihi gün farkı sayısıdır.
- Frequency (Rezervasyon sıklığı): Müşterinin yaptığı toplam rezervasyon sayısı.
- Monetary (Toplam harcama): Müşterinin yaptığı tüm harcamaların toplamı.

3.2.2.2.3. Etiketleme

CLV, bağımlı değişken olarak tanımlanmış ve bu değer üzerinde tahminleme yapılması hedeflenmiştir. Böylece, bağımsız değişkenlerin, CLV üzerindeki etkilerinin modellenmesi ve incelenmesi sağlanmıştır. Veri setinden bağımsız değişkenler olarak "Recency", "Frequency", "Monetary", "Cluster", "leadtime", "TotalNights", "Nationality", "Board", "Res_Market", "RoomType", "TravelCompanion" ve "Season" olarak tanımlanmıştır. Bunların seçiminde araştırmanın kapsamı doğrultusunda RFM ve rezervasyon verilerinin birlikte kullanılması amaçlanmıştır. Veri analizi ve ML süreçlerinde, verinin uygun biçime dönüştürülmesi, modelin performansını doğrudan etkileyen kritik bir adımdır. Bu çalışmada, özellikle kategorik değişkenlerin modeller tarafından işlenebilir hale getirilmesi için dönüşüm işlemleri gerçekleştirilmiştir. Veri setinde yer alan "Nationality", "Board", "Res_Market", "Cluster", "Res_RoomType", "TravelCompanion" ve "Season" gibi kategorik değişkenler, LabelEncoder yöntemi kullanılarak etiket kodlamasına tabi tutulmuştur. Bu yöntem, her kategorik sınıfa

benzersiz bir tam sayı atanarak değişkenlerin sayısal temsillere dönüştürülmesini sağlamıştır. Bu dönüşüm, algoritmaların kategorik değişkenleri anlamlı bir şekilde işleyebilmesi için gereklidir ve işlem adımlarında bilgi kaybı olmadan uygulanmıştır.

3.2.2.2.4. Normalizasyon ve Standardizasyon İşlemleri

Ölçekleme, veri setindeki farklı değişkenlerin kıyaslanabilir hale getirilmesi ve bazı algoritmaların daha iyi performans göstermesi için uygulanan bir işlemdir. MinMaxScaler, veri setindeki en küçük ve en büyük değerleri belirli bir aralığa, bu durumda 1 ile 100 arasına, yeniden ölçeklendiren bir yöntemdir. Ölçekleme, özellikle farklı birimlerde ölçülen değişkenlerin etkilerini dengelemek ve algoritmaların doğru sonuçlar üretmesini sağlamak amacıyla tercih edilmiştir. CLV hesaplamasında elde edilen değerler, okunabilirliği ve yorumlana bilirliliği artırmak için MinMaxScaler ile ölçeklendirilmiştir. Bu yöntemle, CLV değerleri 1-100 arası bir aralığa dönüştürülerek puanlanmıştır. Böylece daha büyük veya küçük CLV değerlerinin anlaşılması kolaylaşmıştır. Aynı zamanda RFM analizi için kullanılan Recency, Frequency ve Monetary değişkenleri de farklı ölçeklere sahip olduklarından, K-Means algoritmasında doğru bir segmentasyon sağlanması amacıyla ölçeklendirilmiştir. K-Means algoritması, veri noktalarının birbirine olan uzaklıklarına dayanır ve bu nedenle tüm değişkenlerin aynı aralıkta olması, algoritmanın etkili çalışması için gereklidir. Bu bağlamda, Standart Scaler kullanılmıştır. Standart Scaler, her bir değişkenin ortalama değeri etrafında yeniden dağıtılmasını sağlayarak, her birinin standart sapmasını 1, ortalamasını ise 0 yapar. Bu işlem, tüm verileri aynı ölçek üzerinde değerlendirerek, modelin her bir değişkeni eşit derecede dikkate almasını sağlar.

Standart Scaler kullanımı, K-Means algoritmasının doğru bir segmentasyon yapabilmesi için verileri ölçeklendirirken, MinMaxScaler ise CLV değerlerini 1 ile 100 arasında daha anlaşılır bir forma sokmak için kullanılmıştır.

3.2.2.2.5. Birleştirme

Örnek Veri analizi süreçlerinde, farklı veri kaynaklarının birleştirilmesi, daha kapsamlı ve anlamlı sonuçlar elde edebilmek adına kritik bir adımdır. Bu çalışmada, rezervasyon verileri ile otelde konaklayan misafirlerin POS (Point of Sale) detaylarını içeren veri setleri, GuestId değişkeni kullanılarak entegre edilmiştir.

Rezervasyon veri setinde, misafir davranışlarının incelenmesi amacıyla RFM segmentasyonu gerçekleştirilmiştir. Bu analiz, misafirlerin rezervasyon sıklığı (Frequency), son rezervasyonun üzerinden geçen süre (Recency) ve toplam harcamaları (Monetary) gibi özelliklere dayanarak segmentlere ayrılmasını sağlamıştır. Öte yandan, oteldeki POS

detaylarını içeren veri seti, müşterilerin ekstra hizmetlerden faydalanma davranışlarını analiz etmek için kullanılmış ve bu veri üzerinden CLV hesaplanmıştır.

İki veri setinin GuestId gibi benzersiz bir tanımlayıcı ile birleştirilmesi hem rezervasyon hem de otel içi harcama davranışlarının bütüncül bir şekilde analiz edilmesine olanak tanımıştır. Bu birleştirme süreci, her iki veri kaynağındaki bilgilerin bir araya getirilmesiyle daha zengin bir veri yapısının oluşturulmasını ve misafir davranışlarının daha derinlemesine incelenmesini sağlamıştır. Bu sayede, misafir segmentasyon stratejileri ile misafir değeri analizleri arasında anlamlı ilişkiler kurularak hem operasyonel hem de stratejik karar süreçleri için daha etkili çıktılar elde edilmesi amaçlanmıştır.

Bu tür birleştirme süreçleri, farklı veri kaynaklarının uyumlu hale getirilmesi ve entegre edilmesi ile bilgi kaybı minimuma indirilirken, analiz sonuçlarının güvenilirliğini artırmaktadır.

3.3. Makine Öğrenmesi Modelleri

Bu bölümde, farklı veri setleri üzerinde gerçekleştirilen analiz süreçleri ele alınmıştır. Çalışmada, rezervasyon verileri üzerinden RFM segmentasyonu gerçekleştirilmiş, POS verileri üzerinden CLV hesaplaması yapılmış ve bu iki veri seti birleştirilerek CLV tahmini için ML yöntemleri kullanılmıştır.

3.3.1. RFM Segmentasyon Analizi

RFM analizi, misafir davranışlarını değerlendirmek ve benzer özelliklere sahip misafir grupları oluşturmak için kullanılan etkili bir yöntemdir. RFM ile segmentasyon analizi ML, yapılandırılmamış segmentasyon (unsupervised clustering) yöntemleriyle gerçekleştirilmiştir. Yapılandırılmamış segmentasyon, denetimsiz öğrenme yöntemlerini kullanarak veri setinde doğal olarak oluşan grupları veya desenleri keşfetmeyi amaçlayan bir süreçtir. Bu yöntem, önceden tanımlanmış etiketlerin veya sınıflandırma hedeflerinin olmadığı durumlarda tercih edilmektedir (Sinaga ve Yang, 2020).

Analiz sürecinde üç temel metrik olan Recency, Frequency, Monetary kullanılmıştır. Bu metrikler, misafirlerin davranışsal özelliklerini analiz etmek için standartlaştırılmıştır. Standardizasyon işlemi, metriklerin aynı ölçekte değerlendirilmesini sağlamış ve kümeleme algoritmalarına uygun hale getirilmiştir.

Kümelemede kullanılan K-ortalamlar (K-Means) algoritmasında optimal küme sayısını belirlemek için dirsek yöntemi (elbow method) ve silhouette skoru gibi metriklerden yararlanılmıştır. K-ortalamlar kümelemesi, n gözlemi k kümeye ayıran ve her gözlemin en yakın ortalamaya sahip kümeye (küme merkezi) ait olduğu ve kümenin prototipi olarak hizmet eden denetimsiz bir makine öğrenimi algoritmasıdır (Ahmed vd., 2020). Söz gelimi her

gözlemin d boyutlu gerçek bir vektör olduğu bir gözlem kümesi $(x_1, x_2, \dots, x_n)$ verildiğinde, k -ortalamalar kümelemesi, küme içi kareler toplamını (WCSS) veya varyansı en aza indirecek şekilde n gözlemi k ($\leq n$) $S = \{S_1, S_2, \dots, S_k\}$ kümesine bölmeyi amaçlamaktadır. Analizde kullanılan parametreler küme sayısı ($n_clusters$) 5, yeniden üretilebilir sonuçlar için sabit rastgelelik ($random_state$) 42, algoritmanın maksimum iterasyon sayısı (max_iter) 300, modelin yakınsama toleransı (tol) $1e-4$ olarak ayarlanmıştır. Analiz sonucunda, misafirler 5 farklı segmente ayrılmıştır.

3.3.2. CLV Segmentasyon Analizi

CLV hesaplamasında kullanılan bileşenler değişken mühendisliği kısmında üretilmiştir. CLV hesaplaması için aşağıdaki bileşenler kullanılmıştır:

- Ortalama Satın Alma Değeri (APV- Average Purchase Value): Bir satın alımın ortalama değeri.
- Satın Alma Frekansı (PF- Purchase Frequency): Bir müşterinin belirli bir dönemde yaptığı ortalama satın alma sayısı.
- Müşteri Yaşam Süresi (CL- Customer Lifetime): Müşterinin aktif olduğu süre.
- Kar Marjı (PM- Profit Margin): Satışlardan elde edilen kar oranı.
- İskonto Oranı (DR- Discount Rate): Gelecekteki kazançları bugüne indirmek için kullanılan oran.

CLV'yi hesaplama formülü:


$$CLV = \frac{APV \times PF \times CL \times PM}{1 + DR}$$

Her müşteriye özel CLV için formül her müşterinin verilerine göre ayarlanabilir. Örneğin:

$$CLV_i = \frac{APV_i \times PF_i \times CL_i \times PM_i}{1 + DR}$$

Burada i her bir müşteriye temsil eder.

Hesaplama işlemi sonrasında veri setinde Şekil 3.3'de gösterildiği gibi her misafir için farklı bir değer olacak şekilde yer almaktadır.



GuestId	CLV
268	61.778138
289	127.040138
290	1086.646089
321	94.597496
354	380.499570

Şekil 3.3 Her Bir Müşteri İçin Hesaplanan Müşteri Yaşam Boyu Değeri

Hesaplanan CLV değerleri 1 ile 100 arasında ölçeklendirilmiş ve daha kolay yorumlanabilir bir hale getirilmiştir. Bu işlem, CLV değerlerinin normalize edilmesini sağlamış ve tüm değerleri aynı ölçeğe taşımıştır.

Sonrasında, bu normalize edilmiş CLV değerleri, yüzdelik dilimlere (quantiles) göre sınıflandırılmıştır. Bu sınıflandırma yöntemi, verileri üç gruba (A, B, C segmentleri) ayırır.

A segmenti: En yüksek CLV değerlerine sahip müşteriler (en üst %33'lük dilim).

B segmenti: Orta düzey CLV değerlerine sahip müşteriler (orta %33'lük dilim).

C segmenti: En düşük CLV değerlerine sahip müşteriler (en alt %33'lük dilim).

Bu yöntem, veri dağılımına dayalı bir sınıflandırma tekniği olarak bilinir ve her segmentin eşit sayıda müşteri içermesini hedefler. Böylece, misafirlerin CLV değerlerine göre kolayca sınıflandırılması ve analiz edilmesi sağlanmaktadır.

3.3.3. CLV'nin Makine Öğrenmesi ile Tahmini

CLV'nin makine öğrenmesi ile tahminini yapabilmek için yenilikçi ML algoritmaları kullanılmıştır. Bahsi geçen bu algoritmalar, XGBoost (eXtreme Gradient Boosting), LightGBM (Light Gradient Boosting Machine) ve CatBoost (Categorical Boosting) gradient boosting karar ağaçlarının (GBDT) gelişmiş uygulamalarıdır. Güçlü bir tahmin modeli oluşturmak için sırayla zayıf öğrencilerden oluşan bir topluluk oluşturma temel ilkesini paylaşırsalar da, her birinin farklı özellikleri ve optimizasyonları vardır.

XGBoost, önceki modeller tarafından yapılan hataları düzeltmek için sırayla modeller ekleyen gradyan artırma çerçevesi üzerine kuruludur. Bu yinelemeli süreç, tahmin edilmesi zor örneklere odaklanarak modelin doğruluğunu artırmaya yardımcı olmaktadır (Chen ve Guestrin, 2016). XQBoost'un çalışma mekanizması incelendiğinde, temel öğrencileri olarak öncelikle karar ağaçlarını kullandığı görülmektedir. Algoritma, hızlı eğitim için çoklu GPU sistemlerini kullanarak ölçeklenebilirlik için tasarlanmıştır. Bellek kullanımını en aza indirmek ve işlem

hızını optimize etmek için veri sıkıştırma ve parçalama teknikleri kullanmaktadır (Mitchell vd., 2018). XGBoost'un performansı büyük ölçüde hiperparametrelerine bağlıdır. Izgara arama ve parçacık sürüsü optimizasyonu (PSO) gibi teknikler, bu parametrelerin ince ayarını yapmak, model doğruluğunu ve verimliliğini artırmak için kullanılmaktadır (Wang ve Zhou, 2023).

Microsoft Research tarafından geliştirilen LightGBM, Gradyan Tabanlı Tek Taraflı Örnekleme (GOSS) ve Özel Özellik Paketleme (EFB) teknikleriyle öne çıkmaktadır. GOSS, eğitim sırasında daha büyük gradyanlara sahip örnekler odaklanarak hesaplama karmaşıklığını azaltırken yüksek doğruluğu korumaktadır (Cai vd., 2023). Bu yaklaşım, öğrenme için en bilgilendirici örnekleri etkili bir şekilde tanımlamaktadır. EFB, birbirini dışlayan özellikleri bir araya getirerek yüksek boyutlu verileri ele almaktadır. Böylece bellek kullanımını azalmaktadır. Bu bağlamda önemli bilgi kaybı olmadan eğitimi hızlandırılmaktadır (Cai vd., 2023).

Bir diğer önemli boosting modellerinden olan CatBoost özellikle kategorik verilerin işlenmesi için yenilikçi bir yaklaşım sunmaktadır. Sıralı artırma tekniği, klasik gradyan artırma uygulamalarında hedef sızıntısının neden olduğu tahmin kaymasını azalttığı söylenmektedir (Bharath vd., 2024). Kategorik özellikler için CatBoost, tek vuruşlu kodlama ve çeşitli istatistiksel ölçümlerin otomatik bir kombinasyonunu kullanır ve sayısal özellikler oluşturmak için sıralı hedef istatistiklerini hesaplar. Bu yaklaşım özellikle kategorik değişkenler üzerindeki aşırı uyumu azaltmada etkilidir (Bharath vd., 2024).

Birleştirilmiş veri setinden elde edilen CLV değeri, ML algoritmaları ile tahmin edilmiştir. Bu amaçla bağımlı değişken olarak CLV, bağımsız değişken olarak ise aşağıdaki özellikler kullanılmıştır:

- RFM Metrikleri ve Segmentleri: Recency, Frequency, Monetary ve müşteri segment bilgileri.
- Rezervasyon Detayları: Rezervasyon Pazarı (Market), Oda tipi (Room Type), toplam geceleme sayısı (Total Nights), rezervasyon ile check-in arasındaki süre (Lead time).
- Demografik Bilgiler: Müşterinin milliyeti (Nationality), seyahat eşlenikçisi (Travel Companion), konaklamanın yapıldığı mevsim (Season).

Değişkenler belirlendikten sonra, k-katlı çapraz doğrulama (k-fold cross validation) uygulanmıştır. Bu yöntem modelin değerlendirilmesinde verisetini parçalara ayırarak çapraz doğrulamalar yapmaktadır. Böylece belirlenen k sayıda parçaya bölünen veri üzerinde her bir parçanın hem test hem de eğitim seti olarak kullanılması sağlanmış olmaktadır (Wong ve Yeh, 2019). Analizlerde k=10 olarak belirlenmiş ve 10 katlı çapraz doğrulama yapılmıştır.

Tahmin işlemi için üç ML algoritması kullanılmıştır:

XGBoost (Extreme Gradient Boosting):

- Rastgele tohum değeri 42
- Maksimum ağaç derinliği 5
- Öğrenme oranı 0.03
- 700 adet ağaç (tahminleyici) kullanılıyor
- L1 regülerizasyon parametresi (alfa) 1.0
- L2 regülerizasyon parametresi (lambda) 2.0

LightGBM (Light Gradient Boosting Machine):

- Rastgele tohum değeri 42
- Maksimum ağaç derinliği 5
- Öğrenme oranı 0.03
- 700 adet ağaç kullanılıyor
- L1 regülerizasyon parametresi 1.0
- L2 regülerizasyon parametresi 2.0
- Her ağaçtaki maksimum yaprak sayısı 20 olarak belirlenmiş

CatBoost:

- Rastgele tohum değeri 42
- Ağaç derinliği 5
- Öğrenme oranı 0.03
- 700 iterasyon kullanılacak
- Yaprak regülerizasyon parametresi 5.0 olarak ayarlanmış

Modellerin performansları aşağıdaki metriklerle değerlendirilmiştir:

- RMSE (Root Mean Squared Error): Tahmin doğruluğunu ölçen bir hata metriği.
- MAE (Mean Absolute Error): Ortalama mutlak tahmin hatası.
- R^2 (Determinasyon Katsayısı): Bağımlı değişkenin açıklanma oranı.

3.4. Değişken Önem Derecesi

ML modellerinde, değişken önem derecesi, modelin tahmin performansı üzerinde hangi değişkenlerin ne derece etkili olduğunu ölçmeye yarayan bir araçtır (Lu vd., 2017). Bu ölçüm, modelin tahminleri üzerindeki değişkenlerin etkisinin hem nicel hem de yorumlanabilir bir şekilde analiz edilmesini sağlamaktadır (Majumdar, 2024). Değişken önem derecesi, modellerin tahmin doğruluğuna katkı sağlamanın yanı sıra içsel mekanizmalarının anlaşılmasına yönelik önemli bir içgörü sunmaktadır. Bu sayede, hangi değişkenlerin modelin

çıktısı üzerinde daha fazla etkili olduğu görülerek, karar verme süreçlerinde daha kanıta dayalı adımlar atılmasına olanak tanımaktadır.

Bu çalışmada, değişken önem derecesini değerlendirmek için SHAP (Shapley Additive Explanations) analizi kullanılmıştır. SHAP, oyun teorisine dayalı bir yaklaşımla her bir değişkenin model üzerindeki marjinal katkısını hesaplar (Lundberg ve Lee, 2017). Shapley değerlerinden türetilen bu yöntem, özelliklerin hem model genelindeki önemini hem de belirli bir tahmin üzerindeki lokal etkisini belirlemek için güçlü bir araçtır (Lundberg ve Lee, 2017).

SHAP analizi, model açıklanabilirliği konusunda standart bir yöntem olarak öne çıkmaktadır. Söz gelimi, bir değişkenin pozitif veya negatif yönlü etkisinin şiddetini belirleyerek, modelin önyargılarını veya potansiyel yanlış genellemelerini tespit etmeye yardımcı olmaktadır. Bu bağlamda, SHAP sadece bir analiz aracı değil, aynı zamanda model geliştirme süreçlerinde rehberlik eden bir mekanizma olarak da değerlendirilmektedir.

3.5. Performans Ölçütleri

3.5.1. RFM Segmentasyon Performansı

Tez çalışmasında RFM segmentasyonu için K-Means algoritmasının performansı çeşitli metrikler ile değerlendirilmiştir. Bu metriklerden biri olan inertia, her bir segment içindeki veri noktalarının küme merkezine olan uzaklıklarının toplamını ifade etmektedir. Düşük inertia değerleri, segmentlerin daha sıkı bir şekilde gruplandığını göstererek başarılı bir segmentasyonun önemli bir göstergesi olarak kabul edilir (Rykov vd.,2024).

Bir diğer metrik olan Silhouette skor -1 ile 1 arasında değer almaktadır. Silhouette skoru segmentasyon sonuçlarının doğruluğunu değerlendirmek için kullanılmıştır. Bu skor, veri noktalarının doğru kümelerle atanıp atanmadığını ölçer; 1'e yakın değerler, daha başarılı bir segmentasyona işaret etmektedir (Punhani vd., 2022). Ayrıca, Davies-Bouldin İndeksi (DBI), segmentlerin birbirine olan benzerliğini ve küme içi yoğunluğu analiz ederek segmentasyon kalitesini ölçmektedir. Bu indekste daha düşük değerler, daha iyi segmentasyon performansını temsil etmektedir (Xiao vd.,2017).

Segmentasyon performansını ölçmek için kullanılan bir diğer önemli metrik ise Calinski-Harabasz Skorudur. Bu skor, segmentler arasındaki ayrışmayı ve küme içi sıklığı analiz etmektedir. Daha yüksek değerler, segmentlerin daha net bir şekilde ayrıştığını ve algoritmanın segmentasyonu başarıyla gerçekleştirdiğini ifade etmektedir (Ashari vd., 2023). Bu metrikler bir arada kullanılarak, RFM segmentasyonunun genel başarımı kapsamlı bir şekilde değerlendirilmektedir. Tablo 3.2' de yer aldığı üzere, silhouette skoru (0.51) kümelerin orta düzeyde ayrıştığını, davies-Bouldin indeksi (0.86) ise sıkı kümelenmeyi desteklemektedir.


Calinski-Harabasz skoru (6725.25) yüksek olup, kümeler arası farklılığın belirginliğini yanıtmaktadır.

Tablo 3.2 K-Means Kümeleme Performans Değerlendirme Metrikleri

Metric	Value
Inertia	14803.8
Silhouette Score	0.51
Davies-Bouldin Index	0.86
Calinski-Harabasz Score	6725.25


3.5.2. CLV Segmentasyon Performansı

Anlaşılır bir forma sokmak için CLV değerleri MinMaxScaler kullanılarak 1 ile 100 arasında normalize edilen müşterilerin kolayca sınıflandırılmasını sağlamak amacıyla A, B ve C segmentlerine ayrılmıştır. CLV segment Lorenz Eğrisi ve Gini Katsayısı, CLV segmentleri arasında misafir bazlı değer eşitsizliğini görmek için kullanılmıştır. CLV verilerinin Lorenz Eğrisi üzerinde analiz edilmesi, misafir değerlerinin eşit olmayan bir şekilde dağıldığı gösterilmiştir. Şekil 3.4'te Gini Katsayısı, bu eşitsizliğin açık bir analizidir ve 0,7380 olarak hesaplanmıştır. Bu sonuç, misafirlerin CLV değerlerinin belirgin bir şekilde farkına işaret ettiğini ve yüksek CLV'ye sahip A segmentinin misafirleri tarafından sağlandığını göstermektedir. Gini katsayısının analizi, CLV segmentasyonunun misafir gruplarındaki eşitsizlikleri anlamada ve stratejik kararlar almak için nasıl bir araç olarak kullanılabileceğini göstermektedir.



Şekil 3.4 Lorenz eğrisi üzerinden hesaplanan Gini katsayısı, CLV dağılımındaki eşitsizliği 0.7380 olarak göstermektedir. Segment ortalamaları, A segmenti (23.82), B (1.90) ve C (1.11)

Segment ortalamaları, A, B ve C segmentlerinin CLV düzeylerini karşılaştırarak analiz edilmiştir. A segmenti, ortalama CLV değeri açısından diğer segmentlere kıyasla belirgin şekilde ayrılmıştır (23,82). C segmenti, en düşük ortalama CLV'ye (1.11) sahipken, B segmenti bu iki uç arasında yer almaktadır (1.90). Segmentlerin ortalama CLV değerlerine göre, A segmentindeki misafirlerin işletme için C segmentindeki misafirlere kıyasla 21,45 kat daha değerli olduğu belirlenmiştir.



Şekil 3.5 Normalize Edilmiş CLV Bileşenlerinin Karşılaştırılması

Şekil 3.5'te yer alan grafikte CLV ve bileşenlerin normalleştirilmiş değerlerinin karşılaştırılmıştır. Özellikle, CLV'nin diğer bileşenlerle ilişkisini göstermek için normalleştirme yapılmıştır. Grafikteki eğrilerin bazı bileşenlerde ani yükselmesi, segmentlerin arasındaki belirgin farkı açıklamaktadır.

Segment A'nın diğer segmentlerden ortalama CLV değeri bakımından büyük bir farkın sebebi, bu segmentte yer alan müşterilerin hem daha yüksek alım frekansı (Purchase Frequency) hem de daha yüksek ortalama satın alma değerine (Average Purchase Value) sahip olmasıdır. Grafikteki yeşil çizginin (Purchase Frequency) eğimi de bu durumu desteklemiştir.

3.5.3. CLV'nin Tahmin Performansı

CLV hesaplamaları sonucunda elde edilen değerlerin farklı segmentlere ayrılması, misafir gruplarının işletme açısından değerini anlamak için önemlidir. Normalize edilen CLV değerlerinin A, B ve C segmentlerine ayrılması, misafirler arasındaki değer farklarını anlamayı kolaylaştırmıştır. Segmentasyon performansı, segmentler arasındaki CLV değerlerinin tutarlılığı ve dağılım analizi ile doğrulanmıştır.

CLV tahmininde kullanılan XGBoost, LightGBM ve CatBoost algoritmaları, tahmin doğruluğunu değerlendirmek ve karşılaştırma için kullanılan metrikler: RMSE (Root Mean Squared Error), tahmin edilen CLV değerleri ile gerçek değerler arasındaki farkların karekökünü ifade eder. Daha düşük RMSE değerleri, modelin daha iyi bir performans sergilediğini gösterir. MAE (Mean Absolute Error), tahmin edilen ve gerçek değerler arasındaki

mutlak farkların ortalamasıdır. Hata seviyesini değerlendirmek için kullanılır. R^2 (Determinasyon Katsayısı), modelin bağımlı değişkenin varyansını ne kadar açıkladığını ölçer. 1'e yakın R^2 değerleri, yüksek bir açıklama oranını ifade eder.

3.6. Bulgular

3.6.1. Tanımlayıcı Analiz Sonuçları

Bu bölümde araştırmada kullanılan verilerin tanımlayıcı istatistikleri ve değişkenlerin temel dağılımları sunulmuştur. Bulgular, misafir profili, konaklama tercihleri, seyahat davranışları ve otel özelliklerine ilişkin kapsamlı bir özet sağlamaktadır.

3.6.1.1. Kategorik Değişkenlerin Dağılımı ve Frekansları

Verilerde belirgin örüntüler gözlemlenmiştir. Tablo 3.3'te kategorik değişkenlerin ilk beş değerlerinin frekans ve yüzdesel dağılımları verilmiştir:

Nationality (Milliyet): Verilerde en yüksek oranda Türkiye'den (%41.25) misafir bulunmaktadır. Rusya (%9.1), Almanya (%6.9), ABD (%5.9) ve Birleşik Krallık (%4.7) diğer yüksek frekanslı ülkeler arasında yer almaktadır.

Board (Konaklama Tipi): "BB" (oda kahvaltısı) seçeneği %55.54 ile en yaygın tercih edilen konaklama tipidir. Ardından "RO" (sadece oda) %17.72, ve "HB" (yarım pansiyon) %14.71 oranlarıyla takip etmektedir.

Market (Pazar Türü): OTA (çevrimiçi seyahat acenteleri) %27.1 ile en büyük müşteri grubu kaynağıdır. Ind (Bireysel- %14.63), Whs (Toptan Satış Acenteleri- %13.33), Mtg (Toplantı- %11.86) ve Cor (Kurumsal- %8.89) kanallar diğer önemli pazar segmentlerini oluşturmaktadır.

Travel Companion (Seyahat Eşlikçisi): Misafirlerin çoğunluğu Single (tek başına- %46.53) veya Couple (çift olarak - %44.0) seyahat etmektedir. With children (Çocuklu) seyahat edenlerin oranı %6.61 olup, Triple (üçlü) ve Quadruple (dörtlü) gruplar ise oldukça düşük oranlardadır (%2.81 ve %0.04).

Season (Mevsim): Winter (Kış- %33.94) ve Autumn (sonbahar- %26.37) ayları, rezervasyonların en yoğun olduğu dönemlerdir. High summer (Yüksek yaz %15.96), Spring (İlkbahar- %13.46) ve Early_summer (Erken yaz- %10.27) oranları daha düşük düzeydedir.

Room Type (Oda Türü): En yaygın tercih edilen oda tipi, "DSW" (%56.32) olup, bunu "DCW" (%25.97) ve "SMD" (%5.55) oda tipleri takip etmektedir. Daha az tercih edilen oda tipleri arasında "CON" (%3.35) ve "GDX" (%3.19) yer almaktadır.

Tablo 3.3 Kategorik Değişkenlerin Dağılımı ve Frekansları

Variables	Values (Top 5 values)	Frequency	Percentage (%)
Nationality	Turkey	5879	41.25
	Russia	1289	9.1
	Germany	981	6.9
	United States	844	5.9
	United Kingdom	671	4.7
Board	Bb	5879	55.54
	Ro	1289	17.72
	Hb	981	14.71
	Fb+	844	9.3
	Fbe	671	1.45
Market	Ota	3858	27.1
	Ind	2085	14.63
	Whs	1900	13.33
	Mtg	1691	11.86
	Cor	1267	8.89
Travel Companion	Single	6632	46.53
	Couple	6270	44.0
	With children	942	6.61
	Triple	401	2.81
	Quadruple	5	0.04
Season	Winter	4837	33.94
	Autumn	3758	26.37
	High summer	2274	15.96
	Spring	1919	13.46
	Early_summer	1464	10.27
Room Type	DSW	8027	56.32
	DCW	3701	25.97
	SMD	792	5.55
	CON	478	3.35
	GDX	455	3.19

3.6.1.2. Numerik Değişkenlerin Tanımlı İstatistikleri

Veriler, misafir davranışını analiz etmek için Recency (son konaklama üzerinden geçen süre), Frequency (tekrar rezervasyon sıklığı), Monetary (toplam harcama), TotalNights (toplam gece sayısı) ve Leadtime (rezervasyon penceresi) gibi RFM göstergelerini içermektedir. Bu göstergelere ait istatistiksel özet Tablo 3.4'teki gibidir:

Tablo 3.4 Numerik Değişkenlerin Tanımlı İstatistikleri

RFM göstergeleri	Min.	Maks	$\bar{X}$	Std.s.
Recency	10	374	141.48	98.49

Frequency	1	28	1.50	1.74
Monetary	14	19610.92	673.16	1030.64
TotalNights	1	87	4.13	5.53
Leadtime	1	792	20.56	57.81

Bu göstergeler, misafirler genel satın alma davranışları ve otel ile etkileşimlerinin detaylı bir resmini sunmaktadır. Özellikle, harcama tutarlarında yüksek bir standart sapma (1030.64) gözlemlenmiş olup, müşteriler arasında önemli farklılıklar olduğunu göstermektedir.

3.6.2. CLV Tahmin Bulguları

CLV tahmin etmek için üç makine öğrenmesi modeli (CatBoost, XGBoost ve LightGBM) Kök Ortalama Karesel Hata (RMSE), Ortalama Mutlak Hata (MAE) ve R^2 (belirleme katsayısı) gibi performans ölçütleriyle değerlendirilmiştir. Tablo 3.5'te sunulan sonuçlara göre, CatBoost modeli en iyi performansı gösterdiği anlaşılmaktadır. En düşük RMSE (0.335), en düşük MAE (0.0635) ve en yüksek R^2 (0.9234) değerleriyle, CLV tahmininde yüksek doğruluk ve düşük hata üretmiştir. XGBoost modeli, 0.3728 RMSE, 0.0577 MAE ve 0.9203 R^2 ile CatBoost'a yakın bir performans sergilemiştir. CatBoost'a kıyasla biraz daha yüksek hata oranına sahip olsa da, güvenilir bir model olarak değerlendirilebilir.

Bununla birlikte, LightGBM modeli belirgin şekilde düşük performans göstermiştir. RMSE değeri 1.4340, MAE değeri 0.1571 ve R^2 değeri -0.7129 olup, bu modelin tahmin doğruluğunun yetersiz olduğunu göstermektedir. Negatif R^2 değeri, modelin verilerdeki değişkenliği anlamlı şekilde açıklayamadığını ve tahmin gücünün zayıf olduğunu ortaya koymaktadır.

Tablo 3.5 XGBoost, LightGBM ve CatBoost Algoritmaları ile CLV Tahmini Performans Karşılaştırması


Model	CV Ort. RMSE	CV Ort. MAE	CV Ort. R^2
CatBoost	0.335027	0.063500	0.923385
XGBoost	0.372766	0.057651	0.920260
LightGBM	1.434029	0.157148	-0.712880

CatBoost, diğer modellerden daha iyi performans göstererek, bu çalışmada doğru CLV tahmini için en uygun seçim olmuştur. Tahmin hatalarını en aza indirme ve verilerdeki değişkenliğin çoğunu yakalama yeteneği sağlamlığını göstermektedir. XGBoost, biraz daha az hassas olsa da güçlü bir alternatif olarak hizmet ederken, LightGBM diğer modellerin performansına uyması için daha fazla optimizasyon gerektirebilir.

3.6.3. SHAP (SHapley Additive ExPlanations) Analiz Bulguları

CLV tahmin modelinde çeşitli özelliklerin katkılarını açıklamak için SHAP grafiği kullanılmıştır. Grafik, veri kümesindeki her değişkenin tahmin edilen sonucu nasıl etkilediğini görüntülemektedir ve her değişken değerinin modelin tahmini üzerindeki etkisini göstermektedir. X eksen, her bir özelliğin modelin tahmini üzerindeki etkisini gösteren SHAP değerini temsil etmektedir. Pozitif SHAP değerleri, modelin tahminini daha yükseğe itmekte (tahmin edilen CLV'yi artırır), negatif SHAP değerleri ise tahmini daha aşağıya itmektedir. Y eksenindeki renk gradyanı, değişken değerini temsil ederken ve renk ölçeği "Yüksek" değerleri kırmızı, "Düşük" değerleri ise mavi olarak göstermektedir. Bu, belirli bir değişkenin değerinin SHAP değeriyle nasıl ilişkili olduğunu anlamana yardımcı olmaktadır. Her yatay çizgi, veri kümesindeki bir değişkeni temsil etmekte ve noktalar, veri kümesindeki farklı örneklerde o değişkenin SHAP değerlerini temsil etmektedir.

Değişkenlerin daha yüksek (Kırmızı-Yüksek) değerlerinin (örneğin, yüksek parasal değer- **Monetary**), yüksek güncellik (**Recency**) tahmin edilen CLV'yi artırma eğiliminde olduğunu göstermektedir. Değişkenlerin daha düşük değerlerinin (Mavi- Düşük) tahmin edilen CLV'yi azaltma eğiliminde olduğunu göstermektedir. Şekil 3.6'te SHAP değerleri ile model tahminine özelliklerin katkısını gösteren analiz grafiği yer almaktadır.



Şekil 3.6 SHAP analiz çıktısı: Her bir özellik, tahmin üzerindeki pozitif veya negatif etkisiyle renklendirilmiş ve sıralanmıştır.

Recency değişkeninin modelin çıktısı üzerinde önemli bir etkiye sahip olduğu görünmektedir, çünkü SHAP değerleri yayılmış durumdadır ve daha yüksek değerler CLV tahminlerine olumlu etki etmektedir. Monetary değişkeni SHAP değerleri hem olumsuz hem de olumlu aralıklara yoğun bir şekilde yayılmıştır. Milliyet (Nationality), Sıklık (Frequency), Toplam Geceleme (TotalNights), Pazar (Res_Market) değişkenleri de CLV tahminini etkilemektedir.

SHAP değerlerinde daha yüksek yayılım veya değişime sahip özellikler, bu özelliklerin tahmine önemli ölçüde katkıda bulunduğunu göstermektedir. Pansiyon tipi (Board), RFM kümeleri (CLUSTER), Seyahat eşlikçisi (TravelCompanion) ve Sezon (Season) değişkenleri daha zayıf katkılar gösterebilir, ancak yine de tahmin üzerinde bir etkiye sahiptirler. Örneğin, belirli değerler, değişkenin etkisine bağlı olarak CLV'nin artmasına veya azalmasına neden olabilir.

3.6.4. RFM ve CLV Segmentasyon Bulguları

3.6.4.1. RFM Segmentasyon Bulguları

RFM segmentasyonu, misafirlerin yakınlık, sıklık ve parasal değerlerine göre konuk davranışları hakkında değerli içgörüler sağlamaktadır. Her küme, benzersiz özelliklere sahip belirli bir misafir grubunu temsil etmekte ve bu da özel pazarlama ve hizmet stratejilerine olanak sağlamaktadır. Tablo 3.6'te yer alan sonuçlara istinaden aşağıda kümelerin, özelliklerinin ve eyleme geçirilebilir önerilerin ayrıntılı bir açıklaması bulunmaktadır.

Tablo 3.6 RFM Segmentasyonu Sonuçları ve Küme Karakteristikleri

Küme	N	Recency	Frequency	Monetary	RFM Skoru	TotalNights	Leadtime
		$\bar{X}=141.48$	$\bar{X}=1.50$	$\bar{X}=673.16$		$\bar{X}=4.13$	$\bar{X}=20.56$
0	4086	277,39	1,09	329,26	R↑F↓M↓	4,34	10,11
1	7399	82,08	1	367,2	R↓F↓M↓	3,24	29,9
2	52	73,07	9,81	4452,64	R↓F↑M↑	5,06	6,56
3	1670	144,23	1,17	1741,17	R↑F↓M↑	8,34	19,48
4	1045	93,56	2,63	794,03	R↓F↑M↑	3,22	13,83

Küme 0 (Pasif Misafirler): Bu kümede toplam 4086 misafir yer almaktadır. Ortalama Recency (yenilik) değeri 277,39 gün olup misafirlerin uzun bir süre önce işlem gerçekleştirdiğini göstermektedir. Frequency (rezervasyon sıklığı) 1,09 ile düşük seviyededir, bu da misafirlerin nadiren işlem yaptığını ifade etmektedir. Ayrıca, Monetary değeri 329,26 birimle düşük harcamaya işaret etmektedir. Misafirlerin ortalama kalış süresi 4,34 gece,

rezervasyon penceresi (leadtime) ise 10,11 gündür. Bu grup, düşük sadakat ve düşük harcama düzeyine sahip, nadir işlem gerçekleştiren misafirlerden oluşmaktadır.

Küme 1 (Yeni Misafirler): Toplam 7399 misafirin bulunduğu bu kümede, Recency değeri 82,08 gün olup, misafirlerin daha yakın zamanda işlem yapmış oldukları görülmektedir. Ancak, Frequency değeri 1,00 seviyesinde olduğu için bu misafirlerin yalnızca tek seferlik işlem gerçekleştirdiği anlaşılmaktadır. Monetary ortalaması 367,2 birimle düşük harcamayı ifade etmektedir. Ortalama kalış süresi 3,24 gece, rezervasyon penceresi ise 29,9 gün olarak belirlenmiştir. Bu küme, yakın zamanda ilk kez rezervasyon yapmış ve geceleme sayısı ve düşük harcama yapmış müşterileri kapsamaktadır.


Küme 2 (Sadık ve Prestijli Misafirler): Bu kümede toplam 52 misafir yer almakta olup, Recency değeri 73,07 gün ile daha yakın zamanlı konaklamalar olduğunu göstermektedir. Frequency değeri 9,81 ile oldukça yüksek olup, sık konaklama gerçekleştirdiğini ifade etmektedir. Ayrıca, Monetary değeri 4452,64 birimle kümenin en yüksek harcama yapan misafirlerinin olduğu görülmektedir. Misafirlerin ortalama kalış süresi 5,06 gece, rezervasyon penceresi ise 6,56 gecedir. Bu grup, yüksek harcama yapan, sadık ve sık işlem gerçekleştiren misafirlerden oluşmaktadır.

Küme 3 (Uzun Süreli Konaklayanlar): Bu kümede toplam 1670 misafir bulunmaktadır. Recency değeri 144,23 gün ile misafirlerin konaklama işlemlerinin daha eski tarihli olduğunu göstermektedir. Frequency değeri 1,17 seviyesinde olup, düşük işlem sıklığını ifade etmektedir. Ancak, Monetary ortalaması 1741,17 birimle orta düzeyde bir harcamaya işaret etmektedir. Ortalama kalış süresi 8,34 gece, rezervasyon penceresi ise 19,48 gündür. Bu küme, daha fazla harcama yapan, ancak nispeten düşük işlem sıklığına sahip misafirlerden oluşmaktadır.

Küme 4 (Orta Harcama Orta Sıklık): Toplam 1045 misafir içeren bu kümede, Recency değeri 93,56 gün olup misafirlerin daha güncel işlemler gerçekleştirdiğini göstermektedir. Frequency değeri 2,63 ile misafirlerin genel ortalamasının üzerinde işlem gerçekleştirdiğini ifade etmektedir. Ayrıca, Monetary ortalaması 794,03 birimle orta düzeyde harcamaya yapıldığı anlaşılmaktadır. Ortalama kalış süresi 3,22 gece, rezervasyon penceresi ise 13,83 gündür. Bu küme, sık işlem yapan ve orta düzeyde harcama gerçekleştiren misafirlerden oluşmaktadır.

3.6.4.2. CLV Segmentaston Bulguları

CLV segmentlerinin daha doğru yorumlanabilmesi için CLV bileşenlerinin hesaplamadaki katkılarını anlamak önemlidir. Şekil 3.7’de korelasyon ısı haritası, CLV (Customer Lifetime Value) ile bileşenleri arasındaki ilişkileri göstermektedir.



Şekil 3.7 CLV ve bileşenleri arasındaki korelasyon matrisi, Pearson korelasyon yöntemi kullanılarak oluşturulmuştur.

Analize göre, CLV üzerinde en güçlü etkiye sahip bileşen, Average Purchase Value (ortalama satın alma değeri) olup, bu iki değişken arasında 0.86'lık güçlü bir pozitif korelasyon bulunmaktadır. Bu, müşterilerin ortalama satın alma değerini artırmanın CLV'yi önemli ölçüde yükselteceğini göstermektedir. Buna karşın, Purchase Frequency (satın alma sıklığı) ile CLV arasındaki korelasyon yalnızca 0.14 olarak bulunmuştur, bu da satın alma sıklığının CLV üzerindeki etkisinin sınırlı olduğunu ifade eder. Customer Lifetime (müşteri yaşam süresi) ise CLV ile 0.095'lik çok zayıf bir korelasyona sahiptir ve yaşam süresindeki artışın CLV üzerindeki etkisinin minimal olduğunu göstermektedir.

Bileşenler arasındaki ilişkilere bakıldığında, Purchase Frequency ile Customer Lifetime arasında 0.59'luk orta düzeyde pozitif bir korelasyon olduğu görülmektedir; bu durum, müşterinin yaşam süresi uzadıkça satın alma sıklığının da artma eğiliminde olduğunu ifade eder. Ancak, Average Purchase Value ile diğer bileşenler arasında korelasyon oldukça zayıftır, bu da ortalama satın alma değerinin daha bağımsız bir değişken olduğuna işaret eder.

Genel olarak, CLV'yi artırmada Average Purchase Value'nin en kritik bileşen olduğu anlaşılmaktadır. Bu nedenle, müşterilerin satın alma değerlerini artırmaya yönelik stratejiler önceliklendirilmeli, ayrıca müşteri yaşam süresi ve satın alma sıklığını artıracak bağlılık programları ile desteklenmelidir. Bu analiz, CLV'nin optimize edilmesi için hangi alanlara odaklanılması gerektiğine dair değerli bir rehber sunmaktadır.

Tablo 3.7 ve Tablo 3.8 birlikte değerlendirilip küme özellikleri detaylandırılmıştır. CLV segmentleri sırasıyla A, B ve C olarak isimlendirilmiştir. Bu segmentlerin değişkenlere göre yorumlanması aşağıdaki yer almaktadır.

Segment A, toplam misafirlerin %29.27'sini oluşturmaktadır. Bu segmente ait Recency değeri 118.04 gün olup, misafirlerin son rezervasyonu üzerinden geçen süre diğer segmentlere göre daha iyi seviyededir. Frequency değeri 6,65 ile diğer segmentlere göre misafirlerin tekrar rezervasyonlarının yüksek olduğunu göstermektedir. Monetary değeri 5306,64 ile toplam harcama düzeyinde C segmentinin altında yer alırken, Lead Time (rezervasyon penceresi) 9,03 gün ve Length of Stay (konaklama gün sayısı) ise 10,86 gün ile C segmentiyle yakın seviyede yer aldığı görülmüştür. Bu bulgular, otel rezervasyonlarının girişten yaklaşık iki hafta önce yapıldığı ve ortalama konaklama durumunun uzun olduğunu göstermektedir.

Demografik olarak Küme A'da yeni misafirler (%45,2) ve pasif misafirler (%28,9) daha fazla yer almaktadır. Misafirlerin çoğunluğu Türkiye (%34,6) ve Rusya (%9,4) uyrukludur. Tercih edilen konaklama tipi BB (oda kahvaltı, %55.2) iken pazar kanalı OTA (online seyahat acenteleri, %31) ve IND (bireysel rezervasyonlar, 17.7%) şeklindedir. Seyahat eşlikçisi olarak çiftler (%51) öne çıkarken, kış (%30.1) ve sonbahar (%26.2) sezonları bu kümede konaklamaların yoğunlaştığı dönemlerdir. Bu kümede departman harcamaları (DepartName) arasındaki oda harcamaları (Room, %8,3) ve minibar (%7,6) harcamaları ön plana çıkmıştır. Popüler ürünler arasında Açık Büfe Akşam Yemeği (%3,1) ve Kemik Suyuna Ezogelin (%1,9) öne çıkmıştır.

Segment A, misafir sayısı olarak ikinci sırada olsa da ekstra harcama işlem sayısı olarak en yüksek orana sahip misafir grubunu içermektedir. Misafirler diğer segmentlere göre yeni konaklama yapmışken bu misafirlerin rezervasyon yapma sıklığı yine diğer segmentlerden yüksektir. Toplam konaklama harcamaları açısından ikinci olsa da segmentteki misafir sayısını göz önünde bulundurursak müşteri başına harcamanın daha yüksek olduğu görülmektedir. Bu durum segmentin daha verimli olduğunu göstermektedir. Harcama yapılan departman kullanımında diğer segmentlerin açık büfe hizmeti veren restoran (Panora Restaurant) kullanımını tercih ettikleri görülürken Segment A daha lüks hizmet veren alakart restoran (Hotel Pablito) kullanımının da olumlu düzeyde ön plana çıktığı gözlenmiştir.

Tablo 3.7 CLV Segmentasyonu Sonuçları ve Küme Karakteristikleri

CLV Segmentleri	Misafir Sayısı	Recency	Frequency	Monetary	Lead Time	Length of Stay
	N (%)	$\bar{X}$	$\bar{X}$	$\bar{X}$	$\bar{X}$	$\bar{X}$

A	1663 (29.27%)	118.04	6.65	5306.64	9.03	10.86
B	1599 (28.14%)	164.43	2.81	1752.68	16.37	9.49
C	2420 (42.59%)	127.26	3.34	6922.51	9.01	10.86

Segment B, toplam misafir tabanının %28.14'ünü kapsamaktadır. Recency değeri 164.43 gün ile en yüksek seviyededir; bu durum, bu gruptaki müşterilerin diğer segmentlere göre uzun süredir konaklama gerçekleştirmediğini göstermektedir. Frequency değeri 2.81 ile oldukça düşük seviyede olup, Monetary değeri de 1752.68 ile toplam oda gelirine işaret ettiği görülmektedir. Bununla birlikte, Lead Time ortalaması 16.37 gün olup, rezervasyonlarını diğer segmentlere göre daha uzun süre önce planlandığını göstermektedir. Length of Stay ise 9.49 gün ile diğer iki segmentten daha kısa konaklama süresine sahiptir.

Demografik olarak, yeni misafirler (%45.8) ve pasif misafirler (%27.9) bu kümede de daha fazla bulunmaktadır. Ülke bazında Türkiye (%35.1) ve Rusya (%8.9) ön plandadır. Konaklama tercihi BB (%54) olurken, en çok kullanılan pazar kanalı OTA (%32.5) ve WHS (Kontratlı toplan satış kanalları- 15%)'dir. Diğer iki segmentte pazar kanalı olarak ikinci pazarlama kanalı IND (bireysel rezervasyonlar) iken bu segmentte WHS olması dikkat çekicidir. Seyahat eşlikçisi açısından çiftler (%48.7) ve tek başına seyahat edenler (%40.2) göze çarpmaktadır. Kış (%30.6) ve sonbahar (%26.2) sezonlarının bu segmente de yoğun kullanım dönemleri olduğu görülmektedir. En çok kullanılan ürünler arasında Bitter Çikolatalı Gofret (%2.3) ve Çikolata (%2.9) yer almaktadır. Segment B, orta düzeyde CLV değerine sahip misafirler olarak segmentte yer alan misafir sayısı diğer iki segmentten azdır.

Tablo 3.8 CLV Kümelerine Göre Müşteri Segmentlerinin Özellikleri

CLV Kümeleri	RFM Kümeleri (%)	Nationality (%)	Board (%)	Market (%)	Room Type (%)	TravelCompanion (%)	Season (%)	Pos	
								Depart Name (%)	Product (%)
A	Yeni Misafirler (45.2%)	Turkey (34.6%)	BB (55,2%)	OTA (31%)	DSW (55%)	Couple (51%)	Winter (30.1%)	Room (8.3%)	Açık Büfe Aksam Yem. Otel (3.1%)
	Pasif Misafirler (28.9%)	Russia (9.4%)	RO (20,8%)	IND (17.7%)	DCW (22.6%)	Single (36,9%)	Autumn (26.2%)	Minibar (7.6%)	Kemik Suyuna Ezogelin (1.9%)
	Uzun Süreli Konaklayanlar (15.6%)	Germany (8.9%)	HB (14,6%)	WHS (15.8%)	SMD (8.5%)	WithChildren (9%)	High_summer (16.6%)	Pension Breakfast (7.6%)	Bitter Cıkolatalı Gofret 28,5 Gr (1.5%)
	Orta Harcama Orta Sıklık (9.3%)	United Kingdom (6.8%)	FB+ (7,7%)	COR (7%)	GDX (3.4%)	Triple (2.8%)	Spring (13.4%)	Room Service (7.3%)	Açık Büfe Kahvaltı Otel (1.4%)

	Sadık ve Prestijli Misafirler (1%)	United States (6%)	-	WEB (6.1%)	-	Quadruple (0.1%)	Early_summer (10.7%)	HOTEL Pablito (6.8%)	Antep Fıstıklı Cıkolata 80 Gr (1.2%)
B	Yeni Misafirler (45.8%)	Turkey (35.1%)	BB (54%)	OTA (32.5%)	DSW (54%)	Couple (48.7%)	Winter (30.6%)	Room (10%)	Bitter Cıkolatalı Gofret 28,5 Gr (2.3%)
	Pasif Misafirler (27.9%)	Russia (8.9%)	RO (23%)	WHS (15%)	DCW (24%)	Single (40.2%)	Autumn (26.2%)	Minibar (8.6%)	Cıkolata 50 Gr (2.9%)
	Uzun Süreli Konaklayanlar (1%)	Germany (7.9%)	HB (13,6%)	IND (14%)	SMD (6.8%)	WithChildren (7.3%)	High_summer (17.6%)	Pension Breakfast (8.3%)	Espresso Double (1.8%)
	Orta Harcama Orta Sıklık (9.4%)	United States (6.4%)	FB+ (7,3%)	COR (8.5%)	GDX (4.3%)	Triple (3.8%)	Spring (13.9%)	Room Service (7.3%)	Fındıklı Draje 45 Gr (1.8%)
	Sadık ve Prestijli Misafirler (0.4%)	United Kingdom(6.1%)	-	MTG (6.6%)	CON (4.3%)	-	Early_summer (10.9%)	Panorama Restaurant (6.8%)	Açık Büfe Akşam Yem. Otel (1.8%)
C	Yeni Misafirler (46.4%)	Turkey (36%)	BB (57,9%)	OTA (30.2%)	DSW (56,2%)	Couple (51%)	Winter (31.9%)	Room (6.7%)	A Marka Mineralli İçecek 75 CL (1.6%)

Pasif Misafirler (28.5%)	Russia (9.1%)	RO (19,9%)	IND (15.6%)	DCW (23.3%)	Single (38%)	Autumn (25.8%)	Pension Breakfast (7.8%)	Açık Büfe Akşam Yem. Otel (1.5%)
Uzun Süreli Konaklayanlar (14.7%)	Germany (8,4%)	HB (13%)	WHS (14.1%)	SMD (6.7%)	WithChildren (7.7%)	High_summer (17.6%)	Minibar (7.7%)	B Marka Filtresız Bira(1.5%)
Orta Harcama Orta Sıklık (10.%)	United States (6,3%)	FB+ (7,2%)	COR (8.1%)	GDX (3.6%)	Triple (3.4%)	Spring (13.4%)	Room Service (7%)	Patates Tava (1.4%)
Sadık ve Prestijli Misafirler (0.3%)	United Kingdom (6%)	FBE (0,8%)	MTG (6.9%)	CON (3.6%)	Quadruple (0.1%)	Early_summer (11.5%)	Panora Restaurant (6.6%)	Açık Büfe Kahvaltı Otel (1.3%)

Segment C, misafir oranının en geniş kısmını oluşturarak %42.59'luk bir paya sahiptir. POS işlem hacmi ise %38.8'i da bu kümeye aittir. Recency değeri 127.26 gün olup Segment A'dan en yakın tarihte konaklamış ikinci segmenttir. Frequency değeri 3.34 ile yine ikinci en sık konaklama yapan segment konumundayken Monetary değeri 6922.51 ile diğer kümelere göre açık ara en yüksektir. Bu durum, bu misafirlerin elde edilen oda gelirlerinin oldukça yüksek olduğunu göstermektedir. Lead Time 9.01 gün, Length of Stay ise 10.86 gün olarak hesaplanmıştır.

Segment C'de de yeni misafirler (%46.4) ve pasif misafirler (%28.5) öne çıkmaktadır. Ülke dağılımında Türkiye (%36) ve Rusya (%9.1) en fazla yer alan milliyetlerdir. Konaklama tercihi BB (%57.9) olarak dikkat çekerken, pazar kanalı OTA (%30.2) diğer segmentlerde olduğu birinci Segment A'da olduğu gibi IND (15.6%) pazar kanalı ikinci en çok tercih edilen kanaldır. Seyahat eşlikçisi olarak çoğu çiftler (%51) iken, kış (%31.9) ve yüksek yaz (%17.6) sezonları en yoğun dönemlerdir. Harcamalarda room service (%6.7) ve pansiyon BB (%7.8) olarak öne çıkarken, popüler ürünler arasında A Marka Mineralli içecek (%1.6) ve B Marka FILTRESİZ Bira (%1.5) yer almaktadır.

Segment C, göreceli olarak düşük CLV değerine sahip misafirlerin yer aldığı grup olsa da misafirlerin rezervasyon davranışlarına göre (Recency-Son rezervasyonu üzerinden geçen süre, Frequency-Rezervasyon sıklığı, Monetary- Toplam harcama) en prestijli segment olduğu söylenebilir.

3.7. Gerçeğe Alma- Web Uygulama ve Dağıtım

Bu bölümde, geliştirdiğimiz web tabanlı uygulamanın dağıtım süreci ve sağlanan teknolojik altyapı detaylandırılacaktır. Uygulama, PythonAnywhere platformu kullanılarak çevrimiçi olarak erişime sunulmuş ve otel işletmeleri için kullanılabilir hale getirilmiştir. PythonAnywhere, Python tabanlı projelerin hızlı ve kullanıcı dostu bir şekilde dağıtılmasını sağlayan bir bulut hizmeti olup, bu çalışmada ücretli hesap seçeneği kullanılarak daha geniş kaynaklar ve gelişmiş özellikler tercih edilmiştir. Aşağıda, uygulamanın dağıtım süreci ve sağlanan altyapıya dair ayrıntılar yer almaktadır.


3.7.1. Uygulamanın ve Teknolojik Altyapısının Geliştirilmesi

Uygulama, PythonAnywhere platformunda barındırılarak çevrimiçi hale getirilmiştir. PythonAnywhere, Python projelerinin bulut ortamında çalıştırılmasını sağlayan güçlü bir altyapıdır. Ücretli hesap seçeneği, yüksek CPU süresi, geniş depolama alanı ve ek özellikler gibi avantajlar sunarak uygulamanın performansını artırmıştır. Teknolojik altyapı açısından,

uygulama Python betikleriyle geliştirilmiş ve sanal ortam kullanılarak bağımlılıkların izole edilmesi sağlanmıştır. Bu sayede, platform bağımsız çalışacak şekilde tasarlanan uygulama, PythonAnywhere platformunda verimli bir şekilde çalıştırılmıştır.

3.7.2. CLV Modelinin Web Uygulamasına Entegrasyonu

CLV (Customer Lifetime Value) modelinin web uygulamasına entegrasyonu, otel işletmelerinin müşteri değerini daha doğru bir şekilde tahmin etmelerine ve pazarlama stratejilerini buna göre optimize etmelerine olanak sağlamaktadır. CLV modelinin entegrasyonu, uygulamanın backend kısmında gerçekleştirilmiş ve müşteri verileri üzerinden CLV tahminleri yapılmıştır. Bu entegrasyon sayesinde, otel yöneticileri her bir müşterinin gelecekteki değerini belirleyerek, özel pazarlama kampanyaları ve segmentasyon stratejileri oluşturabilirler. CLV hesaplamaları, kullanıcı dostu bir dashboard üzerinde görselleştirilerek, otel işletmelerinin stratejik kararlar almasına yardımcı olmaktadır.



Şekil 3.8 Web Uygulama Modeli

3.7.3. Kullanıcı Arayüzü ve İşlevleri

Bu bölümde, PythonAnywhere platformu üzerinde barındırılan, Dash bileşenleri ve Plotly kütüphanesi kullanılarak Python ile geliştirilen kullanıcı arayüzü ve işlevleri açıklanmaktadır. Kullanıcı arayüzü, interaktif veri görselleştirmelerini etkin bir şekilde sunmayı amaçlayan, kullanıcı dostu ve dinamik bir yapı ile tasarlanmıştır.

Uygulamanın geliştirilmesinde Dash, web tabanlı interaktif paneller oluşturma yeteneğiyle ön plana çıkmıştır. Plotly ise yüksek kaliteli ve dinamik görselleştirmeler sunarak kullanıcıların verileri detaylı bir şekilde incelemesini mümkün kılmıştır. Kullanıcı arayüzü, veri görselleştirme ve analiz süreçlerini kolaylaştırmak için çeşitli etkileşimli bileşenler (örneğin, açılır menüler, kaydırma çubukları ve seçim kutuları) içermektedir.

Arayüz, hem fonksiyonel hem de estetik açıdan optimize edilmiş bir yapıya sahiptir. Dinamik veri analizi ve gerçek zamanlı güncellemeler, kullanıcının sisteme girdiği parametrelere anında yanıt verilmesini sağlamaktadır. Ayrıca, grafikler ve görselleştirme araçları, kullanıcıların müşteri yaşam boyu değerini (CLV) daha derinlemesine incelemelerine olanak tanıyacak şekilde tasarlanmıştır.

Platformun PythonAnywhere üzerinde barındırılması, hem güvenilir bir çalışma ortamı sağlamakta hem de kolay entegrasyon ve ölçeklenebilirlik imkânı sunmaktadır. Bu altyapı sayesinde, kullanıcı arayüzü hem masaüstü hem de mobil cihazlar için uyumlu bir şekilde çalışmaktadır.

Bu bağlamda, kullanıcı arayüzünün geliştirilmesinde benimsenen yaklaşım, hem teknik gerekliliklere hem de kullanıcı deneyimine odaklanarak veri odaklı karar süreçlerini destekleyen etkili bir çözüm sunmayı amaçlamaktadır.

3.7.3.1. Uygulamaya Giriş

Web uygulamasının giriş ekranı (Şekil 3.9), kullanıcı doğrulama amacıyla tasarlanmıştır. Kullanıcı adı ve şifre alanları, güvenli oturum başlatmak amacıyla kimlik doğrulama protokolüne entegredir. Şifreler, veri tabanında hashlenerek saklanmaktadır.

Şekil 3.9 Uygulamaya Kullanıcı Adı ve Şifre ile Giriş Ekranı

3.7.3.2. Ana Ekran Özellikleri

Web uygulamasının ana ekranı, kullanıcı deneyimini optimize etmek amacıyla ve veriye dayalı analiz süreçlerini kolaylaştırmak için beş ana alana ayrılmıştır. Bu alanlar sırasıyla “Tarih filtreleme alanı”, “rapor tipi alanı”, “sekmeler alanı”, “dinamik veri tablosu alanı”, “analiz sonuçları ve görsel raporlama alanı” şeklindedir. Her bir alan kullanıcı dostu tasarımı sağlamak adına uygun bloklar halinde yerleştirilmiştir.

3.7.3.2.1. Tarih Filtreleme Alanı (Date Filter)

Bu alan Şekil 3.10’da görüldüğü gibi, veri setini belirli bir tarih aralığına göre filtrelemek için tasarlanmıştır. Kullanıcı, tarih seçim araçlarını kullanarak "Check-in" tarihine göre verileri istediği aralıkta çağırabilir. Filtreleme sonucunda, sadece seçilen zaman aralığındaki veriler sisteme çağırılır. Ayrıca bu ekranda ne zaman değişiklik yapılırsa diğer tüm analizler de interaktif olarak güncellenmektedir. Böylece sayfanın dinamik yapısı korunarak istenilen analizlerde tarih filtrelemelerine olanak sağlanmıştır.

The screenshot displays the 'Smart Reporting' dashboard. At the top, there's a blue header with the title 'Smart Reporting'. Below it, a 'Date Filter' section contains a 'Start Period' and 'End Period' input field. To the right, a 'Report Type' dropdown menu is set to 'Booking Window'. A calendar widget for December 2024 is open, showing dates from 1 to 31. Below the calendar, there are four data columns: 'Reservation Status', 'Room Revenue', 'Nationality', and 'Repeat Status'. The interface is clean and modern, with a blue and white color scheme.

Şekil 3.10 Tarih Filtreleme Alanı

3.7.3.2.2. Rapor Tipi Alanı (Report Type)

RFM, CLV ve Booking Window temelli üç farklı rapor tipinin yer aldığı bu alan (Şekil 3.11), uygulamanın temel analiz süreçlerini başlatmaktadır. Kullanıcı rapor tipi seçimine göre, ilgili rapor tipi backend'e iletilir ve veriler üzerinde uygun analiz işlemleri gerçekleştirilir. Tarih filtreleme ile bu alan, uygulamanın temel filtreleme mekanizmasını oluşturur. Ayrıca bu alanlar tasarımda en yukarıda yer almaktadır. CLV temelindeki analizlere ulaşmak için “Report Type” kısmından CLV’yi seçmek yeterli olmaktadır. Böylece ilgili tarih aralığındaki verilere yönelik CLV temelindeki analizleri gerçekleştirmek mümkündür.

Smart Reporting

OPEN OFFCANVAS

Date Filter

1-1-2021 → 31-12-2021

Report Type

CLV
Booking Window
RFM
CLV

Filter by


Main | Reservation Status | Room Revenue | Nationality | Repeat Status

Analizler ve raporlamalar bir miktar zaman almaktadır.


Şekil 3.11 Rapor Filtreleme Alanı

3.7.3.2.3. Sekmeler Alanı

Bu alan, uygulama ekranında ‘Filter by’ alanı olarak da anılmaktadır. Rapor tipine göre özelleşmiş beş sekmeyi içerir. Bu sekmeler sırasıyla “Main”, “Reservation Status”, “Room Revenue”, “Nationality”, ve “Repeat Status” şeklinde tasarlanmıştır. Her bir sekme, hedef değişkeni odak alarak seçilen rapor tipi doğrultusunda analitik çıktılar ve görseller sunmaktadır. Main sekmesi daha çok veriye ve seçilen değişkene yönelik ilk görüşleri sunmakta iken, “Reservation Status” farklı rezervasyon statülerine göre seçilen değişkenleri karşılaştırır. Benzer şekilde değişkenleri oda gelirlerine göre ele almak için “Room Revenue” sekmesi tasarlanmıştır. Değişkenlerin milliyete göre karşılaştırılması “Nationality” ekranından yapılırken, misafirlerin oteli ziyaret sayılarına göre karşılaştırmalar “Repeat Status” ekranından yapılır.




Treemap of CLTV Segment with path of RFM Segments, Market, Agency, Nationality, Travel Companion based on Total Night




Şekil 3.12 Main Sekmesi Seçiliyken CLV Kümelerine Ait Genel Durumu Gösteren Analiz Raporu Örneği

Şekil 3.12’da Main alanı seçiliyken rapor tipinin genel durumu aşağıdaki şekilde gösterilmiştir. Söz gelimi ilk blokta CLV segmentlerinin dağılımına yönelik bir görsel yer almaktadır. Sağda yer alan ikinci blokta toplam geceleme sayılarına göre segmentler karşılaştırılmıştır. Altta yer alan ağaç grafiğinde ise toplam gecelemeye göre çoklu değişkenlerle CLV segmentlerinin ağaç grafiği yapılmıştır.




Şekil 3.13 Kümelerin Rezervasyonların Giriş Tarihine Göre Rezervasyon Penceresinin Ortalamasını Gösteren Grafik

Bir diğer ekran olan “Reservation Status” alanı seçiliyken rapor tipinin rezervasyon durumu Şekil 3.13’de gösterilmiştir. Şekilde kümelerin rezervasyonların giriş tarihine göre rezervasyon penceresinin ortalamasını gösteren grafik yer almaktadır. CLV segmentleri de şekil üzerinde tarihsel düzeyde karşılaştırmalı olarak görülmektedir.




Şekil 3.14 CLV Kümelerinin Acentalara Göre Dağılımını Gösteren Çubuk Grafik

Şekil 3.14’te yer alan diğer şekil ise yine “Reservation Status” sekmesinin altında üretilmiştir. Bu şekilde segmentlerin acentelere göre dağılımını gösteren bir çubuk grafiği yer almaktadır. Şekilde yer alan renklerin her biri farklı acenteleri temsil etmektedir. Her bir CLV segmenti ise birbirinden ayrı olarak grafikte yer almaktadır.




Şekil 3.15 CLV Kümelerinin Pazar Segmentlerine Göre Dağılımını Gösteren Çubuk Grafik

“Reservation Status” sekmesinin altında üretilmiş bir diğer analiz ise Şekil 3.15’te bulunan Pazar segmentleri analizidir. Bu şekilde CLV kümelerinin pazar segmentlerine göre dağılımını gösteren çubuk grafik yer almaktadır. Analizde yer alan renklerin her biri farklı pazarları temsil etmektedir. Her bir CLV segmenti ise birbirinden ayrı olarak grafikte bulunmaktadır.




Şekil 3.16 CLV Kümelerinin Seyahat Eşlikçisine Göre Dağılımını Gösteren Çubuk Grafik

Şekil 3.16’te bulunan seyahat eşlikçisi analizi de “Reservation Status” sekmesinin altında üretilir. Bu şekilde CLV kümelerinin seyahat eşlikçisine göre dağılımını gösteren çubuk grafik yer almaktadır. Analizdeki renklerin her biri farklı seyahat eşi durumunu temsil etmektedir. Her bir CLV segmenti ise birbirinden ayrı olarak grafikte bulunmaktadır.




Şekil 3.17 Giriş Tarihlerine Göre Beklenen Ortalama Kar Sıcaklık Haritası

Şekil 3.17’te bulunan kar marjı tahmini analizi de “Reservation Status” sekmesinin altında üretilir. Bu şekilde giriş tarihlerine göre beklenen ortalama kar sıcaklık haritası gösterilmiştir. Analizdeki koyu renkler daha yüksek değerleri, açık renkler ise daha düşük kar marjlarını temsil etmektedir. Seçili olan tarih aralığına göre günler x ekseninde aylar ise 12 ay boyunca yukarıdan aşağı doğru y ekseninde sıralanmaktadır.




Şekil 3.18 CLV Kümelerinin Oda Gelirine Göre Açılır Menüden Seçmeli Temel İstatistiksel Dağılımını Gösteren Grafik

Şekil 3.18'da yer alan ilk blok CLV segmentlerinin istatistiksel dağılımlarını açılır menü yardımıyla vermektedir. Solda yer alan blok ise aynı şekilde “Room Revenue” sekmesi ile birlikte üretilmektedir. Şekilde CLV segmentasyonuna göre gelir dağılımı analiz edilmektedir. Huni şeklindeki grafik, müşterilerin farklı CLV segmentlerine göre gelir katkısını görselleştirmektedir. Grafik, şirketin müşterilerini CLV değerlerine göre analiz ederek hangi segmentlere odaklanması gerektiği konusunda stratejik içgörüler sağlamaktadır.



Şekil 3.19 CLV Kümelerinin Oda Gelirinin Solda Pansiyon Durumu Sağda Aylara Göre Dağılımını Gösteren Çubuk Grafik

3.19’de bulunan seyahat eşlikçisi analizi de “Room Revenue” sekmesinin altında üretilir. Bu şekilde CLV kümelerinin oda gelirinin solda pansiyon durumu sağda aylara göre dağılımını gösteren çubuk grafik yer almaktadır. Analizdeki renklerin her biri farklı CLV segmentlerini temsil etmektedir. Soldaki blokta Y ekseninde oda geliri, X ekseninde ise board tipi bulunmaktadır. Sağdaki blokta ise Y ekseninde oda geliri, Y ekseninde ise otele giriş yapılan aylar yer almaktadır.




Şekil 3.20 CLV Kümelerinin Oda Gelirine Göre RFM Kümeleri, Pazar Segmenti, Acenta, Ülke ve Seyahat Eşkenliğine olan Dağılımını Gösteren Ağaç Grafiği

“Room Revenue” sekmesindeki Şekil 3.20’de yer alan ağaç grafiği, RFM kümelerine, pazara, milliyete, seyahat arkadaşın değişkenlerinin oda gelirine göre gruplandırılmış müşteri kümelerini göstermektedir. CLV Kümelerine göre sınıflandırılmış bu grafikte, her küme farklı bir renklerle temsil edilmiş ve her kümenin büyüklüğü oda gelirini büyüklüğünü temsil etmektedir. Grafik interaktif olup en alt kıvrıma kadar detaylandırılabilir.

Top 20 Nationality and Segments Statistics by Room Revenue Total Nights, Average Lead Time, Total Pax, Total Free Child, Total Paid Child, Total Baby									
CLTV Predict Segment	Nationality	Total Room Revenue	Average Room Revenue	Total Nights	Average Nights	Average Lead Time	Total Pax	Total Free Child	Total Paid Child
Churn Risk Customer	TURKEY	6917277.21	436.15	35766	2.26	0.46	19026	184	4
Potential Growth Prospects	TURKEY	1982056.04	207.2	20365	2.13	1.06	12205	176	11
High-Value VIPs	TURKEY	1426260.91	283.72	14466	2.88	6.23	7248	242	15
Churn Risk Customer	GERMANY	996859.69	402.77	8862	3.58	1.94	2854	10	0
Potential Growth Prospects	GERMANY	978386.95	834.09	7997	6.82	2.32	1611	42	0
High-Value VIPs	RUSSIA	623837.68	852.24	3654	4.99	5.27	1197	32	0
High-Value VIPs	GERMANY	426677.69	626.55	3318	4.87	4.75	970	19	2
Churn Risk Customer	RUSSIA	388634.78	187.84	4110	1.99	0.33	3390	137	19
Potential Growth Prospects	RUSSIA	291524.58	382.08	2488	3.26	0.99	1114	85	4
Churn Risk Customer	AUSTRALIA	257509.42	675.88	5399	14.17	7.13	411	0	0
Churn Risk Customer	UNITED KINGDOM	223668.66	880.59	1725	6.79	1.19	385	7	0
Churn Risk Customer	SAUDIA ARABIA	221646.64	510.71	873	2.01	-0.64	809	8	0
High-Value VIPs	NETHERLANDS	176976.68	1179.84	728	4.85	9.38	223	47	0
Churn Risk Customer	ITALY	170516.03	411.87	1398	3.38	2.44	435	0	0
Churn Risk Customer	DENMARK	159587.76	2346.88	238	3.5	3.65	148	0	0
Churn Risk Customer	AZERBAIJAN	147255.03	433.1	632	1.86	-0.69	575	0	0
Churn Risk Customer	AFGHANISTAN	137401.30	305.68	1398	3.01	3.57	654	0	0


Şekil 3.21 CLV Kümelerinin En Çok Rezervasyonu Olan İlk 20 Ülkenin Numerik Değişkenlere Göre Dağılım Tablosu

“Nationality” sekmesinde yer alan Şekil 3.21’de milliyetlerin durumu incelenmektedir. Şekilde CLV kümelerinin en çok rezervasyonu olan ilk 20 ülkenin numerik değişkenlere göre dağılım tablosu mevcuttur. Tablo aslen bir plotly şekli olduğu için esnek olarak büyütülüp ekran görüntüsü alınabilir. Aşağı yukarı yönlü hareket ettirilme özelliği de mevcuttur.



Şekil 3.22 CLV Kümelerinin Ülkelere Göre Yüzdesel Dağılımı

“Nationality” sekmesinde yer alan bir diğer alan ise ülkelerin yüzdelik dilimler halinde gösterildiği ve ekrandan süzulebildiği CLV kümelerinin ülkelere göre yüzdesel dağılımı ekranında yapılmaktadır (Şekil 3.22). Bu şekilde renkler farklı ülkeleri temsil etmektedir. CLV kümeleri birbirinden bağımsız olacak şekilde konumlandırılmıştır.



Şekil 3.23 CLV Kümelerinin Oda Gelirine Göre Farklı Değişkenler Üzerinde Dağılımını Gösteren Ağaç Grafiği

Son sekme olan “Repeat Status” alanı seçiliyken ortaya çıkan ağaç grafiği Şekil 3.23’de gösterilmektedir. Bu şekilde tek bir blok halinde CLV kümelerinin oda gelirine göre farklı değişkenler üzerinde dağılımını gösteren ağaç grafiği yer almaktadır. Her renk bloğu bir CLV segmentini temsil etmekle birlikte blokların büyüklüğü oda gelirinin büyüklüğü ile doğru orantılıdır.

3.7.3.2.4. Dinamik Veri Tablosu Alanı

Dinamik veri tablosu alanı, ana filtreleme işlemleri sonrasında, kullanıcının veriyi ayrıntılı incelemesine olanak sağlayan tablo ekranıdır. Şekil 3.24 örneğinde görüldüğü gibi her bir değişken için tablo üzerinden ayrıca dinamik filtreleme yapılabilir. Bu esneklik, verinin daha derinlemesine analiz edilmesine olanak tanımaktadır. Bu ekran tarih filtrelemesinden bağımlı olarak değişse de, değişkenler düzeyinde tarih filtresinde herhangi bir değişiklik yapılmaksızın verilerin filtrelenmesi sağlanmaktadır. İşlemler interaktif olarak

gerçekleştiği için her bir filtrelemeden sonra ilgili rapor tipine ve sekmeye göre ilgili analizler de güncellenmektedir.

Click for more information.

	Nationality	Gender	Repeat	Age	CIN Date	COUT Date	Board	Vip	Type	Room	Type	Pric
	USA	Female					RO					
	USA	Female	5	38	2021-01-31T00:00:00	2021-02-02T00:00:00	RO	VIP	3		DSW	
	USA	Female	5	38	2021-01-31T00:00:00	2021-02-02T00:00:00	RO	VIP	3		DSW	
	USA	Female	5	38	2021-01-31T00:00:00	2021-02-02T00:00:00	RO	VIP	3		DSW	
	USA	Female	5	38	2021-01-31T00:00:00	2021-02-02T00:00:00	RO	VIP	3		DSW	
	USA	Female	5	38	2021-01-31T00:00:00	2021-02-02T00:00:00	RO	VIP	3		DSW	

Şekil 3.24 Filtrelenebilir İnteraktif Tablo

3.7.3.2.5. Analiz Sonuçları ve Görsel Raporlama Alanı

Bu alan daha önce bahsedilen analizler ve onların haricinde yer alan tüm analizlerin yer aldığı bölümü temsil etmektedir. Seçilen rapor tipi ve sekme doğrultusunda gerçekleştirilen analizlerin sonuçlarını görsel ve metinsel formatta kullanıcıya bu alanda sunulmaktadır. Kullanıcı, raporlama sonuçlarını burada detaylı inceleyebilmekte ve gerektiğinde farklı seçimlerle analizleri yeniden yönlendirebilmektedir. Ekran aşağı- yukarı hareket ettirilerek tüm sonuçlara ulaşılabilir. Bu alanda ilgili görseller “Sekmeler Alanı” başlığı altında ayrı ayrı olacak şekilde tasarlanmıştır.

Uygulama, analiz sonuçlarını Python Plotly kullanarak interaktif tablolar ve görsellerle sunmaktadır. Bu sayede kullanıcılar, verileri daha dinamik bir şekilde keşfedebilmekte ve analizlerini görsel olarak inceleyebilmektedirler.

SONUÇ

Bu tez çalışmasında, otel sektöründe müşteri yaşam boyu değeri (CLV) ve RFM entegrasyonunu kullanarak misafir davranışlarını analiz etmeye odaklanılmıştır. Rezervasyon verisi ve otel içi ekstra harcama verilerinin entegre edilmesiyle gerçekleştirilen bu çalışma, teorik ve uygulamalı alanlarında önemli katkılar sağlamaktadır. Özellikle, yenilikçi veri analizi tekniklerinin kullanılması, titiz müşteri segmentasyonu ve ML algoritmalarını kullanarak her bir misafir için CLV değeri tahmin edilmesi ve analiz sonuçlarının interaktif web tabanlı bir uygulama üzerinden sunulmuş olması bu konuda yapılacak çalışmalar için ayrıntılı bir yol haritası sunmaktadır. Bu uygulama, otel yöneticilerinin karar alma süreçlerini destekleyecek şekilde, veri odaklı bir yapıda gerçek zamanlı analiz sağlamaktadır.

Araştırma sonucunda oluşturulan RFM ve CLV kümelemeleri ışığında, misafir davranışlarını ölçen Recency, Frequency, ve Monetary parametrelerinin literatürde de bahsedildiği gibi (Dursun ve Caber, 2016) otel sektöründe çok önemli belirleyiciler olduğu ortaya konulmuştur. RFM analizine göre Küme 2 gibi yüksek değerli misafir gruplarının ($R \downarrow F \uparrow M \uparrow$) özellikle sık ve yüksek harcama yapan sadık misafirlerden oluştuğu tespit edilmiştir. Bu durum literatürdeki baskın görüşü de desteklemektedir (Stahl vd., 2012). Buna karşılık Küme 0 ve Küme 1, daha düşük harcama ve seyrek ziyaret alışkanlıklarıyla düşük değerli misafirleri içermektedir. Literatürde bu gibi davranışların kümeleme için önemli veriler olduğu söylenmiştir (Safari vd., 2016).

CLV analizi ile A, B ve C segmentlerine ayrılarak otelin farklı değer gruplarındaki müşteri profilleri detaylı bir şekilde analiz edilmiştir. CLV segmentlerinin ortak noktalarına baktığımızda A, B ve C segmentleri, müşteri yaşam boyu değeri açısından farklı özellikler taşımakla birlikte bazı benzerliklere de sahiptir. Her üç segmentte de yeni misafirler ve pasif misafirler önemli bir paya sahiptir. Özellikle yeni misafirlerin her kümede %45'in üzerinde bir oranla yer alması, otelin geniş çapta yeni misafir çekme kapasitesini ve pazar payını artırma yeteneğini gösterse de Kumar ve Shah (2004) müşteri elde etme ve tutma maliyetlerinin dengeli bir şekilde kullanımına dikkat çekmektedir. Ayrıca, tüm kümelerde Türkiye ve Rusya en baskın milliyetler olarak dikkat çekmektedir. Bu durum, otelin coğrafi olarak belirli bir müşteri tabanına hitap ettiğini ve bu ülkelerde güçlü bir pazar payına sahip olduğunu ortaya koymaktadır. Ayrıca Türkiye'yi ziyaret eden turistlerin milliyetleri ve Antalya şehir merkezinde yer alan otelin konumuyla açıklanabilir bir durumdur (Kültür ve Turizm Bakanlığı, 2024). Benzer şekilde, BB (oda kahvaltı) konaklama tipi ve OTA (online seyahat acenteleri) pazar kanalı, üç kümede de en sık tercih edilen seçeneklerdir. Bu ortak eğilim, müşterilerin

ekonomik ve esnek konaklama seçeneklerine yöneldiğini ve online platformların rezervasyon kanallarında belirleyici bir rol oynadığını göstermektedir ve literatürde de OTA'ların gelirler açısından önemi vurgulanmıştır (Mao vd., 2023). Seyahat eşlikçisi açısından ise çiftler her üç kümede de en baskın kategori olarak yer almakta, otelin çiftlere yönelik hizmetlerde başarılı bir deneyim sunduğu çıkarımını yapabilmektedir. Ayrıca çiftlerin yeni bir tatil yerinden memnun kaldıklarında otel içerisinde beraber kaliteli zaman geçirmekten de memnun kaldıkları söylenmektedir (Yoo ve Wilson, 2020).

Ayrışan noktalara gelindiğinde, harcama düzeyi (Monetary), konaklama sıklığı (Frequency) ve rezervasyon yakınlığı (Recency) kriterlerinde belirgin farklılıklar gözlenmektedir. Segment C, en yüksek Monetary değeri (6922.51) ile öne çıkarken, bu durum bu grubun parasal değer olarak otelin önemli bir müşteri tabanını oluşturduğunu göstermektedir. Buna karşılık segment B, Monetary (1752.68) ve Frequency (2.81) açısından en düşük değerlere sahip olup, düşük harcama kapasitesine ve seyrek konaklama alışkanlığına işaret etmektedir. Segment A ise Frequency (6.65) değeriyle en yüksek sıklıkta konaklama gerçekleştiren misafir grubunu temsil etmekte, ancak Monetary değeri (5306.64) ile Segment C'nin altında kalmaktadır. Bu farklılıklar, Segment A'nın mevcut harcama potansiyelini artırmak için müşteri odaklı kampanyalar ve hizmetler ile desteklenmesi gerektiği hakkında fikir vermektedir.

Bir diğer önemli ayrışma noktası ise Lead Time ve Length of Stay süreleridir. Segment B, Lead Time değeri (16.37 gün) ile rezervasyonlarını en erken yapan misafir grubu olarak öne çıkarken, bu durum planlı ve düşük harcama yapan müşteri profiliyle tutarlılık göstermektedir. Buna karşın Segment A ve Segment C, Lead Time açısından birbirine yakın değerler (9.03 gün ve 9.01 gün) sergileyerek rezervasyonların daha kısa süreli planlandığını göstermektedir. Konaklama süreleri açısından Segment A ve Segment C, Length of Stay değerinde (10.86 gün) benzer olup, uzun süreli konaklamaların baskın olduğu misafir gruplarıdır. Segment B ise daha kısa süreli konaklamaları (9.49 gün) tercih eden bir yapıdadır.

Sezon dağılımı da kümeler arasında farklılık göstermektedir. Her üç kümede kış ve sonbahar sezonları ortak tercih edilse de, Segment C'de yüksek yaz sezonu (%17.6), Segment A ve B'ye kıyasla daha yüksek bir orana sahiptir. Bu durum, Segment C'deki müşterilerin tatil sezonunda da yüksek harcama eğiliminde olduğunu göstermektedir. Ayrıca, Segment B ve C gruplarında tek başına seyahat edenler ve çocuklu aileler öne çıkarken, diğerlerine göre Küme A'da çiftler daha baskın bir paya sahiptir.

Ürün bazlı harcamalar da segmentler arasında farklılık göstermektedir. Segment A'da açık büfe akşam yemeği ve minibar harcamaları dikkat çekerken, Segment B'de çikolata ve

atıştırmalıklar öne çıkmaktadır. Segment C ise premium ürünler ile farklılaşmakta, bu da bu müşterilerin kaliteye ve lükse yönelik harcama eğiliminde olduğunu göstermektedir.

Sonuçlar ışığında, otel yöneticilerine önerilen stratejiler şunlardır:

Yeni Misafirlerin Sadık ve Yüksek Değerli Misafirlere Dönüştürülmesi: Yeni misafirlerin oranı iki segment yapısında da %45'in üzerindedir. Yeni misafirlerin ilk deneyimlerinin iyileştirilmesi, kişiselleştirilmiş hizmetler ve memnuniyet ölçümü ile sadık müşterilere dönüştürülmesi sağlanmalıdır. C segmentindeki CLV değerine göre en alt segment olmasına karşılık bu segment tercih edilen sezon ve yeni misafir oranı açısından dikkat çekmektedir. Bu, özellikle uzun süreli konaklama ve premium hizmet tercihleriyle dikkat çekmektedir. Bu kümeye özel indirimler, sadakat programları ve kişiselleştirilmiş hizmetler sunularak sadakat artırılabilir.

Sadık ve Yüksek Değerli Misafirlerin Kullanım Alışkanlıklarının Yönlendirilmesi: En değerli Segment A misafirleri, sık konaklama yapmalarına rağmen harcama seviyesi açısından ilk sırada değildir. Bu grupta ek harcamaları teşvike yönelik kampanyalar, paket servisler ve otel içi harcamaları özendiren uygulamalar geliştirilmelidir. Ayrıca CLV değeri olarak ilk sırada yer alan A segmentinin genel durumda orta değerde kalmasının Recency değerinden kaynaklandığına dikkat çekmek gerekmektedir. Bu bağlamda bu misafirlerin konaklama zamanlarını yaz sezonuna kaydırmaya teşvik edilebilir ve rezervasyon süreleri arasındaki farkın da azaltılmasına yönelik hatırlatıcı kampanyalar düzenlenebilir.

Sezon Odaklı Stratejiler: Kış ve sonbahar dönemlerinin baskın olmasına rağmen, yüksek CLV değerli C segmentinde yaz döneminde de belirgin bir talep gözlemlenmektedir. Bu nedenle yüksek değerli misafirleri yaz döneminde çekmek için erken rezervasyon kampanyaları ve özel teklifler geliştirilmelidir.

Teoriye Yönelik Katkılar

Bu tez çalışması, teorik katkılar bakımından önemli bir yenilik sunarak, CLV'yi RFM analiziyle entegre eden otel sektörü özelindeki ilk çalışmalardan biri olma özelliği taşımaktadır. Çalışma, RFM modelinin Recency, Frequency ve Monetary (RFM) parametrelerini CLV tahminleriyle birleştirerek daha derinlemesine bir analiz imkânı sağlamış ve bu yöntemle müşteri davranışlarını tahmin etmek için ML algoritmalarından yararlanmıştır. Bu yönüyle, pazarlama literatüründe önemli bir teori geliştirme katkısı sağlamakta, müşteri analizlerinde yeni bir perspektif sunmaktadır.

Tez, CLV analizlerinde genellikle finans veya perakende sektörünün ele alındığı literatürün aksine, otelcilik sektörünü odak noktası haline getirerek bu alandaki bilgi boşluğunu

doldurmaktadır. Özellikle, otel rezervasyon verileri ile otel içi ekstra harcamaların birleştirilmesi, teorik anlamda önemli bir yenilik sunmaktadır. Bu tür bir bütünleşik veri kullanımı, müşteri değerlemesinde daha kapsamlı bir yaklaşım geliştirilmesine olanak tanımış, aynı zamanda pazarlama stratejileri için daha isabetli tahminlerin yapılmasını sağlamıştır.

Çalışmada, müşteri davranışlarını incelemek üzere demografik ve davranışsal değişkenlerin analizlere entegre edilmesi, CLV'yi etkileyen çeşitli faktörlerin çok boyutlu bir şekilde değerlendirilmesine olanak tanımıştır. Bu kapsamda CLV'nin Lead Time, Length of Stay ve Season gibi değişkenlerle ilişkisinin ele alınması, konaklama sektörü için daha çeşitli müşteri analizleri yapılmasına olanak sunmuş ve sektöre özgü stratejik öneriler geliştirilmesine katkıda bulunmuştur.

Bir diğer yenilikçi katkı, müşterilerin otel içi ekstra harcamalarına göre segmentlere ayrılmasıdır. Bu yaklaşım, çapraz satış stratejilerinin geliştirilmesi için önemli bir zemin hazırlamış, aynı zamanda otel yöneticilerine, kaynak optimizasyonuna yönelik yeni stratejiler geliştirme olanağı sunmuştur. Çalışma, CLV segmentlerinin müşteri değeri odaklı bir yaklaşımla ele alınmasını teşvik etmekte ve gelecekteki akademik çalışmalara referans niteliğinde bir model sunmaktadır.

Tezin de bulguları arasında yer alan misafiri elde tutma ve kazanma arasındaki dengenin hassasiyeti bu çalışma ile de kanıtlanmıştır. Segmentler incelendiğinde az sayıda “sadık ve prestijli” misafirin geliri etkileyebileceği görülmüştür. Çalışmamız yeni misafir edinme ve mevcut misafiri tutma maliyetlerinin ayrı ayrı değerlendirilmesi gerektiğini de ortaya koymaktadır. Bu sayede çalışmamız CLV'nin doğru bir değerlendirilmesini önermiş olmaktadır.

Ek olarak, turizm gibi uygulama yoğun bir sektörde yapılan bu çalışmanın, akademik çıktıları bir Web Uygulaması ile desteklenerek analiz sonuçlarıyla uygulama arasında köprü kurmayı başarmıştır. Bu bağlamda, araştırma bulgularının sektörel pratiğe aktarılabilir olması hem akademik hem de endüstriyel alanda önemli bir fayda sağlamaktadır.

Son olarak, RFM ve CLV analizlerinin entegre kullanımına yönelik sistematik ve prosedüre dayalı bir literatür taraması yapılmış ve bu yöntemlerin otelcilik sektörüne yönelik uygulanabilirliği, literatür bağlamında sistematik bir şekilde incelenmiştir. Bu katkı, hem akademik çalışmalara yönelik yeni bakış açıları sunmaktadır. Tezin bulguları, teorik düzeyde literatürü zenginleştirdiği gibi pratikte de otelcilik sektörünün müşteri odaklı stratejiler geliştirmesine yardımcı olacak niteliktedir.

Uygulamaya Yönelik Katkılar

Bu tez çalışmasının önemli bir çıktısı olan web tabanlı uygulama, otel yöneticilerine müşteri değerlerini gerçek zamanlı ve interaktif bir şekilde analiz etme imkânı sunmaktadır. RFM ve CLV segmentasyonlarını temel alarak geliştirilen bu uygulama, kullanıcıların müşteri kümelerini görsel ve detaylı bir biçimde inceleyebilmesine olanak tanımaktadır. Python Plotly gibi modern veri görselleştirme araçlarıyla desteklenen analizler, kullanıcı deneyimini güçlendirerek otel yöneticilerinin karar alma süreçlerini hızlandırmaktadır.

Otel yöneticileri, uygulama aracılığıyla yüksek değerli müşteri kümelerini kolaylıkla tespit edebilir ve bu müşterilere yönelik kişiselleştirilmiş pazarlama stratejileri geliştirebilir. Özellikle, sadık ve yüksek harcama yapan misafir gruplarına yönelik olarak veri odaklı kampanyalar düzenlenmesi mümkün hale gelmiştir. Bu süreç, yalnızca mevcut müşterilerin korunmasını değil, aynı zamanda yeni misafirlerin sadık müşterilere dönüştürülmesini de desteklemektedir. Uygulama, müşteri segmentasyonu sonuçlarını analiz ederek düşük değerli müşteriler için gelir artırıcı stratejiler geliştirilmesine ve bu müşterilerin otel içi harcama potansiyelinin artırılmasına olanak sağlamaktadır.

Otel içi ekstra harcamaların hangi müşteri segmentlerinde yoğunlaştığını detaylı bir şekilde ortaya koyan uygulama, otel yönetimine gelirlerini artırıcı yeni yöntemler sunmaktadır. CLV modelinin entegrasyonu sayesinde uzun vadeli yüksek değerli müşterilerle ilişkilerin güçlendirilmesi ve stratejik kaynak tahsisi sağlanmaktadır. Yönetim, bu uygulama ile müşteri verilerini daha verimli bir şekilde analiz ederek, otel gelirlerini artırabilecek öncelikli alanları belirleyebilir ve operasyonel verimliliği artırabilir.

Uygulama, müşteri değerine dayalı segmentasyon analizleri ile otel işletmelerine özelleştirilmiş hizmetler ve promosyonlar geliştirme olanağı tanımaktadır. Örneğin, yüksek CLV değerine sahip müşteriler için premium hizmetler sunulabilirken, daha düşük CLV değerli müşteriler için otel içi harcamaları teşvik eden kampanyalar düzenlenebilir. Ayrıca, sezonluk müşteri davranışları ve segmentler arasındaki harcama alışkanlıklarının ortaya konması, otel yöneticilerine hedefli pazarlama stratejileri geliştirme konusunda önemli bir rehberlik sunmaktadır.

Uygulama, yalnızca mevcut müşteri verilerinin analiz edilmesini değil, aynı zamanda gelecekteki müşteri davranışlarının tahmin edilmesini de sağlamaktadır. ML algoritmaları ile güçlendirilen bu yapı, otel işletmelerinin stratejilerini gelecekteki eğilimlere göre şekillendirmelerine yardımcı olmaktadır. Bu sayede, müşteri sadakati artırılabilir, müşteri memnuniyeti sağlanabilir ve otelin rekabet gücü önemli ölçüde artırılabilir.

Analiz sonuçlarının Python Plotly ile görselleştirilmesi, kullanıcıların verileri interaktif bir şekilde incelemesine ve derinlemesine analiz yapmasına olanak tanımaktadır. Bu özellik, uygulamanın kullanıcı dostu bir deneyim sunmasını sağlamakta ve otel yöneticilerinin veriye dayalı karar alma becerilerini geliştirmektedir. Ayrıca, uygulama aracılığıyla oluşturulan interaktif tablolar, müşteri verilerini görsel olarak daha kolay anlamaya ve stratejik aksiyonların hızla alınmasına katkıda bulunmaktadır.

Kısıtlar ve Gelecek Çalışmalar İçin Öneriler

Bu tez çalışması, otel sektöründe yenilikçi bir müşteri analizi yaklaşımı sunmasına rağmen bazı doğası gereği bazı kısıtlamalara da sahiptir. Çalışmanın kapsamı, kullanılan veri setinin özellikleri ve metodolojik tercihler, elde edilen sonuçların genellenebilirliği açısından dikkatle ele alınmalıdır.

Tezde kullanılan veri seti, hemen pandemi ardındaki döneme ait olduğu için misafir davranışlarında pandemi koşullarının doğrudan veya dolaylı etkileri gözlemlenmiş olabilir. Bu durum, elde edilen sonuçların farklı dönemlerde geçerliliği konusunda kısıtlar yaratmaktadır. Ayrıca, rezervasyon verileri ile otel içi harcama (POS) verilerinin birleştirilmesi sırasında yaşanan veri kaybı, analizlerin arzu edilen kapsamdaki sonuçlara ulaşmasını engellemiş olabilir. Her ne kadar büyük veri kullanılmış olsa da örneklem büyüklüğünün belirli “koşulları sağlayanlarla” sınırlı olması da sonuçların farklı oteller veya konaklama sektörünün farklı aktörleri için genellenebilirliğini sınırlandıran bir diğer faktördür.

Bu çalışmada CLV segmentasyonu için kullanılan MinMax Scaling yöntemi, veri ölçeklendirme süreçlerinde belirli sınırlamalar yaratabilmektedir. Ölçekleme yöntemi, farklı veri setleri veya bağlamlar için farklı sonuçlar üretebileceğinden, sonuçların genelleştirilmesi konusunda dikkatli olunmalıdır. Ayrıca, RFM analizi yalnızca Recency, Frequency ve Monetary parametrelerine dayalı olarak yapılmış olup, bu parametrelerin ötesinde kalan müşteri davranışlarını veya diğer potansiyel etkileyicileri analizlere dâhil etmemiştir.

RFM ve CLV’nin birleştirilmesi yenilikçi bir yaklaşım sunmakla birlikte, bu entegrasyonun daha fazla geliştirilmesi ve test edilmesi gereken yönleri olabilir. Örneğin, modelde kullanılan değişkenler ve metodolojik tercihler, farklı sektörlerde veya bağlamlarda yeniden ele alınabilir. Ayrıca, bu çalışma tek bir otelden elde edilen verilerle sınırlı olduğundan, sonuçların benzer profildeki diğer otellere genellenmesi sınırlı olabilir. Ancak geliştirilen web tabanlı uygulama, farklı otel türlerinde kullanılabilir şekilde tasarlanmıştır; bu da gelecekteki çalışmalar için geniş bir uygulama potansiyeli sunmaktadır.

Çalışmamızda gelecek çalışmalar için bazı öneriler mevcuttur. Bu öneriler belirli başlıklar altında sıralanmıştır:

- **Daha Geniş ve Çeşitli Veri Setleri:** Gelecekteki araştırmalar, daha geniş örneklem grupları ve farklı coğrafi bölgelerden elde edilen veri setleri ile yürütülebilir. Böylece, farklı kültürel ve ekonomik bağlamlarda müşteri davranışları incelenebilir.
- **Metodolojik Derinleşme:** Çalışma, mevcut metodolojik yaklaşımların ötesine geçerek, yenilikçi yöntemlerin kullanılması ile zenginleştirilebilir. Özellikle, farklı ölçekleme teknikleri ve segmentasyon algoritmalarının karşılaştırılması, daha modellerin geliştirilmesine katkıda bulunabilir.
- **Disiplinlerarası Yaklaşımlar:** Çalışmanın turizm, pazarlama ve veri bilimi gibi farklı disiplinlerden bilgi ve tekniklerle desteklenmesi, müşteri analizi süreçlerine yeni bakış açıları kazandırabilir.
- **Sektörel Çeşitlilik:** Otelcilik sektörünün yanı sıra, restoranlar, eğlence merkezleri veya perakende gibi benzer müşteri analizlerinin fayda sağlayacağı diğer sektörlerle de odaklanılabilir.
- **Teknolojik Geliştirmeler:** Web tabanlı uygulamanın yapay zekâ destekli chatbot gibi yenilikçi teknolojilerle entegre edilmesi, müşteri deneyimini daha ileri bir seviyeye taşıyabilir.
- **Pandemi Dışı Dönem Verileri:** Gelecekte yapılacak çalışmalar, pandemi etkilerinden bağımsız dönemlere ait verileri analiz ederek, farklı dönemlerde müşteri davranışlarının nasıl değiştiğini inceleyebilir.

K A Y N A K Ç A

- Ahmed, M., Seraj, R., & Islam, S. M. S. (2020). The k-means algorithm: A comprehensive survey and performance evaluation. *Electronics*, 9(8), 1295.
- Ahmed, R. R., Zaidi, E. Z., Alam, S. H., Streimikiene, D., & Parmar, V. (2023). Effect of social media marketing of luxury brands on brand equity, customer equity and customer purchase intention. *Amfiteatru economic*, 25(62), 265-282.
- Akbari, M., & Moradipour, S. (2021). Horses for courses: B2B salesperson performance: the role of their characteristics and promotion efforts. *Middle East Journal of Management*, 8(4), 297-318.
- Albadvi, A., & Koosha, H. (2011). A robust optimization approach to allocation of marketing budgets. *Management Decision*, 49(4), 601-621.
- Albadvi, A., & Shahbazi, M. (2010). Integrating rating-based collaborative filtering with customer lifetime value: New product recommendation technique. *Intelligent Data Analysis*, 14(1), 143-155.
- Alizadeh Zoeram, A., & Karimi Mazidi, A. R. (2018). New approach for customer clustering by integrating the LRFM model and fuzzy inference system. *Interdisciplinary Journal of Management Studies (Formerly known as Iranian Journal of Management Studies)*, 11(2), 351-378.
- Ambler, T., & Roberts, J. H. (2008). Assessing marketing performance: don't settle for a silver metric. *Journal of Marketing Management*, 24(7-8), 733-750.
- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of informetrics*, 11(4), 959-975.
- Ascarza, E., & Hardie, B. G. (2013). A joint model of usage and churn in contractual settings. *Marketing Science*, 32(4), 570-590.
- Ashari, I. F., Nugroho, E. D., Baraku, R., Yanda, I. N., & Liwardana, R. (2023). Analysis of elbow, silhouette, Davies-Bouldin, Calinski-Harabasz, and rand-index evaluation on k-means algorithm for classifying flood-affected areas in Jakarta. *Journal of Applied Informatics and Computing*, 7(1), 95-103.
- Audzeyeva, A., Summers, B., & Schenk-Hoppé, K. R. (2012). Forecasting customer behaviour in a multi-service financial organisation: A profitability perspective. *International Journal of Forecasting*, 28(2), 507-518.

- Bansal, G., Anand, A., & Yadavalli, V. S. S. (2020). Predicting effective customer lifetime: an application of survival analysis for telecommunication industry. *Communications in Statistics-Theory and Methods*, 49(10), 2305-2320.
- Bekamiri, H., Mehraeen, M., Pooya, A., & Sharif, H. (2020). A stochastic approach for valuing customers in banking industry: a case study. *Ind. Eng. Manag. Syst*, 19, 744-757.
- Ben Rhouma, T., & Zaccour, G. (2018). Optimal marketing strategies for the acquisition and retention of service subscribers. *Management Science*, 64(6), 2609-2627.
- Berger, P. D., & Bechwati, N. N. (2001). The allocation of promotion budget to maximize customer equity. *Omega*, 29(1), 49-61.
- Berger, P. D., & Nasr, N. I. (1998). Customer lifetime value: Marketing models and applications. *Journal of interactive marketing*, 12(1), 17-30.
- Bharath, D., Singh, S. K., Smriti, S., & Arun, A. (2024). Flood Detection on Adverse Natural Conditions using CatBoost algorithm. 11, 321–327.
<https://doi.org/10.1109/iccpct61902.2024.10673168>
- Binh, T. V., Thy, N. G., & Phuong, H. T. N. (2021). Measure of clv toward market segmentation approach in the telecommunication sector (vietnam). *SAGE Open*, 11(2), 21582440211021584.
- Blattberg, R. C., Malthouse, E. C., & Neslin, S. A. (2009). Customer lifetime value: Empirical generalizations and some conceptual questions. *Journal of Interactive Marketing*, 23(2), 157-168.
- Bolton, R. N. (1998). A dynamic model of the duration of the customer's relationship with a continuous service provider: The role of satisfaction. *Marketing science*, 17(1), 45-65.
- Bradlow, E. T., Gangwar, M., Kopalle, P., & Voleti, S. (2017). The role of big data and predictive analytics in retailing. *Journal of retailing*, 93(1), 79-95.
- Braun, M., & Schweidel, D. A. (2011). Modeling customer lifetimes with multiple causes of churn. *Marketing Science*, 30(5), 881-902.
- Cai, Z., Huang, H., Sun, G., Li, Z., & Ouyang, C. (2023, December). Advancing Predictive Models: Unveiling LightGBM Machine Learning for Data Analysis. In *2023 4th International Conference on Computer, Big Data and Artificial Intelligence (ICCBD+ AI)* (pp. 109-112). IEEE.
- Cambra-Fierro, J., Gao, L. X., & Melero-Polo, I. (2021). The power of social influence and customer–firm interactions in predicting non-transactional behaviors, immediate customer profitability, and long-term customer value. *Journal of Business Research*, 125, 103-119

- Cao, J., Yu, X., & Zhang, Z. (2015). Integrating OWA and data mining for analyzing customers churn in E-commerce. *Journal of Systems Science and Complexity*, 28(2), 381-392.
- Casas-Arce, P., Martínez-Jerez, F. A., & Narayanan, V. G. (2017). The impact of forward-looking metrics on employee decision-making: The case of customer lifetime value. *The Accounting Review*, 92(3), 31-56.
- Centobelli, P., & Ndou, V. (2019). Managing customer knowledge through the use of big data analytics in tourism research. *Current Issues in Tourism*, 22(15), 1862-1882.
- Chan, C. C. H. (2008). Intelligent value-based customer segmentation method for campaign management: A case study of automobile retailer. *Expert systems with applications*, 34(4), 2754-2762.
- Chan, S. L., Ip, W. H., & Kwong, C. K. (2011). Closing the loop between design and market for new product idea screening decisions. *Expert Systems with Applications*, 38(6), 7729-7737.
- Chen, C. F., & Chen, C. T. (2014). The effect of higher education brand images on satisfaction and lifetime value from students' viewpoint. *The Anthropologist*, 17(1), 137-145.
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, X., Qu, Q., Chen, M. H., Fang, S., & Cheng, Y. (2018). The sustainable existence of China's bicycle-sharing market: to oversupply or to disappear. *Sustainability*, 10(11), 4214.
- Chiang, L. L. L., & Yang, C. S. (2018). Does country-of-origin brand personality generate retail customer lifetime value? A Big Data analytics approach. *Technological Forecasting and Social Change*, 130, 177-187.
- Choi, Y., & Choi, J. W. (2023). Assessing the Predictive Performance of Machine Learning in Direct Marketing Response. *International Journal of E-Business Research (IJEER)*, 19(1), 1-12.
- Chouaten, K., Rodriguez Rivero, C., Nack, F., & Reckers, M. (2024). Unlocking high-value football fans: unsupervised machine learning for customer segmentation and lifetime value. *Frontiers in Sports and Active Living*, 6, 1362489.
- Chung, J., Johar, G. V., Li, Y., Netzer, O., & Pearson, M. (2022). Mining consumer minds: Downstream consequences of host motivations for home-sharing platforms. *Journal of Consumer Research*, 48(5), 817-838.

- Clempner, J. B., & Poznyak, A. S. (2014). Simple computing of the customer lifetime value: A fixed local-optimal policy approach. *Journal of Systems Science and Systems Engineering*, 23, 439-459.
- Çavdar, A. B., & Ferhatosmanoğlu, N. (2018). Airline customer lifetime value estimation using data analytics supported by social network information. *Journal of Air Transport Management*, 67, 19-33.
- Dahana, W. D., Miwa, Y., & Morisada, M. (2019). Linking lifestyle to customer lifetime value: An exploratory study in an online fashion retail market. *Journal of Business Research*, 99, 319-331.
- Dandis, A. O., Al Haj Eid, M. B., Robin, R., & Wierdak, N. (2022). An empirical investigation of the factors affecting customer lifetime value. *International journal of quality & reliability management*, 39(4), 910-935.
- Dandis, A. O., Al Haj Eid, M., Griffin, D., Robin, R., & Ni, A. K. (2023). Customer lifetime value: the effect of relational benefits, brand experiences, quality, satisfaction, trust and commitment in the fast-food restaurants. *The TQM Journal*, 35(8), 2526-2546.
- De Marco, M., Fantozzi, P., Fornaro, C., Laura, L., & Miloso, A. (2021). Cognitive analytics management of the customer lifetime value: an artificial neural network approach. *Journal of Enterprise Information Management*, 34(2), 679-696.
- del Rio Olivares, M. J., Wittkowski, K., Aspara, J., Falk, T., & Mattila, P. (2018). Relational price discounts: consumers' metacognitions and nonlinear effects of initial discounts on customer retention. *Journal of Marketing*, 82(1), 115-131.
- Dong, Y., Frees, E. W., Huang, F., & Hui, F. K. (2022). Multi-state modelling of customer churn. *ASTIN Bulletin: The Journal of the IAA*, 52(3), 735-764.
- Donkers, B., Verhoef, P. C., & de Jong, M. G. (2007). Modeling CLV: A test of competing models in the insurance industry. *Quantitative Marketing and Economics*, 5, 163-190.
- Drea, J. T., Marlow, L., & Mense, L. K. (2017). Applying customer lifetime value to major league baseball season tickets. *Journal of Applied Sport Management*, 9(2), 8.
- Dursun, A., & Caber, M. (2016). Using data mining techniques for profiling profitable hotel customers: An application of RFM analysis. *Tourism management perspectives*, 18, 153-160.
- Estrella-Ramon, A. M., Sanchez-Perez, M., Swinnen, G., & VanHoof, K. (2013). A marketing view of the customer value: Customer lifetime value and customer equity. *South African Journal of Business Management*, 44(4), 47-64.

- Fader, P. S., & Hardie, B. G. (2009). Probability models for customer-base analysis. *Journal of interactive marketing*, 23(1), 61-69.
- Fader, P. S., & Hardie, B. G. (2010). Customer-base valuation in a contractual setting: The perils of ignoring heterogeneity. *Marketing Science*, 29(1), 85-93.
- Fader, P. S., Hardie, B. G., & Jerath, K. (2007). Estimating CLV using aggregated data: the Tuscan lifestyles case revisited. *Journal of Interactive Marketing*, 21(3), 55-71.
- Fader, P. S., Hardie, B. G., & Lee, K. L. (2005). RFM and CLV: Using iso-value curves for customer base analysis. *Journal of marketing research*, 42(4), 415-430.
- Fader, P. S., Hardie, B. G., & Shang, J. (2010). Customer-base analysis in a discrete-time noncontractual setting. *Marketing Science*, 29(6), 1086-1108.
- Feng, Y., Yin, Y., Wang, D., Ignatius, J., Cheng, T. C. E., Marra, M., & Guo, Y. (2024). Enhancing e-commerce customer churn management with a profit-and AUC-focused prescriptive analytics approach. *Journal of Business Research*, 184, 114872.
- Fernández del Río, A., Guitart, A., & Perianez, Á. (2021). A time series approach to player churn and conversion in videogames. *Intelligent data analysis*, 25(1), 177-203.
- Ferrentino, R., Cuomo, M. T., & Boniello, C. (2016). On the customer lifetime value: a mathematical perspective. *Computational Management Science*, 13, 521-539.
- Fornell, C., Morgeson III, F. V., & Hult, G. T. M. (2016). Stock returns on customer satisfaction do beat the market: Gauging the effect of a marketing intangible. *Journal of marketing*, 80(5), 92-107.
- Gladys, N., Baesens, B., & Croux, C. (2009). A modified Pareto/NBD approach for predicting customer lifetime value. *Expert Systems with Applications*, 36(2), 2062-2071.
- Gladys, N., Lemmens, A., & Croux, C. (2015). Unveiling the relationship between the transaction timing, spending and dropout behavior of customers. *International Journal of Research in Marketing*, 32(1), 78-93.
- Gupta, S., Hanssens, D., Hardie, B., Kahn, W., Kumar, V., Lin, N., ... & Sriram, S. (2006). Modeling customer lifetime value. *Journal of service research*, 9(2), 139-155.
- Haenlein, M., Kaplan, A. M., & Schoder, D. (2006). Valuing the real option of abandoning unprofitable customers when calculating customer lifetime value. *Journal of marketing*, 70(3), 5-20.
- Hajipour, B., & Esfahani, M. (2019). Delta model application for developing customer lifetime value. *Marketing Intelligence & Planning*, 37(3), 298-309.
- Hasheminejad, S. M. H., & Khorrami, M. (2018). Data mining techniques for analyzing bank customers: A survey. *Intelligent Decision Technologies*, 12(3), 303-321.

- Hasheminejad, S. M. H., & Khorrami, M. (2020). Clustering of bank customers based on lifetime value using data mining methods. *Intelligent Decision Technologies*, 14(4), 507-515.
- Hasumoto, K., & Goto, M. (2022). Predicting customer churn for platform businesses: using latent variables of variational autoencoder as consumers' purchasing behavior. *Neural Computing and Applications*, 34(21), 18525-18541.
- Heitz, C., Dettling, M., & Ruckstuhl, A. (2011). Modelling customer lifetime value in contractual settings. *International Journal of Services Technology and Management*, 16(2), 172-190.
- Heldt, R., Silveira, C. S., & Luce, F. B. (2021). Predicting customer value per product: From RFM to RFM/P. *Journal of Business Research*, 127, 444-453.
- Hızıroğlu, A., Sisci, M., Cebeci, H. I., & Seymen, Ö. F. (2018). An empirical assessment of customer lifetime value models within data mining.
- Hogan, J. E., Lemon, K. N., & Libai, B. (2004). Quantifying the ripple: Word-of-mouth and advertising effectiveness. *Journal of Advertising Research*, 44(3), 271-280.
- Hosseini, M., Abdolvand, N., & Harandi, S. R. (2022). Two-dimensional analysis of customer behavior in traditional and electronic banking. *Digital Business*, 2(2), 100030.
- Hosseini, Z. Z., & Mohammadzadeh, M. (2016). Knowledge discovery from patients' behavior via clustering-classification algorithms based on weighted eRFM and CLV model: An empirical study in public health care services. *Iranian journal of pharmaceutical research: IJPR*, 15(1), 355.
- Huang, M. H., & Rust, R. T. (2017). Technology-driven service strategy. *Journal of the Academy of Marketing Science*, 45(6), 906-924.
- Huang, M. H., & Rust, R. T. (2024). The caring machine: Feeling AI for customer care. *Journal of Marketing*, 00222429231224748.
- Hwang, H., Jung, T., & Suh, E. (2004). An LTV model and customer segmentation based on customer value: a case study on the wireless telecommunication industry. *Expert systems with applications*, 26(2), 181-188.
- Jabr, W., Ghoshal, A., Cheng, Y., & Pavlou, P. (2023). Maximizing online revisiting and purchasing: A clickstream-based approach to enhancing customer lifetime value. *Journal of Management Information Systems*, 40(2), 470-502.
- Jamal, Z., & Zhang, A. (2009). 2008 DMEF customer lifetime value modeling (Task 2). *Journal of Interactive Marketing*, 23(3), 279-283.

- Jamison, J., & Snow, C. (2014). An architecture for customer experience management based on the Internet of Things. *IBM Journal of Research and Development*, 58(5/6), 15-1.
- Januszewski, F. (2011). POSSIBLE APPLICATIONS OF INSTRUMENTS OF MEASUREMENT OF THE CUSTOMER VALUE IN THE OPERATIONS OF LOGISTICS COMPANIES. *LogForum*, 7(4)
- Jasek, P., Vrana, L., Sperkova, L., Smutny, Z., & Kobulsky, M. (2019). Predictive performance of customer lifetime value models in e-commerce and the use of non-financial data. *Prague Economic Papers*, 28(6), 648-669.
- Jing, X., & Lewis, M. (2011). Stockouts in online retailing. *Journal of Marketing Research*, 48(2), 342-354.
- Kanchanapoom, K., & Chongwatpol, J. (2023). Integrated customer lifetime value (CLV) and customer migration model to improve customer segmentation. *Journal of Marketing Analytics*, 11(2), 172-185.
- Kim, D., Kim, T., & Ahn, Y. (2024). Counting your mobile customers one by one: mobile transaction predictions using buy-till-you-die models. *International Journal of Mobile Communications*, 24(1), 23-45.
- Kim, K. H., Park, S. Y., Lee, S., Knight, D. K., Xu, B., Jeon, B. J., & Moon, H. I. (2010). Examining the relationships among attitude toward luxury brands, customer equity, and customer lifetime value in a Korean context. *Journal of Global Academy of Marketing*, 20(1), 27-34.
- Kim, S. Y., Jung, T. S., Suh, E. H., & Hwang, H. S. (2006). Customer segmentation and strategy development based on customer lifetime value: A case study. *Expert systems with applications*, 31(1), 101-107.
- Kim, Y. P., Boo, S., & Qu, H. (2018). Calculating tourists' customer equity and maximizing the hotel's ROI. *Tourism Management*, 69, 408-421.
- Kivrak, O., & Akar, C. (2020). Effect of social media interactions on CLV in telecommunications. *International Journal of Information Technology & Decision Making*, 19(02), 447-468.
- Kumar, S., Sahoo, S., Lim, W. M., & Dana, L. P. (2022). Religion as a social shaping force in entrepreneurship and business: Insights from a technology-empowered systematic literature review. *Technological Forecasting and Social Change*, 175, 121393.
- Kumar, V. (2008). *Managing customers for profit: Strategies to increase profits and build loyalty*. Prentice Hall Professional.

- Kumar, V. I. S. W. A. N. A. T. H. A. N., & Shah, D. (2004). Building and sustaining profitable customer loyalty for the 21st century. *Journal of retailing*, 80(4), 317-329.
- Kumar, V., & George, M. (2007). Measuring and maximizing customer equity: a critical analysis. *Journal of the Academy of Marketing Science*, 35, 157-171.
- Kumar, V., & Pansari, A. (2016). National culture, economy, and customer lifetime value: Assessing the relative impact of the drivers of customer lifetime value for a global retailer. *Journal of International Marketing*, 24(1), 1-21.
- Kumar, V., Lahiri, A., & Dogan, O. B. (2018). A strategic framework for a profitable business model in the sharing economy. *Industrial Marketing Management*, 69, 147-160.
- Kumar, V., Petersen, J. A., & Leone, R. P. (2010). Driving profitability by encouraging customer referrals: Who, when, and how. *Journal of Marketing*, 74(5), 1-17.
- Kumar, V., Pozza, I. D., Petersen, J. A., & Shah, D. (2009). Reversing the logic: The path to profitability through relationship marketing. *Journal of Interactive Marketing*, 23(2), 147-156.
- Kumar, V., Venkatesan, R., Bohling, T., & Beckmann, D. (2008). Practice Prize Report—The power of CLV: Managing customer lifetime value at IBM. *Marketing science*, 27(4), 585-599.
- Lee, S., & Yoo, S. (2012). Return on marketing investment: Pizza Hut Korea's case. *Management Decision*, 50(9), 1661-1685.
- Lemmens, A., & Gupta, S. (2020). Managing churn to maximize profits. *Marketing Science*, 39(5), 956-973.
- Li, D. C., Dai, W. L., & Tseng, W. T. (2011). A two-stage clustering method to analyze customer characteristics to build discriminative customer management: A case of textile manufacturing business. *Expert Systems with Applications*, 38(6), 7186-7191.
- Li, Q. (2010). Exploring the relationship between customer-related measures and shareholder value. *Social Behavior and Personality: an international journal*, 38(5), 647-656.
- Li, Q., & Chang, C. (2010). The customer lifetime value in Taiwanese credit card market. *African Journal of Business Management*, 4(5), 702.
- Liao, Y. W., Wang, Y. S., & Yeh, C. H. (2014). Exploring the relationship between intentional and behavioral loyalty in the context of e-tailing. *Internet Research*, 24(5), 668-686.
- Lim, W. M. (2020). Challenger marketing. *Industrial marketing management*, 84, 342-345.
- Lin, C. T., & Wu, C. S. (2008). Selecting a marketing strategy for private hotels in Taiwan using the analytic hierarchy process. *The Service Industries Journal*, 28(8), 1077-1091.

- Lin, R. H., Chuang, W. W., Chuang, C. L., & Chang, W. S. (2021). Applied big data analysis to build customer product recommendation model. *Sustainability*, 13(9), 4985.
- Liu, D. R., & Shih, Y. Y. (2005). Hybrid approaches to product recommendation based on customer lifetime value and purchase preferences. *Journal of Systems and Software*, 77(2), 181-191.
- Liu, F., Zhao, S., & Li, Y. (2017). How many, how often, and how new? A multivariate profiling of mobile app users. *Journal of Retailing and Consumer Services*, 38, 71-80.
- Lu, Z., Li, H., & Wu, J. (2024). Exploring the impact of financial literacy on predicting credit default among farmers: An analysis using a hybrid machine learning model. *Borsa Istanbul Review*, 24(2), 352-362.
- Lundberg, S. M., & Lee, S. I. (2017). Consistent feature attribution for tree ensembles. *arXiv preprint arXiv:1706.06060*.
- Ma, S., Tan, H., & Shu, F. (2015). When is the best time to reactivate your inactive customers?. *Marketing Letters*, 26, 81-98.
- Majid, S. A., Ricardianto, P., Pahala, Y., Saribanon, E., Sidjabat, S., Hernawan, M. A., ... & Suryawan, R. F. (2022). Determining Optimal Marketing based on Market Attraction and Market Based Strategies by Considering Customer Life Time Network Value. *Industrial Engineering & Management Systems*, 21(2), 401-408.
- Majumdar, A., Bakirov, R., Hodges, D., McCullagh, S., & Rees, T. (2024). A multi-season machine learning approach to examine the training load and injury relationship in professional soccer. *Journal of Sports Analytics*, 10(1), 47-65.
- Manosuthi, N., Lee, J. S., & Han, H. (2021). Causal-predictive model of customer lifetime/influence value: mediating roles of memorable experiences and customer engagement in hotels and airlines. *Journal of Travel & Tourism Marketing*, 38(5), 461-477.
- Mao, Z., Liu, T., & Li, X. (2023). Pricing mechanism of variable opaque products for dual-channel online travel agencies. *Annals of Operations Research*, 1-30.
- Marbach, J., Lages, C., Nunan, D., & Ekinci, Y. (2019). Consumer engagement in online brand communities: the moderating role of personal values. *European Journal of Marketing*, 53(9), 1671-1700.
- Marisa, F., Ahmad, S. S. S., Yusof, Z. I. M., Hunaini, F., & Aziz, T. M. A. (2019). Segmentation model of customer lifetime value in small and medium enterprise (SMEs) using K-means clustering and LRFM model. *International Journal of Integrated Engineering*, 11(3).

- Martín-Martín, A., Orduna-Malea, E., Thelwall, M., & López-Cózar, E. D. (2018). Google Scholar, Web of Science, and Scopus: A systematic comparison of citations in 252 subject categories. *Journal of informetrics*, 12(4), 1160-1177.
- Martínez, R. G., Carrasco, R. A., Sanchez-Figueroa, C., & Gavilan, D. (2021). An RFM model customizable to product catalogues and marketing criteria using fuzzy linguistic models: Case study of a retail business. *Mathematics*, 9(16), 1836.
- Matsuoka, K. (2021). A framework for variance analysis of customer equity based on a Markov chain model. *Journal of Business Research*, 129, 57-69.
- McCarthy, D. M., & Fader, P. S. (2018). Customer-based corporate valuation for publicly traded noncontractual firms. *Journal of Marketing Research*, 55(5), 617-635.
- Meire, M., Hewett, K., Ballings, M., Kumar, V., & Van den Poel, D. (2019). The role of marketer-generated content in customer engagement marketing. *Journal of Marketing*, 83(6), 21-42.
- Mirzaei, A., Baumann, C., Johnson, L. W., & Gray, D. (2016). The impact of brand health on customer equity. *Journal of Retailing and Consumer Services*, 33, 8-16.
- Mitchell, R., Adinets, A., Rao, T., & Frank, E. (2018). XGBoost: Scalable GPU Accelerated Learning. *arXiv: Learning*. <https://arxiv.org/pdf/1806.11248v1>
- Moro, S., Cortez, P., & Rita, P. (2015). Using customer lifetime value and neural networks to improve the prediction of bank deposit subscription in telemarketing campaigns. *Neural Computing and Applications*, 26, 131-139.
- Mosaddegh, A., Albadvi, A., Sepehri, M. M., & Teimourpour, B. (2021). Dynamics of customer segments: A predictor of customer lifetime value. *Expert Systems with Applications*, 172, 114606.
- Mukhopadhyay, S., Pandey, R., & Rishi, B. (2023). Electronic word of mouth (eWOM) research—a comparative bibliometric analysis and future research insight. *Journal of Hospitality and Tourism Insights*, 6(2), 404-424.
- Muldoon, J., Lee, Y., Liguori, E. W., Sahoo, S., & Kumar, S. (2024). Mapping the entrepreneurship ecosystem scholarship: current state and future directions. *International Entrepreneurship and Management Journal*, 1-46.
- Musalem, A., & Joshi, Y. V. (2009). Research note—How much should you invest in each customer relationship? A competitive strategic approach. *Marketing Science*, 28(3), 555-565.
- Nemati, Y., Mohaghar, A., Alavidoost, M. H., & Babazadeh, H. (2018). A CLV-based framework to prioritize promotion marketing strategies: a case study of telecom

- industry. *Interdisciplinary Journal of Management Studies (Formerly known as Iranian Journal of Management Studies)*, 11(3), 437-462.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... & Moher, D. (2021). *The PRISMA 2020 statement: An updated guideline for reporting systematic reviews*. *Systematic Reviews*, 10 (1), 89.
- Parracho Sant'Anna, A., & Otavio de Araujo Ribeiro, R. (2009). Statistical modeling and probabilistic composition in the prediction of the customer lifetime value. *Benchmarking: An International Journal*, 16(3), 335-350.
- Paul, J., & Benito, G. R. (2018). A review of research on outward foreign direct investment from emerging countries, including China: what do we know, how do we know and where should we be heading?. *Asia Pacific Business Review*, 24(1), 90-115.
- Paul, J., & Rosado-Serrano, A. (2019). Gradual internationalization vs born-global/international new venture models: A review and research agenda. *International Marketing Review*, 36(6), 830-858.
- Paul, J., Lim, W. M., O'Cass, A., Hao, A. W., & Bresciani, S. (2021). Scientific procedures and rationales for systematic literature reviews (SPAR-4-SLR). *International Journal of Consumer Studies*, 45(4), O1-O16.
- Paul, Justin, Sundar Parthasarathy, and Parul Gupta. "Exporting challenges of SMEs: A review and future research agenda." *Journal of world business* 52, no. 3 (2017): 327-342.
- Permana, D., Pasaribu, U. S., Indratno, S. W., & Suprayogi. (2015). The Probability of First-time and Estimation of the Customer Lifetime Value in Health Insurance Data Using Markov Chain Model. *INTERNATIONAL JOURNAL OF APPLIED MATHEMATICS & STATISTICS*, 53(3), 174-183.
- Persson, A., & Ryals, L. (2010). Customer assets and customer equity: Management and measurement issues. *Marketing Theory*, 10(4), 417-436.
- Petersen, J. A., & Kumar, V. (2009). Are product returns a necessary evil? Antecedents and consequences. *Journal of Marketing*, 73(3), 35-51.
- Prabhu, M., & Srivastava, A. K. (2023). Leadership and supply chain management: a systematic literature review. *Journal of Modelling in Management*, 18(2), 524-548.
- Punhani, A., Faujdar, N., Mishra, K. K., & Subramanian, M. (2022). Binning-based silhouette approach to find the optimal cluster using K-means. *IEEE Access*, 10, 115025-115032.
- Qiasi, R., Baqeri-Dehnavi, M., Minaei-Bidgoli, B., & Amooee, G. (2012). Developing a model for measuring customer's loyalty and value with RFM technique and clustering algorithms. *The Journal of Mathematics and Computer Science*, 4(2), 172-181.

- Randolph, J. J., Julnes, G., Bednarik, R., & Sutinen, E. (2007). A comparison of the methodological quality of articles in computer science education journals and conference proceedings. *Computer Science Education*, 17(4), 263-274.
- Ravasan, A. Z., & Mansouri, T. (2018). A fuzzy ANP based weighted RFM model for customer segmentation in auto insurance sector. In *Intelligent Systems: Concepts, Methodologies, Tools, and Applications* (pp. 1050-1067). IGI Global.
- Rice, D. B., Skidmore, B., & Cobey, K. D. (2021). Dealing with predatory journal articles captured in systematic reviews. *Systematic reviews*, 10, 1-4.
- Roemer, E. (2007). A typology of customer lifetime values in buyer–seller relationships. *Journal of Strategic Marketing*, 15(5), 441-457.
- Rust, R. T., Inman, J. J., Jia, J., & Zahorik, A. (1999). What you don't know about customer-perceived quality: The role of customer expectation distributions. *Marketing Science*, 18(1), 77-92.
- Rust, R. T., Kumar, V., & Venkatesan, R. (2011). Will the frog change into a prince? Predicting future customer profitability. *International Journal of Research in Marketing*, 28(4), 281-294.
- Ryals, L. (2008). Determining the indirect value of a customer. *Journal of Marketing Management*, 24(7-8), 847-864.
- Ryals, L. J., & Holt, S. (2007). Creating and capturing value in KAM relationships. *Journal of Strategic Marketing*, 15(5), 403-420.
- Ryals, L. J., & Knox, S. (2005). Measuring risk-adjusted customer lifetime value and its impact on relationship marketing strategies and shareholder value. *European Journal of Marketing*, 39(5/6), 456-472.
- Rykov, A., De Amorim, R. C., Makarenkov, V., & Mirkin, B. (2024). Inertia-based indices to determine the number of clusters in k-means: An experimental evaluation. *IEEE Access*.
- SAFARI, K. M., & SAFARI, K. Z. (2012). An empirical analysis to design enhanced customer lifetime value based on customer loyalty: evidences from Iranian banking sector.
- Safari, F., Safari, N., & Montazer, G. A. (2016). Customer lifetime value determination based on RFM model. *Marketing Intelligence & Planning*, 34(4), 446-461.
- Segarra-Moliner, J. R., & Moliner-Tena, M. Á. (2022). Engaging in customer citizenship behaviours to predict customer lifetime value. *Journal of Marketing Analytics*, 1-14.
- Seyedin, B., Ramazani, M., Bodaghi Khajeh Noubar, H., & Alavimatin, Y. (2021). Customer lifetime value analysis in the banking industry with an emphasis on brand equity. *International Journal of Nonlinear Analysis and Applications*, 12(2), 991-1004.

- Shih, Y. Y., & Liu, D. R. (2008). Product recommendation approaches: Collaborative filtering via customer lifetime value and customer demands. *Expert Systems with Applications*, 35(1-2), 350-360.
- Shim, B., Choi, K., & Suh, Y. (2012). CRM strategies for a small-sized online shopping mall based on association rules and sequential patterns. *Expert Systems with Applications*, 39(9), 7736-7742.
- Silveira, C. S., Oliveira, M. O. R. D., & Luce, F. B. (2017). Comparing alternative approaches to estimate customer equity. *Marketing Intelligence & Planning*, 35(5), 611-625.
- Sinaga, K. P., & Yang, M. S. (2020). Unsupervised K-means clustering algorithm. *IEEE access*, 8, 80716-80727.
- Singh, S. S., Borle, S., & Jain, D. C. (2009). A generalized framework for estimating customer lifetime value when customer lifetimes are not observed. *Qme*, 7, 181-205.
- Singh, S., & Singh, S. (2016). Accounting for risk in the traditional RFM approach. *Management Research Review*, 39(2), 215-234.
- Sood, H., & Sharma, R. P. (2021). Customer digital engagement and lifetime value: An empirical study of telecom services in India. *FIIB Business Review*, 12(4), 415-424.
- Stahl, F., Heitmann, M., Lehmann, D. R., & Neslin, S. A. (2012). The impact of brand equity on customer acquisition, retention, and profit margin. *Journal of marketing*, 76(4), 44-63.
- Stahl, H. K., Matzler, K., & Hinterhuber, H. H. (2003). Linking customer lifetime value with shareholder value. *Industrial marketing management*, 32(4), 267-279.
- Sunder, S., Kumar, V., & Zhao, Y. (2016). Measuring the lifetime value of a customer in the consumer packaged goods industry. *Journal of Marketing Research*, 53(6), 901-921.
- Szczepanek, R. (2022). Daily streamflow forecasting in mountainous catchment using XGBoost, LightGBM and CatBoost. *Hydrology*, 9(12), 226.
- Tarokh, M. J., & EsmaeiliGookeh, M. (2019). Modeling patient's value using a stochastic approach: An empirical study in the medical industry. *Computer methods and programs in biomedicine*, 176, 51-59.
- Tsai, C. F., Hu, Y. H., Hung, C. S., & Hsu, Y. F. (2013). A comparative study of hybrid machine learning techniques for customer lifetime value prediction. *Kybernetes*, 42(3), 357-370.
- Tsao, H. Y., Lin, P. C., Pitt, L., & Campbell, C. (2009). The impact of loyalty and promotion effects on retention rate. *Journal of the operational research society*, 60(5), 646-651.

- Valentini, T., Roederer, C., & Castéran, H. (2024). From redesign to revenue: measuring the effects of servicescape remodeling on customer lifetime value. *Journal of Retailing and Consumer Services*, 77, 103681.
- Van Oest, R., & Knox, G. (2011). Extending the BG/NBD: A simple model of purchases and complaints. *International Journal of Research in Marketing*, 28(1), 30-37.
- Venkatesan, R., & Kumar, V. (2004). A customer lifetime value framework for customer selection and resource allocation strategy. *Journal of marketing*, 68(4), 106-125.
- Venkatesan, R., Kumar, V., & Bohling, T. (2007). Optimal customer relationship management using Bayesian decision theory: An application for customer selection. *Journal of marketing research*, 44(4), 579-594.
- Verhoef, P. C., Franses, P. H., & Hoekstra, J. C. (2001). The impact of satisfaction and payment equity on cross-buying: A dynamic model for a multi-service provider. *Journal of retailing*, 77(3), 359-378.
- Vidal, J., Carrasco, R. A., Cobo, M. J., & Blasco, M. F. (2024). Data sources as a driver for market-oriented tourism organizations: A bibliometric perspective. *Journal of the Knowledge Economy*, 15(2), 7588-7621.
- Villanueva, J., & Hanssens, D. M. (2007). Customer equity: Measurement, management and research opportunities. *Foundations and Trends® in Marketing*, 1(1), 1-95.
- Vives, A., Jacob, M., & Payeras, M. (2018). Revenue management and price optimization techniques in the hotel sector: A critical literature review. *Tourism economics*, 24(6), 720-752.
- Walsh, G., Schaarschmidt, M., & Ivens, S. (2018). Assessing the effects of multichannel service provider corporate reputation on customer new product adoption and RFM value. *Journal of Service Management*, 29(4), 680-702.
- Wang, H. F., & Hong, W. K. (2006). Managing customer profitability in a competitive market by continuous data mining. *Industrial marketing management*, 35(6), 715-723.
- Wang, J., & Zhou, S. (2023). Particle swarm optimization-XGBoost-based modeling of radio-frequency power amplifier under different temperatures. *International Journal of Numerical Modelling-Electronic Networks Devices and Fields*.
<https://doi.org/10.1002/jnm.3168>
- Wong, T. T., & Yeh, P. Y. (2019). Reliable accuracy estimates from k-fold cross validation. *IEEE Transactions on Knowledge and Data Engineering*, 32(8), 1586-1594.

- Wu, J., Law, R., & Liu, J. (2018). Co-creating value with customers: a study of mobile hotel bookings in China. *International Journal of Contemporary Hospitality Management*, 30(4), 2056-2074.
- Wu, S. I., & Li, P. C. (2011). The relationships between CRM, RQ, and CLV based on different hotel preferences. *International Journal of Hospitality Management*, 30(2), 262-271.
- Xiao, J., Lu, J., & Li, X. (2017). Davies Bouldin Index based hierarchical initialization K-means. *Intelligent Data Analysis*, 21(6), 1327-1338.
- Xue, W., Sun, Y., Bandyopadhyay, S., & Cheng, D. (2020). Measuring customer equity in noncontractual settings using a diffusion model: An empirical study of mobile payments aggregator. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(3), 409-431.
- Yan, C., Sun, H., Liu, W., & Chen, J. (2018). An integrated method based on hesitant fuzzy theory and RFM model to insurance customers' segmentation and lifetime value determination. *Journal of Intelligent & Fuzzy Systems*, 35(1), 159-169.
- Yang, T., Feng, X., Wu, Y., Wang, S., & Xiao, J. (2018). Human dynamics in repurchase behavior based on comments mining. *Physica A: Statistical Mechanics and its Applications*, 502, 563-569.
- Yilmaz Benk, G., Badur, B., & Mardikyan, S. (2022). A new 360 framework to predict customer lifetime value for multi-category e-commerce companies using a multi-output deep neural network and explainable artificial intelligence. *Information*, 13(8), 373.
- Yoo, H., & Wilson, E. (2020). 'More than a travel companion': accompanying partners' experiences of conference attendance. *Gender and Education*, 32(1), 43-55.
- Yoseph, F., Ahamed Hassain Malim, N. H., Heikkilä, M., Brezulianu, A., Geman, O., & Paskhal Rostam, N. A. (2020). The impact of big data market segmentation using data mining and clustering techniques. *Journal of Intelligent & Fuzzy Systems*, 38(5), 6159-6173.
- Yu, H., Shi, Y., Yu, Y., Liu, J., Yang, F., & Wu, J. (2020). Business analytics: online promotion with gift rewards. *Annals of Operations Research*, 291, 1061-1076.
- Zhang, H., Liang, X., & Wang, S. (2016). Customer value anticipation, product innovativeness, and customer lifetime value: The moderating role of advertising strategy. *Journal of Business Research*, 69(9), 3725-3730.
- Zhang, J. Q., Dixit, A., & Friedmann, R. (2010). Customer loyalty and lifetime value: An empirical investigation of consumer packaged goods. *Journal of marketing theory and practice*, 18(2), 127-140.

- Zhang, Y., Bradlow, E. T., & Small, D. S. (2015). Predicting customer value using clumpiness: From RFM to RFMC. *Marketing science*, 34(2), 195-208.
- Zhou, Z., Zhang, L., & Van Alstyne, M. W. (2020). How users drive value in two-sided markets: platform designs that matter. *Available at SSRN 3625355*.



ÖZGEÇMİŞ

Adı ve SOYADI	Leyla ATABAY
EĞİTİM DURUMU	
Lise	Antalya Atatürk Anadolu Lisesi
Lisans	Nevşehir Hacı Beltaş Veli Üniversitesi, İBBF, Turizm İşletmeciliği ve Otelcilik (2008-2012)
Yüksek Lisans	Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Turizm İşletmeciliği (2017-2020)
Tez Konusu	Otel Yorumlarının Metin Madenciliği Yöntemleri İle Karşılaştırmalı Analizi: Mayorka, Antalya, Şarm-El Şeyh Örneği
Doktora	Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Turizm İşletmeciliği (2020-2025)
Tez Konusu	Otel İşletmelerinde Müşteri Yaşam Boyu Değeri Tahmini Ve Yönetimi: Web Tabanlı Bir Uygulama İle Entegre Yaklaşım
Yabancı Dil / Diller	İngilizce
MESLEKİ DENEYİM	
Doktora Sanayi İş Birliği Projesi	Tübitak 2244 / Bursiyer / Antalya / 2021-2025
Çalıştığı Kurumlar	Hotel Su / Resepsiyonist / Antalya / 2018 – 2019 Oti Holding / Price Analyst / Antalya / 2016 – 2017 Puding Marina / Resepsiyonist / Antalya / 2012 – 2015 Hilton / Resepsiyonist / Kayseri / 2011 – 2011
Stajlar	Pegas Kiriş Resort / Kiriş / Antalya / 2010 Wow Topkapı Palace / Kundu / Antalya / 2009
YAYINLAR	
Makaleler	

Görür, H., Atabay, L., & Güzeller, C. O. (2021). Analysing food image branding of turkey from instagram social media platform. *Journal of Tourism & Gastronomy Studies*, 9(1), 24-46.

Atabay, L., & Çizel, B. (2020). Comparative content analysis of hotel reviews by mass tourism destination. *Journal of Tourism and Services*, 11(21), 147-166.

Bildiriler

Atabay, E., Atabay, L., & Çizel, B. (2019). *Kullanıcı Tarafından Oluşturulan İçeriğin Veri Madenciliği Yöntemleri ile Analizi*, Tam Metin Bildiri, 20. Ulusal Turizm Kongresi, 16 Ekim 2019, 19 Ekim 2019.