

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

KÜMELEME YÖNTEMLERİ İLE MÜŞTERİ KANAL GÖÇÜ ANALİZİ

YÜKSEK LİSANS TEZİ

Gizem ÇALIŞKAN

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

HAZİRAN 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

KÜMELEME YÖNTEMLERİ İLE MÜŞTERİ KANAL GÖÇÜ ANALİZİ

YÜKSEK LİSANS TEZİ

**Gizem ÇALIŞKAN
(507201133)**

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Tez Danışmanı: Dr.Öğr.Üyesi Mehmet Yasin ULUKUŞ

HAZİRAN 2023

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**CUSTOMER CHANNEL MIGRATION ANALYSIS
WITH CLUSTERING METHODS**

M.Sc. THESIS

**Gizem ÇALIŞKAN
(507201133)**

Department of Industrial Engineering

Industrial Engineering Programme

Thesis Advisor: Asst. Prof. Mehmet Yasin ULUKUŞ

JUNE 2023

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 507201133 numaralı Yüksek Lisans Öğrencisi Gizem ÇALIŞKAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “KÜMELEME YÖNTEMLERİ İLE MÜŞTERİ KANAL GÖÇÜ ANALİZİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr.Öğr.Üyesi Mehmet Yasin ULUKUŞ**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Dr. Öğr. Üyesi Ömer Faruk BEYCA**
İstanbul Teknik Üniversitesi

Doç. Dr. Hatice Tekiner MOĞULKOÇ
Marmara Üniversitesi

Teslim Tarihi : 24 Mayıs 2023
Savunma Tarihi : 5 Haziran 2023





Aileme ve Eşime,



ÖNSÖZ

Bu tez çalışmasında gıda perakende sektöründeki müşterilerin hem fiziksel mağaza hem de çevrimiçi kanaldaki alışveriş davranışları incelenerek, müşteri kanal göçü konusunda makine öğrenmesi ve derin öğrenme modelleri kullanılarak müşterilerin davranışlarını öngörebilecek kümeler oluşturulmuştur.

Öncelikle şirketim Migros Ticaret A.Ş. Ar-Ge Merkezi'ne yaptığım çalışmadaki her türlü destekleri için teşekkürlerimi sunarım. Tüm bu süreçte beni yalnız bırakmayan ve her türlü cesareti veren Dr. Ayşegül ÖZKAVUKCU'ya, hep yanımda olup bana güç veren sevgili eşim Nurullah ÇALIŞKAN'a, eğitim hayatım boyunca her zaman yanımda olup, desteklerini her zaman hissettiren aileme teşekkürlerimi sunarım.

Haziran 2023

Gizem ÇALIŞKAN
Endüstri Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxii
1. GİRİŞ.....	1
1.1 Müşteri Segmentasyonu	3
1.2 Tezin Amacı	3
2. LİTERATÜR TARAMASI	5
3. VERİ ANALİZİ VE MODELLER.....	19
3.1 Kavramlar, Değişkenler ve Ölçekleri	19
3.1.1 Ham veri.....	19
3.1.2 Ham veriden değişken oluşturma.....	20
3.2 Tanımlayıcı İstatistiksel Analizler	22
3.2.1 Müşteri örüntüleri, alışveriş sayıları, cinsiyet ve doğum yılı.....	22
3.2.2 Ürün kategorisi ve alışveriş yapılan il verileri	25
3.2.3 Verinin son durumu	26
3.2.4 Temel bileşen analizi (PCA).....	29
3.2.4.1 Temel bileşen analizi sonuçları.....	30
3.3 Kümeleme Modelleri ve Küme Sayısının Tespiti	31
3.3.1 Küme sayısının tespiti.....	32
3.3.1.1 Elbow metodu	32
3.3.1.2 Silhoutte skor	33
3.3.2 K-Ortalama algoritması.....	33
3.3.2.1 K-Ortalama algoritma sonuçları.....	34
3.3.3 Yoğunluk tabanlı kümeleme algoritması (DBSCAN)	36
3.3.3.1 DBSCAN algoritma sonuçları	37
3.3.4 Birleştirici hiyerarjik kümeleme algoritması (Agglomerative).....	38
3.3.4.1 Birleştirici hiyerarjik kümeleme algoritma sonuçları	39
3.3.5 Autoencoder tabanlı Self-organizing map derin öğrenme modeli	41
3.3.5.1 Autoencoder tabanlı Self-organizing map (SOM- kendi kendini organize eden özellik haritası) derin öğrenme modeli ve sonuçları.....	43
4. BULGULAR VE DEĞERLENDİRME	47
4.1 K-Ortalama Değerlendirme.....	49
4.2 DBSCAN Algoritması Değerlendirme.....	53
4.3 Birleştirici Hiyerarjik Kümeleme Algoritması Değerlendirme.....	55
4.4 Autoencoder Tabanlı Self-organizing Map Modeli Değerlendirme	57

5. SONUÇ VE ÖNERİLER.....	59
KAYNAKLAR.....	61
EKLER.....	67
ÖZGEÇMİŞ.....	73



KISALTMALAR

KNN	: K-Nearest Neighbors
NGN	: Next Generation Networks
CLV	: Customer Lifetime Value
B2B	: Business-to-Business
SQL	: Structured Query Language
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
DBSCAN	: Density Based Spatial Clustering of Applications with Noise (Yoğunluk Tabanlı Kümeleme Algoritması)
WCSS	: Within Clusters Sum of Square
SOM	: Self-organizing Map
MSE	: Mean Squared Error
ANOVA	: Analysis of Variance



SEMBOLLER

$a(i)$	: i Kümesi için Benzerlik
$b(i)$	: i Kümesi için Uzaklık
$s(i)$	: i Kümesinin Silhouette Skoru
k	: Küme Sayısı





ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Literatür taraması.	10
Çizelge 3.1 : Müşteri verileri.	20
Çizelge 3.2 : Mağaza bilgileri.	20
Çizelge 3.3 : Müşteri alışveriş geçmişi.	20
Çizelge 3.4 : Alışveriş sayılarından çıkartılan yeni değişkenler.	21
Çizelge 3.5 : Kategori ve il bazında ABC analizi sonuçları.	26
Çizelge 3.6 : Küme ve varyansa göre modellerin silhoutte skoru.	35
Çizelge 3.7 : Yoğunluk tabanlı kümeleme algoritması sonuçları.	37
Çizelge 3.8 : %80 varyans için sonuçlar.	39
Çizelge 3.9 : %85 varyans için sonuçlar.	40
Çizelge 3.10 : %90 varyans için sonuçlar.	40
Çizelge 3.11 : %95 varyans için sonuçlar.	40
Çizelge 4.1 : Değişken bazında küme merkezleri.	50
Çizelge 4.2 : Küme bazında minimum uzaklık ortalamaları.	51
Çizelge 4.3 : Cinsiyet bazında SOM kümeleri.	58



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Hanelerde internet erişimi ve bireylerde internet kullanımı (<i>Hanehalkı Bilişim Teknolojileri (BT) Kullanım Araştırması</i> , 2022).	1
Şekil 2.1 : İncelenen yayınların yıllara göre dağılımı.	5
Şekil 2.2 : İncelenen yayınların sektörlere göre dağılımı.	6
Şekil 2.3 : İncelenen yayınların konulara göre dağılımı.	7
Şekil 3.1 : Çeyrek Dilimi	21
Şekil 3.2 : Müşteri örüntüleri.	22
Şekil 3.3 : Yıllara göre müşteri alışveriş sayılarının dağılımı.	23
Şekil 3.4 : Dışa düşen noktaların çıkarılması ile alışveriş sayıları.	24
Şekil 3.5 : Örüntülere göre doğum yılının dağılımı.	24
Şekil 3.6 : Düzenlemeler sonucu örüntülere göre doğum yılının dağılımı.	25
Şekil 3.7 : Cinsiyet bazında örüntüler arası değişim.	25
Şekil 3.8 : Veri temizleme sonucu örüntüde son durum.	27
Şekil 3.9 : Toplam alışveriş sayısının yıllara göre dağılımı.	27
Şekil 3.10 : Sanal alışveriş sayısının yıllara göre dağılımı.	28
Şekil 3.11 : Bölgelere göre ortalama alışveriş sayısı.	28
Şekil 3.12 : Formata göre ortalama alışveriş sayısı.	28
Şekil 3.13 : Temel bileşen analizi sonucundaki varyanslar.	30
Şekil 3.14 : Kümülatif varyans değerlerine göre kullanılacak değişken sayısı.	31
Şekil 3.15 : Elbow metot sonucu.	35
Şekil 3.16 : K-Ortalama ve müşteri örüntü karşılaştırması	36
Şekil 3.17 : Algoritma sonucuna göre müşteri örüntüleri.	38
Şekil 3.18 : Algoritma sonucuna göre müşteri örüntüleri.	41
Şekil 3.19 : Algoritma sonucuna göre müşteri örüntüleri.	44
Şekil 3.20 : Batchsize parametresine göre MSE değeri değişimi.	45
Şekil 3.21 : Epoch parametresine göre MSE değeri değişimi.	45
Şekil 3.22 : Learning rate parametresine göre MSE değeri değişimi.	46
Şekil 4.1 : Değişken bazında k-ortalama küme sonuçları.	50
Şekil 4.2 : Bir ve ikinci değişken bazında kümeler.	51
Şekil 4.3 : Altı ve yedinci değişkenler bazında kümeler.	52
Şekil 4.4 : Cinsiyet bazında kümeler.	52
Şekil 4.5 : Doğum yılı bazında kümeler	53
Şekil 4.6 : Değişken bazında DBSCAN küme sonuçları.	54
Şekil 4.7 : Doğum yılına göre DBSCAN kümeleri.	55
Şekil 4.8 : Cinsiyet bazında DBSCAN kümeleri.	55
Şekil 4.9 : Değişken bazında birleştirici hiyerarjik küme sonuçları.	56
Şekil 4.10 : Cinsiyet bazında hiyerarjik küme sonuçları.	57
Şekil 4.11 : Doğum yılı bazında hiyerarjik küme sonuçları.	57



KÜMELEME YÖNTEMLERİ İLE MÜŞTERİ KANAL GÖÇÜ ANALİZİ

ÖZET

Bugünün müşterileri, alışveriş yapmak için çeşitli kanallardan faydalanma imkanına sahiptir. Örneğin, fiziksel mağazalardan alışveriş yapabilirler ya da e-ticaret siteleri ve mobil uygulamalar aracılığıyla alışverişlerini gerçekleştirebilirler. Bu geniş kanal seçenekleri, müşteri davranışlarına ve tercihlerine göre şekillenmektedir. Aynı zamanda, müşteriler tüm bu kanallar arasında sorunsuz bir deneyim beklemektedir. Bu durum, şirketlere birçok fırsat ve zorluk sunmaktadır.

Müşteri kanal göçü, müşterilerin farklı kanallar arasında hareket etme eğilimini ifade eder. Bu kanallar, fiziksel mağazalar, e-ticaret platformları, mobil uygulamalar gibi örneklerle temsil edilebilir. Müşteri kanal göçü, farklı sebeplerle gerçekleşebilir. Bu sebepler arasında kolay erişilebilirlik, daha uygun fiyatlar veya çekici teklifler bulunabilir. Önemli bir faktör ise, müşterilerin bir kanaldan olumsuz deneyim yaşaması durumunda başka bir kanala geçiş yapma eğiliminde olmalarıdır.

Bugün birçok işletme, ürün ve hizmetlerini müşterilere farklı kanallar aracılığıyla sunarak çeşitli kanalları kullanmaktadır, yani çevrimiçi platformlar, fiziksel mağazalar, mobil uygulamalar ve çağrı merkezleri gibi. Ancak, müşterilerin kanal tercihleri değişebilmekte ve bu da işletmelerin müşteri kanal göçüyle karşılaşmalarına neden olmaktadır. Bu durum, işletmelerin müşteri davranışlarını anlamalarını ve uygun pazarlama stratejileri geliştirmelerini gerektirir. Bu noktada müşteri segmentasyonu devreye girer. İşletmeler, müşterilerini farklı özelliklere göre gruplandırarak her bir gruba farklı pazarlama stratejileri uygular. Örneğin, bir işletme genç müşterilere yönelik sosyal medya pazarlaması yaparken, orta yaşlı müşterilere yönelik mağaza kampanyaları düzenlemek gibi.

Bu çalışma, perakende sektöründe müşteri kanal göçü olarak adlandırılan önemli bir sorunu ele almaktadır. Bu sorun, müşterilerin fiziksel mağaza ile online kanal arasında geçiş yapması veya tam tersi durumda yaşanmaktadır. Bu durum, perakende şirketlerinin müşteri sadakati konusunda zorluklar yaşamasına neden olmaktadır. Çalışma, müşterilerin hem fiziksel mağaza hem de çevrimiçi kanaldaki davranışlarının incelenmesi ve müşteri kanal göçü konusunun detaylı bir şekilde analiz edilmesi üzerine odaklanmaktadır. Ayrıca, müşteri davranışları yıllara göre analiz edilmiş ve çeşitli örüntüler belirlenmiştir. Müşteriler, klasik kümeleme yöntemleri ve derin öğrenme yöntemleri kullanılarak gruplandırılmış ve sonuçlar ayrıntılı bir şekilde incelenmiştir. Bu şekilde, müşterilerin davranışları hakkında daha kapsamlı bir anlayış elde edilmiştir. Ayrıca, müşteri alışveriş örüntüleri birleştirilerek, perakende şirketinin stratejik kararlar almasına yardımcı olmak amaçlanmıştır. Sonuç olarak, bu çalışma perakende sektöründeki önemli bir soruna odaklanarak müşteri kanal göçü konusunu ayrıntılı bir şekilde analiz etmiştir.

Çalışmada ilk olarak veri analizi çalışmaları yapılmıştır ve dışa düşen noktalar çıkartılarak veri temizlenmiştir. Müşterilerin çevrimiçi kanaldan yaptığı alışverişler analiz edilerek müşterilerin yıl yıl örüntüleri çıkartılmıştır. Bulunan 4 örüntü için, ilk

örüntüde, müşterilerin alışveriş oranlarının sürekli olarak arttığı gözlemlenmektedir. Bu, istenilen bir senaryo olarak değerlendirilebilir ve müşterilerin başka bir kanala geçtiği düşünülebilir. Bu tür müşterilerin oranı %4'tür ve uzun vadede artması hedeflenmektedir. İkinci örüntüde, 2021 yılında diğer yıllara göre daha fazla alışveriş yapan müşterilerin oranının %30 olduğu görülmektedir. Bu, pandemi etkisinden bağımsız olarak 2019 ve 2021 yıllarında müşterilerin daha fazla alışveriş yaptığını göstermektedir. Ancak, 2022 yılında alışveriş sayısı düşmüştür. Bu müşteriler, birinci grafikteki müşterilerden farklı olarak firma tarafından ihmal edilmiş ve kaçırılmış olabilir. Üçüncü örüntüde, belirli bir dönemde alışverişini azaltıp daha sonra tekrar sanal kanala dönen müşterilerin oranı %26'dır. 2020 yılındaki alışveriş miktarının pandemi etkisiyle arttığını göstermektedir. 2021 yılında alışveriş sayısı düşse de 2022 yılında yeniden arttığı görülmektedir. Bu tür müşterilerin kanal göçü kesin olmasa da dengeli olmadığı gözlemlenmektedir. Dördüncü örüntüde, alışveriş sayısı giderek azalan müşterilerin oranı %38'dir. Bu müşteriler, pandemi etkisiyle 2020 yılında diğer yıllara göre daha fazla alışveriş yapmıştır. Ancak, zamanla alışveriş sayıları düşmüştür. Bu tür müşterilerin başka bir kanala geçtiği veya geçeceği söylenebilir. Bu tür müşterilerin elde tutulması için ayrı bir strateji gerekmektedir.

Bu adımlardan sonra 4 adet kümeleme modeli öncesinde Temel Bileşen Analizi uygulanarak sonuçları analiz edilmiştir. K-Ortalama, Yoğunluk Tabanlı Kümeleme ve Birleştirici Hiyerarşik Kümeleme algoritmaları için tüm parametreler ile silhouette skor da hesaplanarak analizler yapılmıştır. 3 algoritmanın SPSS üzerinde yapılan istatistiksel analizlerine tabi tutulmuştur. ANOVA testi, varyans, skor ve küme sayısı için uygulanmıştır. ANOVA sonuçları, yöntem ve küme sayısı kombinasyonunda anlamlı bir fark olduğunu göstermiştir ($p=0.044$). Post Hoc testi sonuçlarına göre Yoğunluk Tabanlı Kümeleme ve Birleştirici Hiyerarşik Kümeleme algoritmaları arasında ($p=0.016$), ayrıca K-Ortalama ve Yoğunluk Tabanlı Kümeleme arasında ($p=0.039$) farklılıklar olduğu belirlenmiştir. Temel bileşen analizi sonuçlarına göre ise 4 farklı varyans şeklinde oluşturulan veride istatistiksel olarak anlamlı bir fark saptanmamıştır.

K-ortalama algoritmasında, erkek müşteriler küme 1 ve 2'de, kadın müşteriler ise küme 3 ve 4'te yoğunur. Genellikle İstanbul'dan alışveriş yapılmaktadır ve doğum yılları benzerdir. Alışveriş formatları incelendiğinde, küme 1 büyük formatlı mağazalardan, küme 2 ve 3 her türden, küme 4 ise küçük formatlı mağazalardan daha çok alışveriş yapmaktadır.

DBSCAN algoritması değerlendirildiğinde, oluşturulan kümelerde ilk kümede hem kadın hem de erkek müşteriler bulunurken, ikinci kümede sadece erkek ve üçüncü kümede ise sadece kadın müşteriler bulunmaktadır. Tüm kümelerde genellikle İstanbul ilinden alışveriş yapıldığı görülmektedir. Doğum yılları incelendiğinde, ilk küme daha yaşlıken diğer kümeler daha genç kesime hitap etmektedir. Alışveriş yapılan mağaza formatı bazında herhangi bir fark tespit edilmemiştir, tüm kümeler benzer oranda dağılmıştır.

Birleştirici hiyerarşik kümeleme algoritması sonuçları incelendiğinde, cinsiyet bazında ilk küme erkek müşterilerden oluşurken, ikinci küme kadın müşterilerden oluşmaktadır. Doğum yılı bazında ise her iki kümede de her doğum yılından müşteri bulunuyor gibi görünmektedir. Alışveriş yapılan formatlarda da belirgin bir bölünme gözlenmemiştir.

Son olarak Autoencoder tabanlı Self-organizing map kullanılarak derin öğrenme algoritması uygulanmıştır. Batchsize parametresi düşük tutulmalıdır, çünkü arttıkça

kayıp da artmaktadır. Epoch parametresi arttıkça MSE değeri düşmektedir. 100 ve sonrası arasında önemli bir fark yoktur, bu nedenle 100 kullanılabilir. Learning rate parametresinde büyük bir fark gözlenmemiştir, herhangi bir değer kullanılabilir. Daha ayrıntılı bir model isteniyorsa, Autoencoder tabanlı Self-organizing map kullanmak faydalı olabilir. Örneğin, 70 küme çıkaran parametrelerle stratejiler oluşturulabilir. En çok müşteriye sahip olan 3 kümeye odaklanılarak ayrıntılı analizler yapılmıştır.

Gıda perakende sektöründe müşterileri bir kanala yönlendirmek veya elde tutmak için kampanyalar yaygın olarak kullanılır. Özellikle genç ve erkek müşterilerin yoğun olduğu 3. küme, sepet bazlı kampanyalarla kanal göçünü teşvik etmek için idealdir. 1. küme için, mağazada fiziksel olarak iletişim kurmak daha uygundur. Örneğin, alışveriş sırasında kasiyer tarafından çevrimiçi kanalın avantajları anlatılarak, fişin altında bir kampanya koduyla müşteri sanal kanala çekilebilir. Küme 2 için ise, özellikle deterjan, tuvalet kağıdı, yağ gibi temel ihtiyaç ürünlerinde yapılan ürün bazlı indirimler kanal göçünü teşvik edecektir.

Tüm denenen kümeleme algoritmaları arasında sonuçlar incelendiğinde veriyi doğru kümelemediği görülmektedir. Bu nedenle, k-ortalama algoritması tercih edilmiştir. Belirlenen 4 örüntü ve kümeleme yöntemi sayesinde, benzer müşterilerin alışveriş örüntüleri öngörülerek stratejik kararlar verilebilir. Alışveriş sayısı sürekli artan müşteriler için agresif kampanyalar uygulanabilir ve tüm kanallardan bilgilendirme ve reklam yapılabilir. Bu müşterilerin çevrimiçi kanala yönlendirilmesi önemlidir. Autoencoder tabanlı Self-organizing map modeli ile 70 farklı küme ile müşterilere daha nokta atışı bir strateji geliştirilmesinde faydalı olacağı düşünülmektedir. Bu konuda 3 küme incelenerek sektörel tecrübe ile değerlendirilerek kampanya stratejisi önerilmiştir.

Bu çalışmada, müşteri kanal göçü konusunda Autoencoder tabanlı Self-organizing map derin öğrenme modelinin kullanılması literatürde bir yenilik olarak yansımıştır. Ayrıca, Birleştirici Hiyerarjik Kümeleme Algoritması'nın müşteri kanal göçü konusunda kullanılmamış bir yöntem olduğu belirtilerek literatüre katkı sağlamıştır. Gelecekte yapılacak çalışmalarda, derin öğrenme yöntemlerinin müşteri kanal göçü konusunda üretilen sonuçlarla literatüre katkı sağlayabileceği düşünülmektedir. Bu yeni yöntemlerin farklı alanlarda kullanılması, çeşitliliği ve doğruluğu artıracaktır. Ek olarak, Türkiye'deki gıda perakendeciliğinde, e-ticaret kanalında müşterilerin bir sipariş daha vermesini teşvik etmek için promosyonlar kullanma odak noktasıdır. Ancak, müşteri kanal göçüyle hedeflenen organik büyümeyi sağlayacak çalışmalar oldukça nadirdir. Bu nedenle, her iki kanala da sahip olan firmaların nokta atışı tespitlerle müşterilerin kanal göçünü yönlendirmeleri, firmalar açısından yenilik sağlayacaktır.

Migros Ticaret A.Ş., kendi fiziksel mağazalarından alışveriş yapan müşterilerin online kanaldaki en büyük potansiyeli olduğunu gözlemleyerek müşteri göçü üzerine çalışmalar yürütmektedir. Bu çalışma, Migros AR-GE merkezinde bir Ar-Ge projesi olarak gerçekleştirilmiş ve ayrıca 41. Yöneylem Araştırması Endüstri Mühendisliği Kongresi'nde "Literature Review on Customer Channel Migration and Forecasting in Retail Sector" başlıklı sunum ile Denizli'de katılım sağlanmıştır.

CUSTOMER CHANNEL MIGRATION ANALYSIS WITH CLUSTERING METHODS

SUMMARY

Today's customers have the opportunity to shop through various channels like physical stores, mobile applications and also e-commerce websites. These wide channel options are shaped based on customer behaviors and preferences. Customers expect a seamless experience across all these channels. This situation presents both opportunities and challenges for companies.

Customer channel migration denotes the propensity of customers to shift between various channels. These channels can be represented by examples such as physical stores, e-commerce platforms, and mobile applications. Customer channel migration can occur for various reasons, including accessibility, better prices, or attractive offers. An important factor is that customers tend to switch to another channel if they have a negative experience with one channel.

Today, a wide range of businesses employ diverse channels, such as online platforms, brick-and-mortar stores, mobile applications, and call centers, to provide their products and services to customers. However, customers' channel preferences can change, leading businesses to face customer channel migration. This situation requires businesses to understand customer behaviors and develop appropriate marketing strategies. This is where customer segmentation comes into play. Businesses group their customers based on different characteristics and apply different marketing strategies to each group. For example, a company may engage in social media marketing targeted at young customers while organizing store campaigns for middle-aged customers.

This study addresses an important issue in the retail sector, which is customer channel migration. This problem occurs when customers switch between physical stores and online channels or vice versa, posing challenges to retail companies' customer loyalty efforts. The study focuses on analyzing the behaviors of customers in both physical store and online channels and thoroughly examining the subject of customer channel migration. Furthermore, customer behaviors are analyzed year by year, and various patterns are identified. Customers are clustered using both traditional clustering methods and deep learning techniques, and the results are extensively analyzed. By combining customer shopping patterns, the study aims to assist retail companies in making strategic decisions. In conclusion, this study analyzes the issue of customer channel migration in detail, focusing on an important problem in the retail sector.

In the study, data analysis was conducted, and outliers were removed to clean the data. Customer shopping patterns in the online channel were analyzed, and patterns for each year were identified. For the identified four patterns It was noted that the shopping rates of customers continuously increased in the first pattern. This can be considered as a desirable scenario, indicating that customers may switch to another channel. The percentage of these customers accounts for 4% and is anticipated to grow over time.

In the second pattern, it was observed that the proportion of customers who made more purchases in 2021 compared to other years was 30%. This indicates that customers made more purchases in 2019 and 2021 regardless of the pandemic effect. However, the number of purchases decreased in 2022. These customers may have been neglected or missed by the company compared to the customers in the first graph.

In the third pattern, the proportion of customers who reduced their shopping in a certain period and then returned to the online channel was 26%. It demonstrates that the amount of shopping increased in 2020 due to the pandemic effect. Although the number of purchases decreased in 2021, it increased again in 2022. The channel migration of such customers may not be definitive but rather balanced.

In the fourth pattern, the proportion of customers with a decreasing number of purchases over time is 38%. These customers made more purchases in 2020 due to the pandemic effect. However, over time, the number of purchases decreased. It can be said that these customers may have switched to another channel. Retaining such customers requires a separate strategy.

After these steps, four clustering models were applied, and the results were analyzed. Before that, Principal Component Analysis applied the data. Then, K-Means, Density-Based Clustering, and Agglomerative Hierarchical Clustering algorithms were evaluated by calculating the silhouette score for all parameters. The statistical analysis of the three algorithms was conducted using ANOVA tests for variance, score, and cluster number. The ANOVA findings revealed a significant difference in the combination of method and cluster number ($p=0.044$). Based on the outcomes of the post hoc test, there were differences between Density-Based Clustering and Agglomerative Hierarchical Clustering algorithms ($p=0.016$), as well as between K-Means and Density-Based Clustering ($p=0.039$). However, based on the results of principal component analysis, There was no statistically significant difference identified among the four distinct variance patterns observed in the data.

In the K-Means algorithm, male customers were predominantly found in clusters 1 and 2, while female customers were predominant in cluster 3 and 4. Shopping mostly took place in Istanbul, and the birth years were similar across clusters. No significant division was observed in terms of shopping formats, as all clusters had a similar distribution.

When evaluating the DBSCAN algorithm, the first cluster included both male and female customers, the second cluster consisted only of male customers, and the third cluster consisted only of female customers. It was observed that shopping mostly occurred in Istanbul in all clusters. In terms of birth years, the first cluster had an older customer base compared to the other clusters, which catered to a younger demographic. No significant difference was detected based on shopping formats, as all clusters were evenly distributed.

The results of the Agglomerative Hierarchical Clustering algorithm showed that the first cluster comprised of male customers, while the second cluster consisted of female customers. In terms of birth years, both clusters had customers from all birth years. No distinct division was observed in terms of shopping formats.

Lastly, a deep learning algorithm using the Autoencoder-based Self-organizing map was applied. The batch size parameter should be kept low because increasing it leads to an increase in loss. As for the epoch parameter, as it increases, the mean squared error (MSE) value decreases. There is no significant difference between 100 and

higher values, so 100 can be used. No significant difference was observed in the learning rate parameter, so any value can be used. If a more detailed model is desired, using the Autoencoder-based Self-organizing map can be beneficial. For example, by using parameters that generate 70 clusters, strategies can be developed for these 70 clusters. In-depth analyses were performed specifically targeting the top three clusters characterized by the highest customer count, and the findings will be presented in subsequent sections.

7In the food retail sector, campaigns are commonly used to direct and retain customers in a specific channel. The 3rd cluster, which is particularly composed of young and male customers, appears to be ideal for promoting channel migration through basket-based campaigns. For the 1st cluster, it is more appropriate to communicate with these customers physically in-store. For instance, during the checkout process, customers can be encouraged to migrate to the online channel by explaining the advantages of the online channel and providing a campaign code under the receipt. For the 2nd cluster, product-specific discounts, especially on essential items such as detergents, toilet paper, and oil, will incentivize channel migration.

By utilizing the K-Means, Density-Based Clustering, and Agglomerative Hierarchical Clustering algorithms, customers were classified and the K-Means method with 4 clusters was found to be more suitable. Through the identified 4 patterns and clustering method, strategic decisions can be made by predicting the shopping patterns of similar customers. Aggressive campaigns can be implemented for customers with a continuous increase in shopping frequency, and customers in this segment can be targeted. Additionally, informative and advertising efforts should be carried out through all channels, such as SMS, social media, and emails. It is crucial to attract these customers to the online channel.

This study addresses the important problem of customer channel migration in the retail sector. By examining customer behaviors in both brick-and-mortar stores and online channels, and conducting a thorough analysis of customer channel migration, this study offers valuable insights into this phenomenon. Furthermore, customer behaviors were analyzed over the years, and various patterns were identified. Customers were clustered using both traditional clustering methods and deep learning techniques, enabling a comprehensive understanding of customer behaviors. Moreover, by combining customer shopping patterns, the study aimed to assist retail companies in making strategic decisions. In conclusion, this study thoroughly analyzes the issue of customer channel migration, focusing on an important problem in the retail sector.

The study also highlights the novelty of using the Autoencoder-based Self-organizing map deep learning model for customer channel migration, contributing to the existing literature. Additionally, the study makes a novel contribution to the literature by exploring the utilization of the Agglomerative Hierarchical Clustering Algorithm, which has not been extensively employed in the analysis of customer channel migration.

Future studies are expected to further contribute to the literature on customer channel migration by utilizing deep learning methods and generating valuable insights. The application of these new methods in various fields will enhance diversity and accuracy. Additionally, in the food retail industry in Turkey, the focus is on using promotions to encourage customers to place additional orders through the e-commerce channel. However, studies that effectively utilize customer channel migration for targeted

organic growth are rare. Therefore, for companies operating in both channels, strategic interventions to direct customer channel migration will provide innovative solutions.


Migros Ticaret A.Ş. has recognized that their customers who primarily shop at their physical stores hold the greatest potential for the online channel. Consequently, they have conducted research on customer migration and implemented an R&D project at the Migros R&D center. Furthermore, they presented a study titled "Literature Review on Customer Channel Migration and Forecasting in the Retail Sector" at the 41st Operations Research Industrial Engineering Congress, which took place from October 16th to 28th, 2022, in Denizli, Turkey.



1. GİRİŞ

Günümüzde müşteriler, alışveriş yapmak amacı ile çok fazla kanal kullanabilmektedir. Örnek vermek gerekirse müşteriler, fiziksel mağazalardan alışveriş yapabilir, e-ticaret sayfaları aracılığı ile veya mobil uygulamalar üzerinden alışveriş yapabilmektedir. Bu geniş yelpazede seçim yapmak, müşterilerin davranışlarına ve yönelimlerine göre şekillenmektedir. Aynı zamanda, müşteriler, tüm bu kanallar arasında sorunsuz bir deneyim beklemektedir. Bu durum özellikle firmalara birçok fırsat ve zorluk yaratmaktadır (Li vd., 2017).

Müşterilerin e-ticaret kanallarını kullanım oranı giderek artmakta ve firmaların bu duruma göre konumlanması önemli hale gelmektedir. TÜİK verilerine göre, 2022 yılında internet kullanan bireylerin oranı %85'e yükselmiştir (Şekil 1.1).



Şekil 1.1 : Hanelerde internet erişimi ve bireylerde internet kullanımı (*Hanehalkı Bilişim Teknolojileri (BT) Kullanım Araştırması*, 2022).

Giysi, ayakkabı ve aksesuar kategorisine odaklandığımızda, bireylerin %71,3'ü bu ürünleri satın almıştır. Ayrıca, erkeklerin %64,7'si giysi, ayakkabı ve aksesuar alışverişini yaparken, %51,1'i lokanta ve fast food zincirlerinden teslimat hizmeti almıştır. Kadınların ise %78,4'ü giysi, ayakkabı ve aksesuar satın alırken, %49,2'si lokanta ve fast food zincirlerinden teslimat hizmeti ve %43,0'u gıda ürünleri satın almıştır (*Hanehalkı Bilişim Teknolojileri (BT) Kullanım Araştırması*, 2022).

Müşteri kanal göçü, müşterilerin farklı kanallar arasında hareket etme eğilimini ifade eder. Fiziksel veya e-ticaret kanalları, mobil uygulamalar ve fiziksel mağazalar bu kanallara örnektir. Müşteri kanal göçü, farklı kanallar arası geçiş yapma eğilimi farklı sebepler ile gerçekleşebilmektedir. Kolay erişebilir olması, daha ucuz veya daha çekici olması sebeplerden bazılarıdır. En önemlilerden bir tanesi, müşteriler bir kanaldan alışveriş yaparken yaşadığı olumsuz bir deneyim dolayısıyla başka bir kanala kanal göçü gerçekleştirebilmektedir.

Müşteri kanal göçü, firmalara zorluklar yaşattığı gibi farklı fırsatlar da doğurmaktadır. Örneğin, müşterilerin farklı kanallar arasında hareket etmeleri, firmaların müşteri davranışlarını daha iyi anlamalarına yardımcı olmaktadır. Bu bilgi, firmaların müşterileri daha iyi anlamalarına ve onların ihtiyaçlarına daha iyi yanıt vermelerine, aynı zamanda firmanın yeni müşteriler kazanmasına da yardımcı olmaktadır. Bir müşteri, fiziksel mağazada ürünü deneyip, sonrasında çevrimiçi kanaldan satın alabilmektedir. Sonrasında, çevrimiçi kanalı keşfetmiş olup gelecekte sadece o kanalı kullanabilmektedir (Li vd., 2017). Perakende firmaları, müşteri kanal göçünü anlamlandırmak için veri analizleri ve çeşitli araçlar kullanarak müşteri davranışlarını incelemektedirler. Yapılan analizler, müşteri kanal göçüne sebep olabilecek faktörleri ortaya çıkartmakta yardımcı olmaktadır. Fiyat, ürün çeşitliliği, erişilebilirlik, kolaylık ve müşteri deneyimi en sık incelenen faktörler arasında yer almaktadır.

Özetlemek gerekirse, müşteri kanal geçişi perakende sektöründe büyük bir öneme sahiptir. Müşteriler, çevrimiçi kanalların kolaylığı ve sunduğu hizmetler sebebi ile fiziksel ve çevrimiçi kanallar arasında geçiş yapmaktadır. Bu sebeple, perakende sektöründe bulunan firmaların müşterilerin hızla değişen bu ihtiyaçlarını karşılamak için çoklu kanallarında stratejiler geliştirmesi gerekmektedir. Perakende şirketleri, müşterilerin bireysel kanal geçişlerini anlamlandırmak için geri bildirimler alınması ve veriler ile analiz edilmesi; buna bağlı olarak stratejiler geliştirmeleri firmalar için olumlu olarak geri dönmektedir (Mark vd., 2014).

Müşterilerin kanal tercihleri ve geçiş nedenleri hakkında bilgi edinmek, perakende şirketleri için müşteri sadakati ve satışları artırmanın önemli bir yolu gibi görünmektedir. Ancak, müşteri kanal geçişleri, perakende şirketleri için birçok zorluk da ortaya çıkartmaktadır. Perakende şirketleri, müşterilerinin değişen ihtiyaçlarını

karşlamak için uygun kanal stratejileri geliştirmek ve farklı kanallar arasında uyumlu bir deneyim sunarak stratejiler geliştirmesi gerekmektedir (Li vd., 2017).

1.1 Müşteri Segmentasyonu

Günümüzde birçok işletme, belirtildiği gibi farklı kanallarla müşterilere ulaşarak ürün ve hizmetlerini birden fazla kanal ile kullanmaktadır. Çevrimiçi kanallar, fiziksel mağazalar, mobil uygulamalar ve çağrı merkezleri firmaların müşterilere ulaşmasını kolaylaştırmaktadır. Fakat, müşterilerin kanal tercihleri değişmekte ve bu da işletmelerin müşteri kanal göçü ile karşılaşmasına neden olmaktadır. Bu durum, işletmelerin müşterilerinin davranışlarını anlamalarını ve uygun pazarlama stratejileri geliştirmelerini gerektirir. Bu noktada müşteri segmentasyonu devreye girmektedir. Firmalar müşterilerini farklı özelliklerine göre gruplandırarak her bir gruba farklı pazarlama stratejileri uygular. Örneğin, bir işletme genç müşterilere yönelik sosyal medya pazarlaması yaparken, orta yaşlı müşterilere yönelik mağaza kampanyaları düzenlemek buna bir örnektir.

Bu konuya ilişkin yapılan bir araştırma, müşteri segmentasyonunun işletmelerin müşteri kanal göçü ile başa çıkmalarına yardımcı olabileceğini göstermektedir. Araştırmada, bir mağaza müşterisi olarak başlayan ve daha sonra online alışveriş yapmaya başlayan bir müşterinin davranışları incelenmiştir. Müşteri segmentasyonu, müşterinin yaş, gelir seviyesi, cinsiyeti ve diğer özelliklerine göre yapılmış ve her bir segmente farklı pazarlama stratejileri uygulanmıştır.

Sonuç olarak, işletmeler müşteri segmentasyonu yaparak müşteri kanal göçü sorununu azaltabilirler. Müşteri segmentasyonu, işletmelerin müşterilerine daha iyi bir hizmet sunmalarına ve müşterilerinin ilgi alanlarına göre pazarlama stratejileri oluşturmalarına yardımcı olur. Bu nedenle, müşteri segmentasyonunun işletmeler için önemi büyüktür ve işletmeler müşteri segmentasyonunu yaparken dikkatli ve detaylı bir şekilde analiz yapılmalıdır (Shi & Myer, 2020).

1.2 Tezin Amacı

Müşteri kanal göçü bir önceki bölümlerde de belirtildiği üzere perakende sektöründe özellikle pandemi sonrasında oldukça gündeme gelen bir konudur. Özellikle hem fiziksel hem çevrimiçi kanalda yer alan firmalar için potansiyel müşteri niteliğindedir.

Çünkü hali hazırda firmaya bağlılığı olan ama çevrimiçi kanalları hiç kullanmamış müşteriler olabilmektedir (Mark vd., 2014). Bu noktada, Shi ve Myer'in (2020) çalışması, müşteri kanal göçü ve müşteri segmentasyonu konusunda önemli bulgular sunmaktadır. Araştırmacılar, birçok şirketin birçok kanalda var olduğu ve müşterilerin bu kanallar arasında göç ettiği günümüz iş dünyasında, müşteri kanal göçünün önemli bir sorun olduğunu belirtmektedirler.


Araştırmacılar, müşteri segmentasyonunun bu soruna bir çözüm olabileceğini belirtmektedirler. Müşteri segmentasyonu, şirketlerin farklı müşteri gruplarını tanımlamalarına ve her bir müşteri grubuna özelleştirilmiş hizmetler sunmalarına olanak tanımaktadır. Örneğin, şirket müşterilerin çevrimiçi alışveriş yapmayı tercih ettiğini belirlediğinde, o müşteri grubuna özelleştirilmiş çevrimiçi alışveriş deneyimi sunacak hale gelir. Bu şekilde müşteri segmentasyonu, müşteri kanal göçünü azaltma ve müşteri memnuniyetini artırmaya yardımcı olabilir (Shi & Myer, 2020).

Bu çalışma, perakende sektöründe yaşanan önemli bir sorun olan müşteri kanal göçü konusuna odaklanmaktadır. Bu sorun, müşterilerin fiziksel mağaza yerine online kanala geçiş yapması veya tam tersi durumunda yaşanmaktadır. Bu durum, perakende şirketlerinin müşterileri elde tutma konusunda zorluklar yaşamasına neden olmaktadır. Müşterilerin hem fiziksel mağaza hem de çevrimiçi kanaldaki davranışları incelenerek, müşteri kanal göçü konusu detaylı bir şekilde analiz edilmiştir. Yıllara göre müşteri davranışları da analiz edilmiş ve çeşitli örüntüler tespit edilmiştir. Sonrasında, klasik kümeleme yöntemleri ve derin öğrenme yöntemleri kullanılarak müşteriler kümelenmiş ve sonuçlar detaylı bir şekilde incelenmiştir. Bu sayede, müşterilerin davranışları hakkında daha kapsamlı bir anlayış elde edilmiştir. Ayrıca, çalışma kapsamında müşterilerin alışveriş örüntüleri birleştirilerek, perakende şirketinin stratejik kararlar alması amaçlanmıştır. Bu sayede, müşterilerin davranışları hakkında daha derinlemesine bir anlayış elde edilerek, şirketin müşteri elde tutma stratejileri belirlenmiştir.

Sonuç olarak, bu çalışma perakende sektöründeki önemli bir soruna odaklanarak, müşteri kanal göçü konusunu detaylı bir şekilde analiz etmiştir. Bu sayede, perakende şirketleri müşterilerinin davranışları hakkında daha kapsamlı bir anlayış elde ederek, müşteri elde tutma stratejileri belirlenebilir.


2. LİTERATÜR TARAMASI

Bu çalışmada, müşteri kanal göçü konusuyla ilgili yayınlar detaylı bir şekilde incelenmiştir. Bu amaçla, Scopus, Science Direct, Emerald Insight gibi çeşitli veritabanları taranarak "Müşteri Kanal Göçü" veya "Müşteri Kanal Değiştirme" anahtar kelimelerini içeren yayınlar toplanmıştır. Toplamda 40 yayın incelenmiştir. Bu yayınların amacı, yayınlandığı yıl ve kullanılan yöntemler gibi detaylar dikkate alınmıştır (Çizelge 2.1). Yayınların yıllara göre dağılımına bakıldığında (Şekil 2.1), müşteri kanal göçüyle ilgili yayınların 2011 yılından sonra artış göstermeye başladığı görülmektedir. Ancak, istikrarlı bir artış eğilimi gözlenmemiştir. En yüksek yayın sayısı, 2019 yılında 6 yayınlı kaydedilmiştir.



Şekil 2.1 : İncelenen yayınların yıllara göre dağılımı.

Yapılan incelemelerde, müşteri kanal göçüyle ilgili yayınların farklı sektörlerden geldiği tespit edilmiştir. Finans, telekomünikasyon, perakende ve turizm sektörleri gibi alanlar, bu yayınlar arasında önemli bir yer tutmaktadır. Özellikle büyük ölçekli işletmeler üzerinde yoğunlaştığı ve küçük ölçekli işletmelerin bu alanda daha az çalışma yürüttüğü gözlemlenmiştir. Makaleler sektör bazında incelendiğinde (Şekil 2.2), perakende sektörünün 18 yayınlı en fazla araştırma yapılan alan olduğu görülmektedir. Onu 4 yayınlı Bankacılık sektörü ve 3 yayınlı E-ticaret sektörü takip etmektedir. Bu bulgular, müşteri kanal göçü konusundaki araştırmaların sektörel farklılıklara bağlı olarak çeşitlilik gösterdiğini ve özellikle perakende sektörüne odaklandığını göstermektedir.



Şekil 2.2 : İncelenen yayınların sektörlere göre dağılımı.


Bu çalışmada yapılan incelemeler, müşteri kanal göçü konusunda farklı yöntemlerin kullanıldığını ortaya koymaktadır. İncelenen 40 yayın arasında, klasik istatistiksel yöntemlerden makine öğrenmesi yöntemlerine ve optimizasyon modellerine kadar çeşitli yöntemlerin kullanıldığı görülmektedir. Ancak, her yöntemin her durumda etkili sonuçlar sağlamayabileceği göz önünde bulundurulmalıdır. Bu nedenle, işletmelerin kendi özelliklerine ve ihtiyaçlarına uygun en uygun yöntemi seçmeleri önemlidir.

Yapılan incelemelerde, müşteri kanal göçü konusunda kullanılan yöntemler arasında Kümeleme & Tahmin yöntemlerinin yaygın olduğu görülmektedir. İncelenen 40 yayın içerisinde, 8 yayında bu yöntemlerin kullanıldığı tespit edilmiştir (Şekil 2.3). Özellikle, K-Ortalama, KNN, Lojistik Regresyon, Gaussian ve Random Forest gibi makine öğrenmesi modellerinin kullanıldığı görülmektedir. Ayrıca, Markov Chain modelleri, BAYES yöntemi, NGN yöntemi ve dinamik optimizasyon modelleri gibi farklı teknikler de müşteri kanal göçü probleminin çözümüne yönelik çalışmalarda kullanılmıştır.

Bunun yanı sıra, yapılan incelemelerde stratejik öneriler sunan yayınların sayısının da oldukça fazla olduğu görülmektedir. Bu yayınlarda, müşteri kanal göçüne karşı alınabilecek stratejik önlemler üzerine öneriler sunulmuş ve çeşitli analiz yöntemleri kullanılarak sonuçlar elde edilmiştir. Tüm bu çalışmalar, müşteri kanal göçü konusunda farklı bakış açıları ve çözüm önerileri sunarak, işletmelere bu sorunla başa çıkmak için önemli bir rehberlik sağlamaktadır.

Yapılan incelemelerin diğ er bir b l m nde, 40 yayının arařtırma konu bařlığında 16'sının yer aldığı ve strateji bařlığı altında 16 yayın incelenmiştir (řekil 2.3). Strateji bařlığı altındaki yayınlar, m řteri kanal g    konusunda iřletmeye stratejik  neriler i ermektedir ve dinamik optimizasyon modelleri, istatistiksel analiz y ntemleri ve oyun teorisi gibi y ntemler kullanılmaktadır. Arařtırma konu bařlığı altındaki yayınlarda ise, istatistiksel analiz y ntemleri kullanılarak elde edilen sonu lar paylařılmıştır.

Bu incelemeler, m řteri kanal g    konusunda geniř bir perspektif sunmaktadır. Farklı sekt rlerden gelen yayınlar, farklı y ntemlerin kullanılması ve stratejik  nerilerin  eřitliliğı, iřletmelere bu konuda kapsamlı bir bilgi kaynağı saėlamaktadır. Sonu  olarak, bu  alıřmalar, m řteri kanal g   yle ilgili yapılan arařtırmalara katkıda bulunmakta ve iřletmelere bu konuda daha bilin li kararlar alabilmeleri i in  nemli bir rehberlik sunmaktadır.



řekil 2.3 : İncelenen yayınların konulara g re daėılımı.

Bahsedildiğı  zere incelenen 40 makale, tablo haline getirilerek  zetlenen ama lar ve kullanılan y ntemlerle ilgili bilgileri i ermektedir ( izelge 2.1). Bu tablo, arařtırmacılar ve ilgili kiřiler i in bir kaynak niteliğı tařımaktadır. Ayrıca, tablo sayesinde farklı sekt rlerde yapılan  alıřmaların genel bir bakıř a ısı sunulmuřtur.

Makalelerin yöntem ve konularından sonra amaçları da özetlenmek istenmiştir. Makaleler, müşteri kanal göçü konusunda farklı sektörlerdeki müşteri davranışlarını ve eğilimlerini araştırmayı hedeflemektedir. Finans, telekomünikasyon, perakende ve turizm gibi sektörlerde gerçekleştirilen çalışmalar, müşteri kanal göçünün sektörlere özgü özelliklerini ve trendlerini analiz etmektedir. Bu amaçla, müşterilerin kanal tercihleri, kanal geçiş davranışları ve kanal göçünün sektörel etkileri incelenmektedir.

Bazı makaleler, müşteri kanal göçü konusunda kullanılan analitik ve istatistiksel yöntemlerin etkinliğini değerlendirmeyi amaçlamaktadır. Bu çalışmalar, farklı yöntemlerin müşteri davranışlarını tahmin etme, segmentlere ayırma ve kanal geçişini yönlendirme konularında ne kadar başarılı olduğunu araştırmaktadır. Klasik istatistiksel yöntemlerden makine öğrenmesi algoritmalarına, optimizasyon modellerinden oyun teorisi tekniklerine kadar çeşitli yöntemler kullanılmaktadır. Bu çalışmalar, işletmelere en etkili yöntemleri seçmede rehberlik sağlamayı hedeflemektedir.

Bir grup makale, müşteri kanal göçünün işletmelere olan etkilerini ve bu göçün işletme performansı, karlılık ve müşteri sadakati üzerindeki sonuçlarını incelemektedir. Bu çalışmalar, müşteri kanal göçünün işletmelerin pazarlama stratejilerine nasıl yansıdığını, işletmelerin müşteri kanal göçüyle nasıl başa çıkabileceğini ve müşteri kanal göçünün işletme performansı üzerindeki etkilerini analiz etmektedir. Bu amaç doğrultusunda, stratejik öneriler sunularak işletmelere müşteri kanal göçüyle ilgili kararlar almalarında yardımcı olunmaktadır.

Son olarak, bazı makaleler müşteri kanal göçünün teknolojik gelişmelerle ilişkisini incelemektedir. Özellikle dijital dönüşüm süreçlerinde, müşteri kanal göçü konusu önem kazanmaktadır. Bu çalışmalar, dijital teknolojilerin müşteri davranışlarını nasıl etkilediğini, müşterilerin yeni teknolojilere nasıl uyum sağladığını ve işletmelerin dijital kanallarla nasıl etkileşimde bulunması gerektiğini araştırmaktadır. Bu tür çalışmalar, işletmelerin dijital dönüşüm stratejilerini geliştirmelerine ve müşteri kanal göçüyle ilgili teknolojik yeniliklere uyum sağlamalarına yardımcı olmayı amaçlamaktadır.

Tüm bu amaçlar doğrultusunda yapılan araştırmalar, müşteri kanal göçü konusunda daha derin bir anlayış sağlamak ve işletmelere stratejik kararlarında yol göstermek amacıyla gerçekleştirilmektedir. Makaleler, müşteri davranışları, pazarlama

stratejileri, işletme performansı, teknolojik gelişmeler ve rekabetçi ortam gibi farklı boyutları ele almaktadır. Bu sayede, işletmeler müşteri kanal göçüyle ilgili kararlarını daha bilinçli bir şekilde alabilir, müşteri deneyimini iyileştirebilir, rekabet avantajı sağlayabilir ve işletme performansını artırabilir.

Bununla birlikte, müşteri kanal göçü konusu hala gelişmekte olan bir araştırma alanıdır ve daha fazla çalışma gerekmektedir. Müşterilerin farklı kanallar arasında geçiş yapması ve bu geçişlerin nedenleri, sonuçları ve etkileri hakkında daha derinlemesine anlayışa ihtiyaç vardır.

İşletmelerin müşteri davranışlarını ve kanal geçişlerini anlamak için daha kapsamlı analizler yapılması önemlidir. Bu analizler, müşteri segmentasyonunu, alışveriş sepeti analizini, zaman serisi analizini ve diğer ilgili yöntemleri içermelidir. Müşterilerin neden farklı kanallara geçtikleri, hangi faktörlerin bu geçişleri etkilediği ve müşteri sadakati üzerindeki etkileri gibi sorulara cevap aranmalıdır.

Yeni analitik yöntemler ve modeller geliştirme ihtiyacı da vardır. Makine öğrenimi, yapay zeka ve büyük veri analitiği gibi alanlardaki ilerlemeler, müşteri kanal göçü analizinde daha güçlü ve hassas sonuçlar elde etme potansiyeline sahiptir. Bu yeni teknolojilerin kullanımı, işletmelere daha derin bir anlayış sağlayabilir ve kanal geçişlerini daha iyi öngörebilmelerini sağlayabilir.

Ayrıca, farklı sektörlerdeki örneklerin daha fazla incelenmesi gerekmektedir. Her sektörde müşteri kanal göçü dinamikleri farklılık gösterebilir ve bu nedenle sektörel farklılıkları anlamak önemlidir. Örneğin, perakende sektöründe müşteri kanal göçü farklı faktörlere bağlı olabilirken, bankacılık sektöründe farklı dinamikler ön plana çıkabilir. Bu nedenle, çeşitli sektörlerden gelen veri setlerinin analiz edilmesi ve karşılaştırılması, genel bir anlayışın oluşturulmasına yardımcı olabilir.

Sonuç olarak, müşteri kanal göçü konusunda yapılan bu makaleler, işletmelere müşteri kanal stratejilerini geliştirmede, rekabet avantajı sağlamada, müşteri deneyimini iyileştirmede ve işletme performansını artırmada önemli bir rehberlik sağlayabilir. Ancak, müşteri kanal göçü konusu hala keşfedilmeyi bekleyen birçok alanı içerdiğinden, gelecekteki çalışmaların bu konuya daha fazla odaklanması, yeni bilgilerin ortaya çıkarılması ve mevcut yöntemlerin geliştirilmesi gerekmektedir. Bu şekilde, işletmeler müşteri kanal stratejilerini daha iyi anlayabilir ve müşteri taleplerine daha etkili bir şekilde yanıt verebilir.

Çizelge 2.1 : Literatür taraması.

No	Yayın İsmi	Yazar	Yıl	Sektör	Ana Konu	Metot	Amaç
1	Configurational analysis of conditions influencing customers' channel switching intention in omnichannel retailing: a fuzzy-set analysis	(Van Nguyen vd., 2023)	2023	Perakende	Strateji	fuzzy-set analiz	Çok kanallı perakendecilikte kanal değiştirme niyetini etkileyen koşulları yapılandırmaya yönelik bir analiz yapmak
2	Explaining consumers' channel-switching behavior in the post-COVID-19 pandemic era	(Tran vd., 2023)	2023	E-ticaret	Strateji	İstatistiksel analiz	COVID-19 pandemisi sonrasında tüketicilerin kanal değiştirme davranışlarının belirleyicilerini incelemek
3	Integrated customer lifetime value (CLV) and customer migration model to improve customer segmentation	(Kanchanapoom & Chongwatpol, 2022)	2022	Sağlık	Kümeleme & Tahmin Modeli	Kümeleme analizi ve RFM modeli	Müşterilerin gelecekte muhtemelen geri dönecekleri pazarlama stratejisinin belirlenmesi
4	Exploring customer experience during channel switching in omnichannel retailing context: A qualitative assessment	(Nguyen vd., 2022)	2022	Perakende	Araştırma	İstatistiksel analiz	Kanal değiştirme davranışını ve müşteri deneyimini incelemek ve sosyal bilişsel teoriye dayalı bir kanal değiştirme davranışı çerçevesi önermek
5	Predictive Model for Cutting Customers Migration from banks: Based on machine learning classification algorithms	(Alkhatib & Abualigah, 2020)	2021	Banka	Kümeleme & Tahmin Modeli	Makine öğrenmesi yöntemleri	Makine öğrenimi sınıflandırma algoritmalarına dayalı müşteri göçü tahmin modeli oluşturmak ve bankalardaki müşteri kaybını azaltmak
6	Channel migration and online and offline behavior changes in retailing: A latent class analysis	(Huang vd., 2021)	2021	Perakende	Araştırma	Gizil sınıf analizi (Latent Class Analysis)	Müşterilerin çevrimiçi ve çevrimdışı kanallar arasında geçiş yapmalarının ve davranış değişikliklerinin belirlenmesi
7	Business-to-business marketing responses to COVID-19 crisis: a business process perspective	(Kang vd., 2021)	2021	-	Araştırma	literatür taraması	Pandemi nedeniyle B2B firmalarının müşteri kanallarında meydana gelen değişimlerin (kanal göçü) nakit akışı üzerindeki etkileri de ele alınmaktadır.

Çizelge 2.1 (Devam): Literatür taraması.

No	Yayın İsmi	Yazar	Yıl	Sektör	Ana Konu	Metot	Amaç
8	Consumers' Channel Switching Behaviour from Off-line to On-line: The Role of the Fear of Covid-19	(Martinelli vd., 2021)	2021	Perakende	Araştırma	İstatistiksel analiz	Covid-19 pandemisi sırasında insanların alışveriş yapma şeklini nasıl değiştirdiğini anlamak
9	How does customer channel migration affect firm value in the retail industry?	(Ma vd., 2020)	2020	Perakende	Araştırma	İstatistiksel analiz	Müşteri kanal göçünün perakende sektöründeki şirket değeri üzerindeki etkisini araştırmak
10	The effects of online reviews and brand reputation on customer migration intention: A case study of Airbnb	(J. Yang & Khoo, 2020)	2020	Turizm	Araştırma	İstatistiksel analiz	Airbnb örneği üzerinden online yorumların ve marka itibarının müşteri göç niyeti üzerindeki etkisini incelemek ve bu tarz şirketlerin müşterilerini tutmalarındaki faktörleri belirlemektir.
11	Online–offline channel migration in retail: A machine learning approach	(Nunes vd., 2020)	2020	Perakende	Araştırma	k-ortalama kümeleme yöntemi	Online ve çevrimdışı kanallar arasındaki geçiş davranışlarının keşfedilmesi ve bu davranışların perakende sektöründeki etkilerinin değerlendirilmesi
12	The effectiveness of random discounts for migrating customers to the mobile channel	(De Vries & Zhang, 2020)	2020	Telekomünikasyon	Strateji	İstatistiksel analiz	En etkili mobil kanal geçiş stratejisi için rastgele indirim veya cezayı belirleme
13	The Effect of Digital Channel Migration, Automation and Centralization on the Efficiency of Operational Staff of Bank Branches	(Ortaköy & Özsürünç, 2019)	2019	Banka	Strateji	-	Dijital dönüşümle gelen gelecek durumunun araştırılması

Çizelge 2.1 (Devam): Literatür taraması.

No	Yayın İsmi	Yazar	Yıl	Sektör	Ana Konu	Metot	Amaç
14	Still Targeting Younger Customers? A Field Experiment on Digital Communication Channel Migration	(Z. Yang vd., 2019)	2019	Sigorta	Araştırma	İstatistiksel analiz	Sigorta şirketinde dijital iletişim kanalı geçişinin etkin stratejilerini incelemek
15	Implementing PPM framework to customer's switching behaviour in dual-channel service supply chain	(Widodo vd., 2019)	2019	Tedarik Zinciri	Araştırma	Kısmi En Küçük Kareler-Yapısal Eşitlik Modelleme	Müşterilerin kanal değiştirme davranışının analizi ve müşteri sadakatini artırmak için bir proje portföyü yönetimi önermek
16	Examining the effects of customer shopping channel migration on retailers' pricing strategies	(Kim & Park, 2019)	2019	Perakende	Strateji	İstatistiksel analiz	Müşteri alışveriş kanalı göçünün perakendecilerin fiyatlandırma stratejileri üzerindeki etkisini araştırmak
17	Channel migration patterns and the impact on online and offline purchases	(Han vd., 2019)	2019	Perakende	Araştırma	İstatistiksel analiz	Tüketicilerin kanal göçü davranışları ile çevrimiçi ve çevrimdışı satın alma davranışları arasındaki ilişkiyi araştırmak
18	Research on customer channel migration in the omni-channel era: A case study of Chinese online retailing.	(Zhang & Zhang, 2019)	2019	Perakende	Araştırma	İstatistiksel analiz	Çevrimiçi perakende sektörü örneği üzerinden, omni-kanal çağında müşteri kanal göçü araştırmalarına odaklanmak
19	Pricing strategies for dual-channel supply chains under a trade credit policy	(Qin vd., 2020)	2020	Tedarik Zinciri	Strateji	Oyun teorisi yaklaşımı	Çift kanallı bir tedarik zincirinde bir ticari kredi politikasının yarattığı çatışmaların hafifletilmesindeki etkisini tartışmak
20	Managing CLV Using the Migration Model Framework: Overcoming the 'Recency Trap'	(Abhishek vd., 2017)	2017	-	Strateji	Dinamik optimizasyon modeli	Hangi müşterilere hangi zamanda hangi pazarlama çabalarının hedeflenmesi gerektiğini belirleyen bir prosedür tasarlamaktır.

Çizelge 2.1 (Devam): Literatür taraması.

No	Yayın İsmi	Yazar	Yıl	Sektör	Ana Konu	Metot	Amaç
21	Customer Channel Migration and Firm Choice: The Effects of Cross-Channel Competition	(Li vd., 2017)	2017	Perakende	Strateji	İstatistiksel analiz	Yeni bir çevrimiçi satın alma kanalı tanıtan firma ile müşterilerin kanal seçiminin araştırılması
22	Reducing the chance of customers leaving by utilizing big data clustering algorithm	(Chen vd., 2017)	2017	-	Kümeleme & Tahmin Modeli	Paralel çekirdek k-ortalama	Daha etkili ve verimli bir kümeleme algoritması olan paralel çekirdek k-ortalama algoritmasını önermek
23	Multichannel service providers' strategy: Understanding customers' switching and free-riding behavior	(Chou vd., 2016)	2016	-	Strateji	faktör analizi ve yapısal eşitlik modellemesi	Müşterilerin kanal değiştirme davranışlarını anlamlandırmaya yardımcı olmak için bir model önermek
24	An Empirical Study of Malaysian Consumers' Channel-switching Intention: Using theory of Planned Behaviour	(Madah i & Sukati, 2016)	2016	Perakende	Strateji	İstatistiksel analiz	Malezyalı tüketicilerin kanal değiştirme niyetlerini belirlemek ve bu niyeti etkileyen faktörleri analiz etmek için Planlı Davranış Kuramı'nı kullanmak
25	Adding store to web: migration and synergy effects in multi-channel retailing	(Fornari vd., 2016)	2016	Perakende	Araştırma	İstatistiksel analiz	Mağazanın web sitesine eklenmesinin göç ve sinerji etkilerini araştırmak ve perakendecilere satışları ve müşteri sadakatini artırmak için optimal kanal karışımı hakkında bilgi sağlamak
26	Pricing strategies of a dual-channel supply chain with risk aversion	(Liu vd., 2016)	2016	Tedarik Zinciri	Strateji	Oyun teorisi yaklaşımı	Çift kanallı bir tedarik zincirindeki kanal göçünün, tedarik zincirindeki fiyatlandırma stratejilerine olan etkisini araştırmak
27	Customers' online channel switching behavior: The moderating role of switching cost	(Poura bedin vd., t.y.)	2016	E-ticaret	Araştırma	İstatistiksel analiz	Müşterilerin online kanal değiştirme davranışlarını ve bu davranışın geçiş maliyeti ile nasıl etkilendiğini araştırmak

Çizelge 2.1 (Devam): Literatür taraması.

No	Yayın İsmi	Yazar	Yıl	Sektör	Ana Konu	Metot	Amaç
28	Customer Responses to Channel Migration Strategies Toward the E-channel	(Trampe vd., 2014)	2014	Banka	Strateji	İstatistiksel analiz	E kanal geçiş stratejileri için müşteri yönelimi analizi
29	Customer Migration Patterns: Evidence from a North American Retailer	(Mark vd., 2014)	2014	Perakende	Kümeleme & Tahmin Modeli	Markov Chain	Zamanla karlı olan müşterinin belirlenmesi
30	Behavioral Consequences of Customer-Initiated Channel Migration	(Ackermann & von Wangenheim, 2014)	2014	Perakende	Araştırma	İstatistiksel analiz	Müşterilerin farklı kanallara geçiş davranışının işletmeler üzerindeki etkilerini incelemek ve müşteri bağlılığını korumak için stratejiler geliştirmek
31	Decision Process Evolution in Customer Channel Choice	(Valentini vd., 2011)	2011	Perakende	Strateji	İstatistiksel analiz	Verileri analiz ederek müşterinin kanal seçim kararının sebeplerini bulma
32	Explaining multi-channel consumer's channel-migration intention using theory of reasoned action	(Pookulangara vd., 2011)	2010	Perakende	Araştırma	İstatistiksel analiz	Çoklu kanallı tüketicilerin kanal-migrasyon niyetini açıklamak ve davranışsal niyetlerinin altında yatan faktörleri teorik bir model olan "akılcı davranış teorisi" kullanarak analiz etmek
33	A Hybrid Firm's Pricing Strategy in Electronic Commerce Under Channel Migration	(Kauffman vd., 2009)	2009	E-ticaret	Strateji	Oyun teorisi temelli fiyatlandırma	Fiyatlandırma stratejileri tasarlamak ve müşterilerin satış kanalları arasında göç etmelerinin olası etkilerini modellemek
34	Migration of customers owing to a service substitution	(Murynets vd., 2009)	2009	-	Strateji	İstatistiksel model	Eski ürünü yeniye kullanan müşteriyi analizi

Çizelge 2.1 (Devam): Literatür taraması.

No	Yayın İsmi	Yazar	Yıl	Sektör	Ana Konu	Metot	Amaç
35	Customer Channel Migration	(Ansari vd., 2008)	2008	Perakende	Kümeleme & Tahmin Modeli	BAYES Modeli	Web üzerinden ve kataloglar aracılığıyla pazarlayan bir perakendeciye uygulanan müşteri kanal geçiş modeli
36	A "Customer Satisfaction" Based Migration Approach toward NGN	(Jamoussi & Al Salem, 2006)	2006	Telekominikasyon	Kümeleme & Tahmin Modeli	"NGN" (Next Generation Networks)	Müşteri memnuniyetine dayalı bir göç yaklaşımı önererek yeni nesil ağları (NGN) kullanarak geçişi kolaylaştırmak
37	Customer Migration: An Empirical Investigation Across Multiple Channels	(Sullivan & Thomas, 2004)	2004	Perakende	Kümeleme & Tahmin Modeli	İstatistiksel analiz	Müşteri kanal geçişini ve kanal geçişinin müşteri karlılığı üzerindeki sonuçları
38	Customer migration, campaign budgeting, revenue estimation: the elasticity of Markov Decision Process on customer lifetime value	(Ching vd., 2004)	2004	-	Kümeleme & Tahmin Modeli	Markov Chain	Müşteri yaşam boyu değeri için üst düzey Markov karar sürecinin uygulanması
39	Migrating customers to new distribution channels: The role of communication	(Sarel & Marmorstein, 2001)	2001	Banka	Strateji	İstatistiksel model	İletişimin etkisinin, müşterilerin yeni teknolojiyi benimsemesinin önemli olduğunun kanıtlanması
40	Strategic integration of customers and channels	(Kimber, t.y.)	2001	Finansal Servisler	Araştırma	-	Kanal yönelimlerindeki trendlerin araştırılması

2001 yılında, Kimber C. tarafından finansal sektörlerdeki müşteri kanal yönelimleri trendleri araştırılmıştır (Kimber, t.y.). Sonrasında yine 2001 yılında, müşterilerin yeni teknolojileri benimsemelerinde iletişimin etkisini göstermek için Banka sektöründe D. Sarel ve arkadaşları tarafından istatistiksel modeller kullanılarak çalışma yapılmıştır (Sarel & Marmorstein, 2001). Ardından, 2004 yılında müşterilerin yaşam boyu değerini görmek için Ching, W. ve diğerleri tarafından markov chain kullanılmıştır (Ching vd., 2004). Yine 2004 yılında, Sullivan, U. Y. ve arkadaşları tarafından perakende sektöründe müşteri kanal geçişinin müşteri karlılığı üzerindeki sonuçlarını incelemek adına çalışma yapılmıştır (Sullivan & Thomas, 2004). Sonrasında 2006 yılında, müşteri memnuniyetine dayalı bir göç yaklaşımı NGN yöntemi kullanılarak geliştirilmiştir (Jamoussi & Al Salem, 2006). Bu çalışmadan 2 yıl sonra 2008 yılında, perakende sektörü kapsamında BAYES modeli kullanılarak müşteri kanal geçiş modeli Ansari A. , Mela C. ve Neslin S. tarafından oluşturulmuştur (Ansari vd., 2008). Sonrasında 2009 yılında, istatistiksel analiz yöntemleri kullanılarak eski ürüne karşı yeniyi kullanan müşterilerin analizi yapılmıştır (Murynets vd., 2009). Yine 2009 yılında, Fiyatlandırma stratejileri tasarlamak ve müşterilerin kanallar arasındaki göçlerinin sebeplerine bakarak etkilerini modellenmiştir. Bu modellemeyi yaparken Oyun teorisi temelli fiyatlandırma kullanılmıştır (Kauffman vd., 2009). 2010 yılında, perakende sektörü için yapılan çalışmada çoklu kanallı tüketicilerin kanal-migrasyon niyetini açıklamak için "akılcı davranış teorisi" kullanarak analiz edilmiştir (Pookulangara vd., 2011). Ardından 2011 yılında, müşteri kanal geçiş davranışının sebeplerini bulmak amacıyla analiz yapılmıştır (Bleier vd., 2011). 2014 yılında bu konu ile ilgili 3 çalışma yapılmıştır. İlkinde, müşterilerin farklı kanallara geçiş davranışının işletmeler üzerindeki etkilerini incelemek ve stratejiler geliştirmek amacı ile çalışma yapılmıştır (Ackermann & von Wangenheim, 2014). İkinci çalışmada, karlı olan müşterilerin tespiti amacı ile markov chain kullanılarak bir çalışma yapılmıştır (Mark vd., 2014). 2014 yılındaki bahsedilecek son çalışmada, istatistiksel analiz yöntemleri kullanılarak E kanal geçiş stratejileri için müşteri yönelimi analizi yapılmıştır (Trampe vd., 2014). 2016 yılında da bahsedilecek 5 çalışma bulunmaktadır. İlk çalışmada, müşterilerin online kanal değiştirme davranışlarının geçiş maliyetlerine etkisi incelenmiştir (Pourabedin vd., t.y.). İkinci çalışmada, Çoklu kanal bir tedarik zincirindeki müşteri kanal göçünün firmanın fiyatlandırma stratejilerine olan etkisini araştırmak için oyun teorisi kullanılarak çalışma yapılmıştır (Liu vd., 2016). Üçüncü çalışmada, müşteri sadakatini artırmak için optimal kanal

stratejiler hakkında bilgi sağlamak amacıyla istatistiksel analizler yapılarak sonuçları paylaşılmıştır (Fornari vd., 2016). Dördüncü çalışmada ise, Malezyalı tüketicilerin kanal değiştirme faktörlerini belirlemek ve analiz etmek için planlı davranış kuramı tanımlanmıştır (Madahi & Sukati, 2016). 2016 yılı için bahsedilecek son çalışmada, faktör analizi ve yapısal eşitlik modelleri kullanılarak müşterilerin kanal göçü konusu için ilgili davranışlarını inceleyip anlamlandırmak üzerine için bir model önerilmiştir (Chou vd., 2016). 2017 yılında yapılan 3 çalışmadan bahsedilecektir. Bunlardan ilki, hangi müşterilere hangi zamanda hangi pazarlama çabalarının hedeflenmesi gerektiğini belirleyen bir prosedür tasarlamak amacı ile dinamik optimizasyon yöntemi kullanılarak sonuçları paylaşılmıştır (Abhishek vd., 2017). İkinci çalışmada, SCM ve SCSCM algoritmalarının yerine müşteri kanal göçü konusunda daha iyi olduğunu düşündükleri bir kümeleme algoritması olan paralel çekirdek K-Ortalama algoritmasını önermişlerdir (Chen vd., 2017). Üçüncü çalışmada ise, yeni bir çevrimiçi kanal kullanan firmanın müşteri kanal seçimlerini araştırmışlardır (Li vd., 2017). 2019 yılı için 5 yayın incelenmiştir. Yayınlarından ilkinde, perakende sektöründe müşterilerin kanal tercihleri kanal göçü modelleri analiz edilmiştir (Zhang & Zhang, 2019). İkinci yayında, müşterilerin çevrimiçi ve fiziksel kanaldaki satın almaları arasındaki ilişki araştırılmıştır (Han vd., 2019). Üçüncü yayında, müşteri kanal göçünün perakende firmalarında fiyatlandırma stratejileri üzerindeki etkisini araştırılmıştır (Kim & Park, 2019). Dördüncü yayında, müşterilerin kanal değiştirme davranışları analiz edilerek müşteri sadakatini arttırmak için bir PPM çerçevesi önerilmiştir (Widodo vd., 2019). Beşinci yayında, sigorta sektöründeki bir firma için dijital iletişim kanalları arasındaki göçün incelenerek stratejiler belirlenmesi üzerine çalışılmıştır (Z. Yang vd., 2019). 2019 yılı için bahsedilecek son yayında, dijital dönüşümle yapılan projelerde banka sektöründeki durum araştırılmıştır (Ortakoy & Özsürünç, 2019). 2020 yılı için, 5 yayın incelenmiştir. İlk yayında, kanal geçiş stratejileri arasında en iyisini belirlemek amacı ile rastgele indirim ve caza yolları ile çalışma yapılmıştır (De Vries & Zhang, 2020). İkinci yayında, perakende sektörü için müşteri kanal göçü ve şirket değeri arasındaki ilişki araştırılmıştır (Ma vd., 2020). Üçüncü yayında ise, çevrimiçi ve fiziksel kanallar arasındaki kanal göçü davranışlarının anlaşılması ve perakende üzerindeki etkileri değerlendirmek üzerine bir çalışma yapılmıştır (Nunes vd., 2020). Dördüncü yayında, Airbnb örneği üzerinden yorumların ve markanın göç üzerindeki etkileri belirlemek ve müşteri tutundurma çalışmaları önermek üzerine bir çalışma yapılmıştır (J. Yang & Khoo, 2020). Son yayında ise, oyun teorisi yaklaşımı

kullanılarak çok kanallı bir tedarik zincirinde kredi politikasının yarattığı çatışmaların hafifletilmesindeki etkisini tartışmak odaklanılmıştır (Qin vd., 2020). 2021 yılı için 4 yayın incelenmiştir. İlk incelenen yayında, COVID-19 nedeniyle B2B firmalarının müşteri kanal göçünün nakit akışı üzerindeki etkileri de ele alınmaktadır (Kang vd., 2021). İkinci yayında, pandemi sönemindeki müşterilerin alışveriş yapma davranışları ve bu davranışların nasıl değiştiğini anlamak üzerine bir çalışma yapılmıştır (Martinelli vd., 2021). Üçüncü yayında, istatistiksel analiz yöntemleri kullanılarak müşteri kanal göçü konusunda çevrimiçi ve çevrimdışı alışveriş davranışları üzerindeki etkileri incelenmiştir (Huang vd., 2021). İncelenen dördüncü yayında, makine öğrenmesi algoritmalarına dayalı müşteri göçü tahmin modeli oluşturulmuştur (Alkhatib & Abualigah, 2020). 2022 yılı için 2 yayın incelenmiştir. İlkinde, müşterilerin kanal değiştirme davranışı ve deneyimini incelenmiş ve bir çerçeve önerilmiştir (Nguyen vd., 2022). İkinci yayında ise, müşterileri kanal göçü ile geri dönmelerini sağlayacak pazarlama stratejisi belirlenmiştir (Kanchanapoom & Chongwatpol, 2022). 2023 yılı için 2 yayın incelenmiştir. İlk yayında, Tran, A. T. N. ve diğer yazarların yaptığı çalışma ile e-ticaret sektöründe pandemi sonrasında tüketicileri kanal göçüne iten davranış belirleyicilerini incelemek amacı ile sonrasında tüketicilerin kanal değiştirme davranışlarının belirleyicilerini incelemiştir (Tran vd., 2023). İkinci yayında ise, A. Van Nguyen ve arkadaşları çok kanallı perakendecilikte müşteri kanal göçü konusunda göçü etkileyen koşulların analizini yapmıştır (Van Nguyen vd., 2023).

Çalışmaya, müşteri kanal göçü ile ilgili birçok farklı yöntem kullanılmaktadır. Bunlar arasında makine öğrenmesi teknikleri, markov zinciri modelleri gibi çeşitli yaklaşımlar bulunur. Sonuçta, müşteri kanal göçü konusunda derin öğrenme yöntemleri kullanılarak yapılan bir segmentasyon çalışmasına rastlanmamıştır. Yapılan araştırma sonuçları, müşteri kanal göçü ile ilgili yöntemler ve amaçları hakkında detaylı bir bakış açısı sunmaktadır. Bu sayede, işletmelerin müşteri kanal göçü ile başa çıkmak için hangi yöntemleri kullanabileceği konusunda daha bilinçli kararlar alması mümkün olacaktır. Ayrıca, gelecekte yapılacak olan benzer çalışmaların da literatüre katkı sağlaması amaçlanmaktadır.

3. VERİ ANALİZİ VE MODELLER

3.1 Kavramlar, Değişkenler ve Ölçekleri

3.1.1 Ham veri

Müşteri kanal göçü hakkında analiz yapabilmek için müşterinin olabildiğince fazla bilgisi edinilmek istenmiştir. Çalışılan firma perakende sektöründe olduğu için ve kendi sadakat programı bulunduğundan müşterilerin alışverişlerini takip etmek ve bilgilerini öğrenmek için birçok veri bulunmaktadır. Perakende sektöründe bu veriler, müşterilere sunulan özel kampanya, kendine özel ürün önerisi gibi birçok alanda yapılan çalışmalarda kullanılmaktadır.

Müşteri verileri bir view olarak cloud ortamına eklenmiştir. Bu veriye firmanın özel Jupyter Lab hesabından ulaşılmaktadır. Veriler istenilen şekilde SQL aracılığı ile çekilebilmekte, işlenebilmektedir. Bu çalışma için hem SQL hem Jupyter Lab ortamında çalışıldığı için “Python” dili kullanılmıştır.

Jupyter Lab üzerinden jaydebeapi kütüphanesinden faydalanılarak cloud ortamında view’de bulunan veriler SQL aracılığı ile çekilmiştir. Sonrasında veriler python ortamında pandas, numpy gibi kütüphaneler kullanılarak işlenmiş; seaborn, matplotlib gibi kütüphaneler ile görselleştirilmiştir.

Ortamda çok fazla veri bulunmaktadır. Bu sebeple, tüm veriler 3 kategori halinde edinilmiştir (Çizelge 3.1, Çizelge 3.2, Çizelge 3.3). Ayrıca, tüm veriler için son 4 yılın verileri edinilmesi istenmiştir. Bu sebeple, 2019-2020-2021-2022 yılları için veriler çekilmiştir. Çekilen verilerin kategorisi firmanın ana tablolarından edinildiği için çekilen 3 kategori aşağıda belirtilmiştir.

1. Müşteri verileri (cinsiyet, segment, doğum günü vb.)
2. Mağaza bilgileri (mağaza bölgesi, ili vb.)
3. Müşteri alışveriş geçmişi (mağaza, kategori vb.)

Çizelge 3.1 : Müşteri verileri.

No	Değişkenler	Açıklama	Ölçek
1	moneykartno	Müşterilerin Money kart numarası	Sürekli
2	dogumtarihi	Müşterinin doğum tarihi bilgisi (yıl-ay-gün)	Tarih
3	cinsiyet	Müşterinin Cinsiyeti	Nominal
4	deger_segment_no	Müşterinin segment no'su	Sürekli
5	deger_segment_tanim	Müşterinin segment no açıklaması	Nominal

Çizelge 3.2 : Mağaza bilgileri.

No	Değişkenler	Açıklama	Ölçek
1	moneykartno	Müşterilerin Money kart numarası	Nominal
2	Magazano	Müşterinin alışveriş yaptığı mağaza no'su	Sürekli
3	sube	Müşterinin alışveriş yaptığı mağazanın bölge bilgisi	Nominal
4	format	Müşterinin alışveriş yaptığı mağaza format bilgisi	Nominal

Çizelge 3.3 : Müşteri alışveriş geçmişi.


No	Değişkenler	Açıklama	Ölçek
1	moneykartno	Müşterilerin Money kart numarası	Nominal
2	Kategori	Müşterinin aldığı ürünün kategorisi	Nominal
3	Satış miktar	İlgili kategoride müşterinin aldığı ürünün miktarı	Sürekli

Çalışma boyunca oluşturulan tüm veriler yukarıda bahsedilen ana verilerden oluşturulmuştur. Diğer bölümde oluşturulan değişkenler ve formülasyonlarından bahsedilecektir.

3.1.2 Ham veriden değişken oluşturma

Bir önceki bölümde bahsedilen ham veriler firmanın milyonluk müşteri datasını içermektedir. Hem gerçek verideki karmaşıklığı gidermek hem de 2020'deki pandemi etkisini ayırt ederek bu etkiden çıkmak için çeşitli değişkenler oluşturulmuştur.

Müşterilerin pandemi sebebi ile alışveriş yaptığını net şekilde görebilmek adına sadece tüm yılların ikinci çeyrekte bulunan alışverişlerine bakılmıştır (Şekil 3.1).



Şekil 3.1 : Çeyrek Dilimi

İkinci çeyrek müşteri verileri ayıklandıktan sonra, sayılardan arındırmak için oranlar oluşturulmuştur. Bu oranlar için müşterilerin fiziksel mağazadan ve sanal kanaldan yaptığı alışveriş sayıları çıkartılmıştır. Her yıl için önce sanal alışveriş sayısı, toplam alışveriş sayısına bölünerek kendi yılının oranı bulunmuştur. Sonrasında yılların birbirine oranı alınarak yeni değişkenlerin bir kısmı oluşturulmuştur (Çizelge 3.4).

Çizelge 3.4 : Alışveriş sayılarından çıkartılan yeni değişkenler

No	Değişkenler	Açıklama	Ölçek
1	2020/2019	2020 yılının sanal alışverişin toplama oranının 2019'daki sanal alışverişin toplama oranına bölünmesi	Sürekli
2	2021/2020	2021 yılının sanal alışverişin toplama oranının 2020'deki sanal alışverişin toplama oranına bölünmesi	Sürekli
3	2022/2021	2022 yılının sanal alışverişin toplama oranının 2021'deki sanal alışverişin toplama oranına bölünmesi	Sürekli
4	Toplam Alışveriş_19	Müşterinin 2019 yılındaki toplam alışveriş sayısı (fiziksel+sanal)	Sürekli
5	Toplam Alışveriş_20	Müşterinin 2020 yılındaki toplam alışveriş sayısı (fiziksel+sanal)	Sürekli
6	Toplam Alışveriş_21	Müşterinin 2021 yılındaki toplam alışveriş sayısı (fiziksel+sanal)	Sürekli
7	Toplam Alışveriş_22	Müşterinin 2022 yılındaki toplam alışveriş sayısı (fiziksel+sanal)	Sürekli

İkinci adım olarak müşterinin alışveriş yaptığı kategoriler üzerinde çalışılmıştır. İncelenen veride toplamda 77 ürün kategorisi bulunmaktadır. Bu kategorik değişkenler

sütun haline getirilerek her kategori için müşterinin satın aldığı ürün miktarı yazılmıştır.

Son olarak müşterinin alışveriş geçmişi verisi incelenmiştir. Bu veri üzerinden alışveriş yapılan il, bölge ve mağaza formatının her biri bir sütun haline getirilerek yapılan alışveriş sayısı yazılmıştır.

Yapılan analizlerin sonuçları gösterilirken firma gizliliği sebebi ile rakamlar gizlenerek gösterilmiştir.


3.2 Tanımlayıcı İstatistiksel Analizler

Tanımlayıcı istatistik, verilerin elde edilmesi ve yorumlanması konusundaki istatistiki yöntemlerden bir tanesidir. Bu yöntem, bir veri kümesinin aykırı değerlerini, dağılımını ve eğilimini incelemek üzere her alanda kullanılmaktadır (Altınöz 2013). Çalışmanın bu bölümünde, tanımlayıcı istatistik yöntemleri kullanılarak veri kümesinin temel özellikleri özetlenecektir.

İki kısma ayrılan bölümde verinin genel özellikleri ve veri temizleme işlemlerinden bahsedilecektir. Son bölümünde ise verinin geldiği son hali ile ilgili bilgi verilecektir.

3.2.1 Müşteri örüntüleri, alışveriş sayıları, cinsiyet ve doğum yılı

Verilerin gözden geçirilmesi için Jupyter Lab kullanılarak python ile analiz yapılmıştır. Çekilen aralıkta veri temizleme yapmadan önce 50.000'in üzerinde müşteri verisi bulunmaktadır. Çıkarılan değişkenlerden yıl oranları incelenerek müşteri alışverişlerinden 4 örüntü bulunmuştur (Şekil 3.2).



Şekil 3.2 : Müşteri örüntüleri.

İlk grafikte müşterinin alışveriş oranlarının sürekli arttığı görülmektedir. Burada istenilen bir senaryo olarak görülmektedir. Müşterinin başka bir kanaldan alışveriş


yapıyorsa bu kanala göçtüğü farz edilmektedir. Bu müşterilerin oranı %4'tür. Uzun vadede bu oranın artacağı müşteriler elde tutulmak istenmektedir. İlerleyen analizlerde bu örüntü için “1” etiketi yazılmıştır.

İkinci grafikte ise, 2021 yılında diğer yıllara göre daha çok alışveriş yapan müşterileri görüyoruz. Bunların oranı %30'dur. Müşterinin 2019 ve 2021 yıllarındaki alışverişinin daha fazla olması pandemi etkisi ile ilgili olmadığını göstermektedir. Fakat yine de 2022 yılında müşterinin alışveriş sayısı düşmüştür. Bu müşteriler birinci grafikteki müşterilere göre firma tarafından ihmal edilip kaçırılan müşteriler olabilir. Kanal göçü olmadan müdahale edilecek müşteri olarak nitelendirilebilir. İlerleyen analizlerde bu örüntü için “0” etiketi yazılmıştır.

Üçüncü grafikte ise belirli bir dönemde alışverişini azaltıp sonra tekrar sanal kanala dönen müşteriler görülmektedir. Bunların oranı %26'dır. Müşterinin 2020 yılındaki alışverişinin fazla olması pandemi etkisi ile olduğunu işaret etmektedir. 2021 yılında alışveriş sayısı düşmüş olsa da sonunda 2022 yılında 2021'e göre tekrar arttığı görülmektedir. Bu müşterilerin kanal göçü kesin olmamakla birlikte çok dengeli olmadığı görülmektedir. İlerleyen analizlerde bu örüntü için “2” etiketi yazılmıştır.


Dördüncü grafikte ise alışveriş sayısı git gide azalan müşteriler görülmektedir. Bunların oranı %38'dir. Bu müşteriler pandemi etkisi ile 2020 yılında diğer yıllara göre fazla alışveriş yapmıştır. Sonrasında yıl geçtikçe alışveriş sayıları düşmüştür. Bu müşteriler için başka kanala göç yaptığı veya yapacağı söylenebilir. Bu tarz müşterileri elde tutmak için ayrı bir strateji gerekmektedir. İlerleyen analizlerde bu örüntü için “3” etiketi yazılmıştır.

Bu örüntüler dışında müşterilerin yıllara göre alışveriş oranları incelenmiştir. Oldukça fazla dışa düşen veri bulunmaktadır (Şekil 3.3).



Şekil 3.3 : Yıllara göre müşteri alışveriş sayılarının dağılımı.


Veride düzenlemeler yaptıktan sonra dışa düşen noktalar azalmıştır (Şekil 3.4). Buna ek olarak yıllara göre müşteri alışveriş sayılarında artış gözlemlenmektedir.




Şekil 3.4 : Dışa düşen noktaların çıkarılması ile alışveriş sayıları.

Ayrıca müşterilerin doğum yılı için inceleme yapılmıştır (Şekil 3.5). Bulunan boş veriler verideki doğum yılı parametrenin medyanı ile doldurulmuştur. Ayrıca, yanlış ve dışa düşen noktalar veri setinden çıkartılmıştır.

Tespit edilen örüntüler bazında herhangi bir fark bulunmadığı görülmektedir (Şekil 3.6). Tespit edilen örüntüler bazında herhangi bir fark bulunmaması, analiz edilen veri setindeki müşteri davranışlarının birbirine benzer olduğunu ve istatistiksel olarak anlamlı bir ayrımın olmadığını göstermektedir.




Şekil 3.5 : Örüntülere göre doğum yılının dağılımı.



Şekil 3.6 : Düzenlemeler sonucu örüntülere göre doğum yılının dağılımı.

Veriye cinsiyet parametresi tarafından bakıldığında, belirlenen müşteri örüntüleri arasında cinsiyetler arasında bir fark görülmemektedir (Şekil 3.7).



Şekil 3.7 : Cinsiyet bazında örüntüler arası değişim.

3.2.2 Ürün kategorisi ve alışveriş yapılan il verileri

Daima Daha İyi Kontrol (Always Better Control)" prensibi, verimliliği artırmak ve daha iyi kararlar almak için genellikle yönetim, ekonomi ve işletme alanlarında kullanılan Pareto İlkesi'nden türetilen bir yaklaşımdır. Pareto İlkesi, birçok durumda sonuçların yaklaşık olarak %80'inin nedenlerin %20'si tarafından üretildiğini ifade etmektedir. ABC analizi ise stokların sınıflandırılması ve yönetimi için yaygın olarak kullanılan bir tekniktir. ABC analizi, stok kalemlerinin maliyetlerini belirleyerek, stoklar üzerinde yapılan harcamaların içinde her bir stok kaleminin kümülatif oranını

dikkate alarak sınıflandırma yapar. Bu sınıflandırma sonucunda stoklar, A, B ve C olmak üzere üç gruba ayrılır.(Korkmaz & Güner, 2022).

Bu çalışmada, ABC analizi ürünlerin satış miktarlarına göre kategorilerin ve alışveriş sayılarına göre illerin A, B ve C şeklinde önem sıralamasına konulması istenmiştir. Tüm matematiksel işlemler python ortamında kodlanmıştır. Analizin çıktısı olarak %80 ve üzeri A kategorisi, %15 oranı B ve kalan %5 oran C olarak sınıflandırılmıştır.

Sonuç olarak, kategori bazında toplamda 30 kategori A ve B sınıfına girmiştir (Çizelge 3.5). Bu veriler yeni bir parametre olarak eklenmiştir. İl bazında ise A ve B kategorisine giren sayı 17'dir (Çizelge 3.5). Aynı şekilde yeni parametreler olarak veriye eklenmiştir. Bu sayede, sınıflandırma yapılırken öncelikli olanlar tercih edilmiştir.

Çizelge 3.5 : Kategori ve il bazında ABC analizi sonuçları.


Sınıf	Kategori Sayısı	İl Sayısı
A	15	4
B	15	13
C	47	64

3.2.3 Verinin son durumu

Son durumda dışa düşen noktalar çıkarıldığında ve boş veriler doldurulduğunda toplamda 20.000'in üzerinde müşteri verisi bulunmaktadır. Değişkenlerin korelasyonuna bakıldığında toplam alışveriş sayılarını yıl bazında yazılanlar arasında yüksek korelasyon olduğu (>0.5) görülmüştür. Bu değişkenlerin ortalaması alınarak veriye eklenmiştir ve yıl bazında olan değişkenler kaldırılmıştır.


Bunlara ek olarak belirli kategorilerde yüksek korelasyon yakalanmıştır. Bu kategori değişkenleri de veriden çıkartılmıştır. Verinin temel bileşen analizine tabii tutulacak son halinde 47 değişken bulunmaktadır.

Son durumda dışa düşen noktalar çıkarıldığında ve boş veriler doldurulduğunda örüntü bazında ulaşılmıştır (Şekil 3.8). Örüntülere göre müşteri sayısı ise sırası ile; %5, %34, %24 ve %35'tir.



Şekil 3.8 : Veri temizleme sonucu örüntüde son durum.


Alışveriş sayıları yıllara göre histogram olarak incelendiğinde öncelikle her yıl için alışveriş sayılarının küçük değerlere yoğunlaştığı yani sol eğilimli olduğu görülmektedir (Şekil 3.9). Yıllar ilerlediğinde ise bu sola eğilimin biraz daha azaldığını gözlemlemekteyiz. Yani yıl içinde müşterilerin toplam alışveriş sayısının arttığı söylenebilir.



Şekil 3.9 : Toplam alışveriş sayısının yıllara göre dağılımı.


Bu sayıların sadece sanal kanal için incelendiğinde, yine benzer bir sola yatıklık görülmektedir (Şekil 3.10). Ayrıca bu toplam alışverişe göre alışveriş sayılarının daha fazla olduğu görülmektedir. 2022'ye geldiğimizde bu yatıklık biraz da olsa azaldığı görülebilmektedir. Genel olarak bakıldığında ise yıllara göre sanal kanalında alışveriş sayılarının arttığı görülmektedir.

Bu eğilimin arkasında, teknolojiye ileriye gidenlerin ve dijital ticaretin yaygınlaşmasının etkisi olduğu düşünülmektedir. İnternetin ve mobil cihazların kullanımının artmasıyla birlikte, tüketicilerin online alışveriş yapma eğilimleri de artmıştır. Sanal kanal, tüketicilere daha kolay ve uzun saatler erişim imkanı sunması ve geniş ürün yelpazesine sahip olması nedeniyle tercih edilmektedir.




Şekil 3.10 : Sanal alışveriş sayısının yıllara göre dağılımı.

Şubelere göre alışveriş sayısı incelendiğinde belirli bir bölgede alışveriş sayısının çok fazla olduğu görülmektedir (Şekil 3.11). Alışveriş sayısı değeri için yıllık toplam alışveriş sayılarının müşteri bazında ortalamaları alınıp toplanmıştır.



Şekil 3.11 : Bölgelere göre ortalama alışveriş sayısı.

Analizin son adımında mağaza formatı bazında alışveriş sayısına bakılmıştır. Alışveriş sayısı değeri için yıllık total alışveriş sayılarının müşteri bazında ortalamaları alınıp toplanmıştır. Formatlara bakıldığında görüldüğü üzere belirli bir tanesinde daha yüksek alışveriş gözükmemektedir (Şekil 3.12).



Şekil 3.12 : Formata göre ortalama alışveriş sayısı.

3.2.4 Temel bileşen analizi (PCA)

Temel Bileşen Analizi, çok parametre bulunan veri setleri için kullanılmaktadır. Veri setindeki değişken sayısını azaltarak optimum değişken ile veriyi açıklayabilmeyi amaçlar. Bunun için, parametreler arasındaki ilişkiye bakarak yeni değişkenler oluşturur. Oluşturulan değişkenler daha az sayıdadır ve verisetinin değişken boyutunu minimize etmektedir.

Yeni oluşturulan değişken veya parametreler temel bileşen olarak ifade edilmektedir. Bu temel bileşenler veri seti arasındaki ilişkiyi en iyi şekilde anlatan lineer kombinasyonlardan oluşmaktadır. Sonrasında değişkenlerin varyansını büyükten küçüğe sıralayarak veri setinin daha az parametre ile anlamlandırılmasını sağlamaktadır. Temel Bileşen Analizi'nin adımları aşağıdaki sıralama ile açıklanır:


1. Standartlaştırma: Veri setindeki tüm değişkenler standartlaştırılır. Bunun anlamı tüm veriler 0-1 arasında dönüştürülmesidir.
2. Kovaryans matrisinin hesaplanması: Oluşturulan veri setinde parametreler arası kovaryans matrisi hesaplanır. Bunun için tüm değişkenler arasındaki kovaryanslar hesaplanarak matris haline getirilir.
3. Kovaryans matrisinin özdeğerleri ve özvektörlerinin hesaplanması: Oluşturulan matrisin özdeğerleri hesaplanarak açıklanabilen toplam varyans gösterilir. Özvektörlerin hesaplanması ile birlikte de temel bileşenlerin yönü belirlenir.
4. Seçim: Özdeğerler büyükten küçüğe sıralanır. Belirli bir toplam varyanstaki k parametre seçilir.
5. Veri setinin hazırlanması: bir önceki adımda seçilen k adet parametre için veri seti oluşturulur.

Belirtilen adımlar kullanılarak veri seti oluşturulmaktadır. Az sayıda bileşenle veri setindeki gürültü azalmış olur. Bu sayede daha anlamlı çıktılar elde edilebilir (Jolliffe, 2002).

Bu bölümde, çok değişken bulunan müşteri verisine temel bileşen analizi uygulanmıştır. Bu analiz ilerleyen bölümlerde bahsedilmiştir. Yeni oluşturulan veri, kümeleme algoritmalarında kullanılacaktır.

3.2.4.1 Temel bileşen analizi sonuçları


Temel Bileşen Analiz yönteminin kullanılması için ilk olarak veri standartlaştırılmıştır. Bunun için Python'ın "Sklearn" kütüphanesindeki "MinMaxScaler" fonksiyonu kullanılmıştır. Sonrasında analiz yine Python ortamında uygulanmıştır. Belirtilen grafiklerde değişkenlerin açıklanabilen varyans ve kümüle varyansı görülmektedir (Şekil 3.13).



Şekil 3.13 : Temel bileşen analizi sonucundaki varyanslar.

Grafiklerden görüldüğü üzere ilk üç değişken veriyi yaklaşık %20'şer açıklamaktadır. Sonraki değişkenler, veriyi açıklamada %10'un altına inerek küçük küçük devam etmektedir. %80 varyansdan sonra değişkenlerin veriyi açıklama oranı çok düşmüştür. Değişkenlerin sonuna doğru bakıldığında 60'ıncı değişkenden itibaren verinin kümülatif varyansı %100'e ulaşmaktadır.

Şekil incelendikten sonra verideki çok sayıdaki değişken yerine; %80 kümülatif varyans kabul edildiğinde 4 değişken ile açıklanabilmektedir (Şekil 3.14). Benzer şekilde %85 varyans kabul edildiğinde 5 değişken ile veri açıklanabilir. %90 varyans ile 7 değişken ile veri açıklanabilmektedir. Son olarak, %95 kümülatif varyans kabul edildiğinde 16 değişken ile veri seti oluşturulabilmektedir.



Şekil 3.14 : Kümülatif varyans değerlerine göre kullanılacak değişken sayısı.

Bu çalışma kapsamında, tüm uygulanan kümeleme modelleri için kümülatif varyansın %80, %85, %90 ve %95 olarak ayrı ayrı hesaplamalar yapılmıştır ve bu hesaplamalara göre değişken sayısı oluşturulmuştur. Bir sonraki bölümlerde bu sonuçlara değinilecektir.

3.3 Kümeleme Modelleri ve Küme Sayısının Tespiti

Kümeleme algoritmaları, verileri gruplandırmak için kullanılan bir tekniktir. Benzer özellikteki noktaları bir araya getirerek gruplar oluşturulur (Xu & Wunsch, 2005). Aynı zamanda, analizlerde benzer verileri tanımlayarak daha anlamlı sonuçlar türetmek için kullanılan bir veri analizi tekniğidir. Veriyi kümelemeyi sağlayan bu algoritmalar birçok farklı disiplinde kullanılır. Perakende, biyoinformatik, ekonomi, mühendislik, tıp ve sosyal bilimler ve daha fazlası. Bu bilgiye ek olarak kümeleme algoritmaları müşteri segmentasyonu, pazarlama stratejileri, tıbbi teşhis, imaj analizi ve web sayfası kategorizasyonu gibi konularda kullanılmaktadır. Bu sebeple kritik makine öğrenmesi kategorilerinden biridir (Jain vd., 2008).

Kümeleme için kullanılan algoritmalar birden fazladır ve farklı yaklaşımlar ile çalışmaktadır. Bunlar:

1. Hiyerarşik kümeleme
2. K-ortalama
3. Yoğunluk tabanlı kümeleme

Hiyerarşik kümeleme yönteminde, veri setindeki her nokta bir küme olarak kabul edilir. Algoritma bu şekilde başlar. Sonrasında belirli kriterlere göre bu kümeler birleşerek yeni kümeler oluşturur (Tan vd., 2006).

K-ortalama algoritması ise önceden belirlenen bir küme sayısına göre verileri gruplandırır. Her bir küme için merkez bir nokta seçer ve tüm verilerin yakınlık matrisine göre en yakın kümeye atar. Her bir atama işleminden sonra merkez tekrar hesaplanarak tüm işlemlere devam edilir (Saeed vd., 2018).

Yoğunluk tabanlı kümeleme algoritması, tüm verilerin yoğunluğuna bakarak bir gruplandırma yapmaktadır. Bunun için yoğunluğu yüksek veya düşük olanlar ayrı küme kabul edilerek gruplandırma gerçekleştirilir (Xu & Wunsch, 2005).

Çalışmanın bu bölümünde, oluşturulan veri için kümeleme modelleri Temel bileşen analizi kullanılarak 4 farklı varyans ile oluşturulan veri grupları bazında denenmiştir. Her bir veri için K-ortalama, Yoğunluk tabanlı kümeleme algoritması (DBSCAN) ve Birleştirici hiyerarşik kümeleme algoritması (Agglomerative) yöntemleri kullanılmıştır. Küme sayısı, elbow metot ve Silhoutte skor yardımı ile bulunarak belirtilen 3 algoritma ile 4 çeşit varyansa sahip veri grubunda denenmiştir. Sonrasında sonuçları toparlanılarak hem kendi içlerinde hem de müşterilerin alışveriş örüntüleri bazında incelemeler yapılmıştır.

3.3.1 Küme sayısının tespiti

Kümeleme algoritmalarının en büyük dezavantajlarından biri küme sayısının önceden girilmesidir. En optimum küme sayısının bulunması için farklı metotlar mevcuttur. Bu metotlar sayesinde en iyi küme sayısı bulunarak kümeleme analizi yapılmaktadır. Makine öğrenmesi yöntemlerinde K-Ortalama algoritması için Elbow ve Silhoutte skor yöntemleri sıkça kullanılan yöntemlerdir.

Çalışmada bu iki yöntem optimum küme sayısını belirlemek için kullanılmıştır. İlerleyen bölümlerde sonuçlarından bahsedilecektir.

3.3.1.1 Elbow metodu

Kümeleme algoritmasında optimal küme sayısının tespiti için kullanılan yöntemlerden biri Elbow yöntemidir. Yöntemi özetlemek gerekirse, “WCSS” adı verilen bir yöntem kullanılarak kümeleme kalitesi ölçülür. WCSS, veri noktalarının kendi merkezleri arasındaki mesafelerinin kareleri toplamıdır. Bu değere göre optimal küme sayısı

belirlenir. Küme sayısı arttıkça WCSS değeri azalmaktadır. Çünkü küme merkezi arasındaki mesafe azalır. Fakat, belirli bir noktadan sonra bu azalma düşmektedir.

WCSS değeri hesaplandıktan sonra küme bazında bir çizgi grafiği çizilir. Bu grafikte bir kırılma başka bir değişle dirsek noktası aranır. Bu nokta optimal küme sayısını göstermektedir. Veriye göre bu nokta birden fazla da olabilmektedir. Bu durumda başka yöntemler ile sağlama yapmak gerekir (Ketchen & Shook, 2011).

3.3.1.2 Silhoutte skor

Kümeleme algoritmaları için optimal küme sayısının bulunmasını sağlayan yöntemlerden bir diğeri Silhoutte skordur. Aslında bu yöntem, kümeleme algoritmalarının performansını değerlendirmek için kullanılan bir ölçüt olarak ortaya çıkmıştır (Rousseeuw, 1987). Silhoutte ile, verilerin kendi kümeleri ile uyumu ölçülebilir. Buna ek olarak diğer kümeler arasındaki uyumuna da bakılır (Kaufman & Rousseeuw, 2009).

Silhouette skoru -1 ile 1 arasında değişmektedir. 0 ile 1 arasındaki değerler doğru kümelemeye işaret ederken -1 ile 0 arasındaki değerler ise yanlış kümelemeyi işaret etmektedir. Silhouette skoru hesaplamak için;

İlk olarak, $a(i)$ ve $b(i)$ değerleri hesaplanır. ($a(i)$ = her veri için kendi kümesindeki benzerlik / $b(i)$ = verinin diğer kümelere uzaklığı)

$$s(i) = (b(i) - a(i)) / \max(a(i), b(i)) \quad (3.1)$$

Sonrasında, Denklem 3.1’de belirtilen formül ile verinin Silhouette skoru ortaya çıkar. $s(i)$ değeri, verinin kendi kümesinde ne kadar iyi yerleştirildiğini gösterir. Sonuçta, en yüksek skorlu küme seçilir (Rousseeuw, 1991).

Skorlar belirlendikten sonra bir tablo veya grafik yardımı ile görselleştirerek kolayca karar verilebilmektedir.

3.3.2 K-Ortalama algoritması

K-Ortalama algoritması, makine öğrenmesi kümeleme modellerinde ve veri madenciliği yöntemlerinde sıkça kullanılan bir yöntemdir (Hastie vd., 2009). K-Ortalama ile veri kümesindeki satırların mesafelerine göre benzerlikleri çıkartılır ve yakınlıklarına göre kümelere bölünür. Algoritmanın tarihçesini incelediğimiz zaman

K-Ortalama algoritması, 1957 yılında Stuart Lloyd tarafından keşfedilmiştir. Fakat, modelin geliştirilmiş hali James MacQueen ve Edward W. Forgy tarafından tanımlanmıştır.

Algoritma adımlarında ilk olarak bir merkez nokta belirlenir. Bu merkez nokta genellikle rastgele seçilir. Bir adım sonra her nokta en yakınında bulunan kümeye atanır. Sonrasında kümenin merkezi tekrar hesaplanır. Tüm veriler en yakın kümesine atandığında tamamlanır.

Algoritmanın çok avantajı olmasına rağmen bazı dezavantajları da mevcuttur. Örneğin, küme sayısı önceden belirlenmektedir. Küme sayısının yanlış belirlenmesi analizi etkilemektedir. Ek olarak, küme merkezinin doğru seçilmemesi durumunda yanlış sonuca götürülebilir.

K-Ortalama algoritması, verideki benzer özellikleri bir araya getirdiğinden özellikleri daha açık şekilde görülmesi sağlayabilir. Ek olarak algoritma, görüntü işleme, ses işleme, biyoinformatik ve sosyal ağ analizi gibi birçok farklı alandaki çalışmalarda tercih edilmektedir (Jain vd., 1999).

3.3.2.1 K-Ortalama algoritma sonuçları

K-ortalama algoritması dört farklı varyansla oluşturulan veri setlerinde uygulanmıştır. Varyanslar, veri noktalarının dağılımını ve benzerliklerini değiştirmek için kullanılan parametrelerdir. Her bir varyans için farklı bir veri seti oluşturulmuş ve K-ortalama algoritması bu veri setlerine uygulanmıştır.


Uygulama aşamasında, küme sayısı farklı değerlerle deney edilmiştir. Bu çalışmada, 12 farklı küme sayısı denenmiştir. Her bir küme sayısı için K-ortalama algoritması uygulanmış ve sonuçlar değerlendirilmiştir. Bu değerlendirme için Silhoutte skoru kullanılmıştır. Silhoutte skoru hem küme sayısının belirlenmesinde hem de kümelemenin sonuçlarını değerlendirmede kullanıldığı önceki bölümlerde bahsedilmiştir.

K-ortalama algoritması uygulandıktan sonra skorlar incelenmiştir. Sonuçlara göre çıkan değerler, 0,20 ve 0,53 arası değişmektedir (Çizelge 3.6). Skorun pozitif olması önceki bölümde anlatıldığı gibi iyi bir kümeleme modeline işaret etmektedir. Negatif olması ise, kötü bir kümelemeye işaret etmektedir. K-Ortalama algoritması için en iyi model %80 varyans ve küme sayısı 4 olarak görünmektedir.

Çizelge 3.6 : Küme ve varyansa göre modellerin silhoutte skoru.


Küme Sayısı (k)/Varyans	0,8	0,85	0,9	0,95
3	0,495	0,47	0,449	0,419
4	0,538	0,51	0,487	0,453
5	0,433	0,401	0,378	0,346
6	0,425	0,393	0,367	0,293
7	0,391	0,35	0,29	0,285
8	0,393	0,354	0,327	0,288
9	0,363	0,321	0,285	0,275
10	0,363	0,315	0,282	0,229
11	0,354	0,287	0,271	0,215
12	0,34	0,294	0,252	0,208

Ayrıca, %80 varyans için Elbow metot da denenmiştir. 4 noktası tam kırılma noktası olarak gözükmemektedir (Şekil 3.15).



Şekil 3.15 : Elbow metot sonucu.

Bir önceki bölümde müşterilerin örüntüleri açıklanmıştı. Bu örüntüleri K-Ortalama yöntemi ile çıkan sonuçlarda kıyaslanmıştır (Şekil 3.16). Bu örüntülerden alışveriş sayısı sürekli yükselen ve yükseldikten sonra düşen müşteri grupları 0 ve 1 şeklinde ifade edilmiştir ve K-Ortalama sonucunda 1 ve 3 kümesine konulmuştur. Bu müşterilerin benzer grupta olduğu görülmüştür. Alışveriş sayısı sürekli düşen ve düşüp yükselen müşteriler ise 0 ve 2 kümesine konulmuştur. 1 ve 3 kümelerinde bulunan müşteriler online kanala geçmeye daha uygun gözükmemektedir. Bu müşteriler için ayrı çalışmaların yapılması gerekmektedir. Diğer kümelerde bulunan müşteriler için müşteri kaybı yaşanmaması adına önleyici çalışmalar yapılması gerekmektedir.



Şekil 3.16 : K-Ortalama ve müşteri örüntü karşılaştırması

Geliştirilen bu model sayesinde yeni bir müşteri veya tamamen fiziksel kanaldan alışveriş yapan bir müşteri için önceden kümesini belirleyerek ona göre bir strateji geliştirilebilir. Bulunduğu kümenin örüntüsü ile de davranışları önceden tahmin edilerek kanal göçünü engelleyici tutundurma çalışmaları yapılabilir.

3.3.3 Yoğunluk tabanlı kümeleme algoritması (DBSCAN)

Yoğunluk tabanlı kümeleme algoritması (DBSCAN), bir veri setini yoğunluğuna göre kümelemeye dayanan bir yöntemdir. Bu algoritma, veride bulunan tüm noktaları yoğunluklarına göre kümelere ayırır. Verinin yoğunluğu belirli bir yarıçapta bulunan noktalar ile belirlenir. Yoğunlukları belirlenen veriler, eğer o yarıçaptaki yoğunluğu aşarsa, bu veri noktaları yeni bir küme yapmak üzere birleştirilir.

Bir veri noktasının yoğunluğunu hesaplamak için yoğunluk tabanlı kümeleme algoritması olan DBSCAN, iki bilgiye ihtiyaç duyar:

1. Bir küme merkezi çevresindeki yarıçap
2. Küme oluşturmak için minimum nokta sayısı.

Diğer algoritmalarda küme sayısını önceden belirlemek bir sorun teşkil ederken, yoğunluk tabanlı kümeleme algoritmasında ise yarıçap ve küme için minimum nokta sayısının önceden belirlenmesi bir dezavantaj oluşturmaktadır. Çünkü, bu parametrelerin doğru belirlenmesi oluşacak kümelemenin doğruluğu açısından

önemlidir. Ayrıca, veri kümesinin yoğunluk değişimlerine çok duyarlı olduğundan büyük veri setlerinde hesaplama karmaşıklıkları yaratabilmektedir.

DBSCAN algoritması, kümeleme yöntemleri içinde etkili bir yöntemdir. Ayrıca, birçok farklı alanda kullanılmaktadır. Bunlardan bazıları, görüntü işleme, tıp, pazarlama, coğrafi bilgi sistemleridir (Ester vd., 1996).

3.3.3.1 DBSCAN algoritma sonuçları


K-Ortalama algoritmasında olduğu gibi yoğunluk tabanlı kümeleme algoritması için de farklı parametreler ile 4 varyans için de Silhouette skor hesaplanmıştır. Skorlar 0,22 ve 0,46 arası değişmektedir (Çizelge 3.7). Yoğunluk tabanlı kümeleme algoritması için en iyi model %80 varyans ve parametreler (eps:0.4, minimum örneklem 7 veya 8) görülmektedir. Algoritmanın sonucu olarak küme sayısı 2 olarak oluşturulmuştur.

Çizelge 3.7 : Yoğunluk tabanlı kümeleme algoritması sonuçları.

eps-min örneklem	Varyans %80		Varyans %85		Varyans %90		Varyans %95	
	Skor	Küme Sayısı	Skor	Küme Sayısı	Skor	Küme Sayısı	Skor	Küme Sayısı
0.2-7	0,296	9	0,256	9	0,224	9	0,109	13
0.2-8	0,296	9	0,256	9	0,223	9	0,125	11
0.3-7	0,294	9	0,257	9	0,23	9	0,186	9
0.3-8	0,294	9	0,257	9	0,229	9	0,186	9
0.4-7	0,464	2	0,449	2	0,435	3	0,41	3
0.4-8	0,464	2	0,449	2	0,435	3	0,41	3

En iyi skorlu model çalıştırılarak sonuçları incelenmiştir. Belirlenen 2 kümede de müşteri örüntülerinin hepsinin bulunduğu görülmektedir (Şekil 3.17). Bu kümeler için ayrı stratejiler geliştirilmesi zor görülmektedir.

Bu durumda, müşteri örüntülerinin her iki kümede de bulunmasının anlamı, müşterileri genelde kampanya ile tutundurma yapıldığı olarak yorumlanabilir. İlgili ekiplerle konuşulduğunda da stratejilerinin kampanya üstüne olduğu öğrenilmiştir. Müşterilerin alışveriş sayılarını arttırmak için sürekli kampanya yapılmaktadır. Fakat, genel olarak bakıldığında bu yöntem ile farklı kümelere strateji geliştirilemeyeceği görülmektedir.



Şekil 3.17 : Algoritma sonucuna göre müşteri örüntüleri.

3.3.4 Birleştirici hiyerarjik kümeleme algoritması (Agglomerative)

Birleştirici hiyerarjik kümeleme algoritması, diğer algoritmalar gibi bir kümeleme algoritmasıdır ve benzer noktaları bir kümeye dahil etmek için kullanılır. Bu algortmada, yakınlıklarına göre veriler kümeler hale getirilir. Başlangıçta her nokta bir kümedir. Birbirine en yakın iki küme birleştirilerek yeni bir küme oluşturulur. Bu işlem optimum hale gelene kadar tekrar tekrar uygulanır.

Algoritmada, yakınlık ölçüleri için farklı yöntemler bulunmaktadır. Bunlardan en çok kullanılanlar şu şekildedir:

1. Tek bağlantı (single linkage)
2. Tam bağlantı (complete linkage)
3. Ortalama bağlantı (average linkage)

Tek bağlantı, belirlenen iki kümede birbirine en yakın veri noktalarının arasındaki mesafeyi bulur. Bu mesafe her küme için hesaplanır ve en yakın olanlar birleştirilir.

Tam bağlantı yöntemi, tek bağlantı yönteminden farklı olarak iki kümedeki en uzak iki veri noktasını seçer. Bu iki noktanın uzaklığını hesaplar. Tüm kümeler için bu mesafeler kullanılarak birbirine en yakın olan kümeler birleştirilir.

Ortalama bağlantı yöntemi ise, iki küme için, her kümenin kendi içinde tüm noktaların ortalamasını alır. Sonrasında, iki küme ortalamasının arasındaki mesafeyi hesaplar. Bu işlem tüm kümeler arasında yapıldıktan sonra yine en kısa mesafede bulunanlar birleştirilir.

Birleştirici Hiyerarjik Kümeleme Algoritması, küme sayısının önceden belirtilmek zorunda olmadığı için avantajlı olarak görünmektedir. Fakat, büyük veri setlerinde Agglomerative algoritmasının avantajları arasında, küme sayısı önceden belirtilmek zorunda değildir ve veri noktalarının birbirleriyle olan mesafeleri hesaplamak için yeterli veriye sahip olduğunda, yüksek doğrulukla sonuçlar üretebilir. Ancak, büyük veri setleri için yüksek doğrulukta bir kümeleme yapılmak isteniyorsa parametrelerin doğru seçilmesi önemlidir (Müller & Günnemann, 2017).

3.3.4.1 Birleştirici hiyerarjik kümeleme algoritma sonuçları

Birleştirici hiyerarjik kümeleme algoritmasının sonuçlarını aktarırken tüm parametreler ve yöntemler için ayrı ayrı sonuçlar çıkartılmıştır. Bunlar, varyans, küme sayısı ve tek bağlantı, ortalama ve tam bağlantı metot ve parametreleridir. Hepsisi için sonuçlar aktarılmıştır.

İlk olarak, tüm bakılan varyanslar arasından, %80 varyans sonuçlarında optimum küme sayısı bulunmuştur. En yüksek skor 0,52'dir. Buna ek olarak en yüksek skorda ortalama bağlantı yöntemi bulunmaktadır. Bu algoritma sonucuna göre de küme sayısı 5 olarak belirlenmiştir. (Çizelge 3.8).

Çizelge 3.8 : %80 varyans için sonuçlar.

Küme Sayısı (k)	Ortalama Bağlantı	Tek Bağlantı	Tam Bağlantı
2	0,464	0,464	0,091
3	0,442	0,443	0,287
4	0,433	0,429	0,187
5	0,525	0,504	0,263
6	0,503	0,361	0,396
7	0,503	0,351	0,34
8	0,439	0,313	0,318
9	0,343	0,294	0,281
10	0,312	0,293	0,253
11	0,308	0,293	0,255
12	0,291	0,289	0,248

Yukarıdaki sonuçlara benzer şekilde %85, %90 ve %95 için de tablolar aşağıda görüldüğü üzere çıkartılmıştır (Çizelge 3.9, Çizelge 3.10, Çizelge 3.11). Tüm varyans değerleri için sonuçlar incelenerek toparlanmıştır.

Çizelge 3.9 : %85 varyans için sonuçlar.

Küme Sayısı (k)	Ortalama Bağlantı	Tek Bağlantı	Tam Bağlantı
2	0,449	0,449	0,07
3	0,425	0,362	0,205
4	0,333	0,349	0,123
5	0,352	0,339	0,224
6	0,474	0,35	0,369
7	0,462	0,461	0,292
8	0,448	0,422	0,274
9	0,431	0,291	0,257
10	0,395	0,271	0,241
11	0,392	0,255	0,205
12	0,363	0,254	0,198


Çizelge 3.10 : %90 varyans için sonuçlar.

Küme Sayısı (k)	Ortalama Bağlantı	Tek Bağlantı	Tam Bağlantı
2	0,536	0,436	0,373
3	0,295	0,436	0,429
4	0,397	0,436	0,436
5	0,378	0,436	0,423
6	0,357	0,436	0,462
7	0,336	0,416	0,372
8	0,327	0,371	0,355
9	0,315	0,37	0,342
10	0,315	0,326	0,303
11	0,41	0,325	0,263
12	0,456	0,306	0,266

Çizelge 3.11 : %95 varyans için sonuçlar.

Küme Sayısı (k)	Ortalama Bağlantı	Tek Bağlantı	Tam Bağlantı
2	0,554	0,602	0,389
3	0,389	0,414	0,412
4	0,364	0,414	0,404
5	0,338	0,411	0,402
6	0,293	0,408	0,41
7	0,284	0,408	0,281
8	0,238	0,408	0,281
9	0,238	0,408	0,281
10	0,208	0,405	0,281
11	0,368	0,394	0,24
12	0,361	0,389	0,24

Tüm sonuçlar incelendiğinde en yüksek skor %95 varyans, tek birleşme ve küme sayısı 2'yi işaret etmektedir. Bu parametreler ile algoritma çalıştırılıp sonuçları toparlanılmıştır. Müşteri örüntüleri bazında bakıldığında algoritmanın en iyi skor veren kümeleme yöntemi uygulandığı halde tek bir kümede çok müşterinin toplandığı görülmektedir (Şekil 3.18). Bu yöntemde de pratik hayatta uygulandığında ilgili kişilere bir aksiyon aldirmek için yönlendirme yapılamamaktadır.



Şekil 3.18 : Algoritma sonucuna göre müşteri örüntüleri.

3.3.5 Autoencoder tabanlı Self-organizing map derin öğrenme modeli

Autoencoder, yapay sinir ağı temelli bir derin öğrenme modelidir. Bu model, girdi verilerini düşük boyutlu bir temsile dönüştürerek (encode) ve bu temsilden tekrar orijinal boyutlara dönüştürerek (decode) veriyi tekrar oluşturma işlemi gerçekleştirilmektedir. Autoencoder, hem boyut indirgeme işlevi hem de veri özelliklerini öğrenmek için kullanılmaktadır.

Goodfellow, Bengio ve Courville (2016) tarafından yazılan Deep Learning kitabında, autoencoder'ın yapısı ve kullanım alanları detaylı bir şekilde ele alınmıştır. Autoencoder, girdi verilerinin temsili öğrenmek için unsupervised learning yöntemi kullanılmaktadır. Bu sayede, veri setindeki özelliklerin model tarafından kendiliğinden öğrenilmesi sağlanmaktadır.

Autoencoder modeli, genellikle encoder kısmı ve decoder kısmı olmak üzere iki bölümden oluşur. Encoder kısmı, girdi verilerini düşük boyutlu bir temsile dönüştürür. Bu işlem sırasında verilerin boyutu azaltılır ve bu sayede veri setindeki fazla veri azaltılır. Decoder kısmı ise, bu düşük boyutlu temsili orijinal boyutlara geri dönüştürür ve girdi verilerinin yeniden oluşturulması sağlanmaktadır.

Autoencoder'ın en önemli avantajlarından biri, unsupervised learning yöntemi ile eğitilmesidir. Bu sayede, büyük veri setleri üzerinde çalışırken, insan müdahalesine gerek kalmadan veri özelliklerinin otomatik olarak öğrenilmesi mümkün hale gelmektedir. Autoencoder, boyut indirgeme, gürültü azaltma, veri analizi ve görüntü işleme gibi birçok alanda kullanılmaktadır.

Fully Connected Autoencoder (Dense Autoencoder), en temel autoencoder modellerinden biridir ve birçok uygulamada kullanılmaktadır. Bu model, encoder ve decoder olmak üzere iki ana bölümden oluşur ve tamamen bağlı katmanlardan (Dense Layer) oluşan bir yapısı vardır.

Bu modelde, girdi verileri önce bir encoder ağına beslenir. Encoder ağı, girdi verilerini daha düşük boyutlu bir temsil şekline dönüştürür. Daha sonra, elde edilen düşük boyutlu temsil decoder ağına beslenir ve decoder ağı, orijinal veri boyutuna geri dönüştürmektedir (Goodfellow vd., 2016).

Dense Autoencoder, verilerin boyutunu azaltmak ve gürültüden arındırmak için kullanılabilir. Ayrıca, verilerin özelliklerini öğrenmek için de kullanılabilir. Bu özellikler sayesinde, verilerin sınıflandırılması, kümeleme ve diğer birçok makine öğrenmesi işleminde kullanılabilir (LeCun vd., 2015).

Dense Autoencoder, birçok uygulamada kullanıldığı gibi, özellikle yüz tanıma, görüntü işleme ve doğal dil işleme gibi alanlarda oldukça popülerdir (Bengio vd., 2013). Bu modelde de Dense Autoencoder kullanılarak ilerlenmiştir.

SOM (Self-Organizing Map), unsupervised öğrenme yöntemleri arasında yer alan ve veri kümesindeki örnekler arasındaki benzerlikleri ortaya çıkaran bir yapay sinir ağıdır (Kohonen, 1990). SOM modeli, verilerin yüksek boyutlu uzayında gösterildiği bir harita oluşturur ve benzer örneklerin birbirine yakın bölgelere yerleştirildiği bir topolojik yapıya sahiptir. Bu yapı sayesinde, veri kümesindeki örnekler arasındaki benzerlikler ve farklılıklar daha iyi anlaşılmaktadır.

SOM modeli, özellikle veri görselleştirme, veri sıkıştırma, veri öncesi işleme ve kümeleme gibi birçok alanda kullanılmaktadır (Kohonen, 1990). SOM modeli, verilerin boyutunu azaltarak veri sıkıştırma yapılıdır. Ayrıca, benzer örneklerin bir arada olduğu bölgeleri belirleyerek kümeleme yapılır. SOM modeli ayrıca, veri görselleştirme işlemleri için kullanılmaktadır. SOM modeli, özellikle görüntü işleme ve doğal dil işleme gibi alanlarda sıklıkla kullanılmaktadır.


Bu çalışmada, iki derin öğrenme yöntemi bir araya getirilerek Autoencoder tabanlı Self-organizing map (SOM- kendi kendini organize eden özellik haritası) derin öğrenme modeli kullanılmıştır. Sonuçları bir sonraki bölümde paylaşılarak literatüre katkı sağlanmıştır.

3.3.5.1 Autoencoder tabanlı Self-organizing map (SOM- kendi kendini organize eden özellik haritası) derin öğrenme modeli ve sonuçları

Çalışmanın bu bölümünde, derin öğrenme yöntemleri ile kümeleme yöntemi kullanılmıştır. Sırasıyla aşağıdaki işlemler gerçekleştirilmiştir.

1. Veriler, pandas kütüphanesi kullanılarak içe aktarılmıştır ve ardından sklearn.preprocessing kütüphanesinden MinMaxScaler kullanılarak ölçeklendirilmiştir.
2. MiniSom kütüphanesi kullanılarak orijinal veriler üzerinde SOM eğitilir. SOM'daki her girdi vektörünün kazananları, pozisyonuna göre etiketlenir.
3. Otokodlayıcı sinir ağı, sırasıyla 64, 32 ve 16 nöron içeren üç yoğun katmanlı bir kodlayıcı ve 32, 64 ve giriş nöronlarının sayısı olan üç yoğun katmanlı bir dekode içeren bir yapıda tanımlanır.
4. Adam optimizör ve kayıp için MSE (Mean-Squared Error) ile derlenen model kullanılarak orijinal veriler üzerinde otokodlayıcı eğitilir.
5. Verilerin özdeş temsili, orijinal verilerin kodlayıcı modelinden geçirilerek elde edilir.
6. MiniSom kütüphanesi kullanılarak verilerin özdeş temsili üzerinde SOM eğitilir. SOM'daki her girdi vektörünün kazananları, pozisyonuna göre etiketlenir.
7. Orijinal veriler üzerinde eğitilmiş SOM'dan elde edilen etiketler ve verilerin özdeş temsili üzerinde eğitilmiş SOM'dan elde edilen etiketler yazdırılır.
8. Tüm bu süreç aşağıdaki parametreler ile denenerek sonuçlar toparlanmıştır.
 - Epoch değeri için 25, 50, 100, 150, 250, 500 denenmiştir.
 - Sigma parametresi için 0.8, 0.9, 0.95, 1.0 değerleri denenmiştir.
 - Learning rate parametresi için, 0.5, 0.05, 0.01 denenmiştir.
 - Batchsize değeri için 32, 64, 128, 512 değerleri denenmiştir.

Autoencoder tabanlı SOM algoritma sonuçları incelendiğinde, en düşük MSE değeri (epoch:500, sigma:0,8, learning rate:0.01, batchsize:32) parametreleri ile 0,013225 olarak elde edilmektedir. En küçük küme sayısı 70 olarak çıkmıştır. Bu da (epoch:25, sigma:0,95, learning rate:0.5, batchsize:128) ile elde edilmektedir. En küçük kümeleme yönteminde veriler ve kümeleri incelenmiştir (Şekil 3.20).




Şekil 3.19 : Algoritma sonucuna göre müşteri örüntüleri.

Yapılan çalışmada, epoch, learning rate ve batchsize parametreleri bulunmaktadır. Sonuçlarda bu parametrelerin MSE'ye olan etkisi ölçümlenmiştir. Bunu yaparken ilk olarak dışa düşen noktalardan veri arındırılmıştır. Sonrasında, kutu grafiği yardımıyla tüm noktalar grafikler üzerinden incelenmiştir.


İlk olarak, batchsize parametresine bakıldığında arttıkça kaybın da arttığı görülmektedir. Bu sebeple modelde düşük kullanılması gerektiği sonucuna varılabilir (Şekil 3.21).

Diğer bir parametre olan epoch parametresi incelendiğinde arttıkça MSE değerinin düştüğü görülmektedir (Şekil 3.22). 100 ve sonrası arasında çok fark gözükmemektedir. Bu sebeple, sistemi kasmaması açısından 100 kullanmak faydalı olacaktır.


Son olarak, learning rate parametresi incelendiğinde ise aralarında büyük bir fark görülmemektedir. Bu sebeple herhangi biri kullanılabilir (Şekil 3.23).



Şekil 3.20 : Batchsize parametresine göre MSE değeri değişimi.



Şekil 3.21 : Epoch parametresine göre MSE değeri değişimi.



Şekil 3.22 : Learning rate parametresine göre MSE değeri değişimi.

Autoencoder tabanlı Self-organizing map derin öğrenme modeli müşterileri birçok farklı açı ile inceleyerek uygun kümelerle koymaktadır. Bu kümeler ile firmalar hepsine farklı stratejiler geliştirerek müşteri kanal göçünü firmanın lehine çevirecek kararlar alınabilir.

4. BULGULAR VE DEĞERLENDİRME

Müşteri kanal göçü, işletmelerin pazarlama faaliyetlerindeki önemli bir değişken olarak kabul edilmektedir. Günümüzde, teknolojinin hızlı gelişimi ve dijitalleşme süreci, müşterilerin kanal tercihlerinde de önemli bir değişim yaratmaktadır. Bu nedenle, işletmelerin müşterilerinin kanal tercihlerini takip etmeleri ve buna göre pazarlama stratejilerini belirlemeleri gerekmektedir.

Sonuçları toplamak gerekirse ilk adımda, tanımlayıcı istatistiksel analiz yöntemleri kullanarak eldeki veri incelenmiştir. Dışa düşen noktalar veya boş satırlar ilgili yöntemler ile düzeltilmiştir. Korelasyonu yüksek olan değişkenler yerine yeni değişkenler eklenmiş veya çıkartılmıştır. Sonrasında, veri temel bileşen analizine sokularak 4 farklı varyansta veri kümesi elde edilmiştir.

İkinci adımda, K-Ortalama, Yoğunluk Tabanlı Kümeleme ve Birleştirici Hiyerarjik Kümeleme algoritmaları, 4 farklı varyans değerindeki veri seti ile denemeler yapılmıştır. Bu denemeler sonucunda, tüm algoritmalar için skoru en iyi olan modeller tekrar çalıştırılıp sonuçları incelenmiştir. İncelemeler sonrası, K-Ortalama algoritmasının ürettiği sonucun, müşteri örüntülerine daha uygun olduğu ve müşteri kanal göçü açısından daha çok bilgi verdiği görülmektedir.

Üçüncü adımda, denenen 3 algoritmanın tüm sonuçları SPSS üzerinden istatistiksel analize tabi tutulmuştur. Denenen yöntem, varyans, skor ve küme sayısı için ANOVA uygulanmıştır. ANOVA uygulanmadan önce bağımlı değişken olan skor, normallik testine sokularak Kolmogorov-Smirnov sonuçlarına göre ($p=0.017$) değişkenin normal dağılımda olduğu görülmüştür.

ANOVA sonuçları incelendiğinde yöntem ve küme sayısının birlikte olduğu durumda fark görülmüştür ($p=0.044$). Hangileri olduğunu öğrenmek için Post Hoc test uygulanmıştır. Tukey testi sonuçlarına göre yöntem Yoğunluk Tabanlı Kümeleme ve Birleştirici Hiyerarjik Kümeleme algoritmaları arasında ($p=0.016$) ve ayrıca K-Ortalama ve Yoğunluk Tabanlı Kümeleme arasında ($p=0.039$) fark olduğu görülmektedir. Temel bileşen analizi ile 4 varyans şeklinde oluşturulan verinin

sonuçları incelendiğinde istatistiksel açıdan herhangi bir fark görülmemiştir. Tüm testlerin sonuçları Ek A 'da yer almaktadır.

Son adımda, Autoencoder tabanlı Self-organizing map derin öğrenme modeli kullanılarak müşteri kanal göçü stratejilerini belirleyebilecek bir model oluşturulmuştur. Bu modeldeki optimum parametreler incelenmiş ve ilgili veri seti için optimum parametreler belirlenmiştir. Batchsize parametresi için arttıkça MSE değerinin arttığı, epoch parametresi için de arttıkça MSE değerinin düştüğü görülmüştür. Learning rate parametresi için MSE değeri değişmediği görülmüştür. Bu bilgiler ile optimum bir model oluşturulabilmektedir.

Sonuç olarak, hem belirtilen müşteri örüntüleri ve K-Ortalama algoritması sonucu elde edilen çalışma ile hem mevcut müşteriler için hem de sadece fiziksel kanaldan alışveriş yapan müşteriler için ayrı ayrı stratejik kararlar verilerek müşteri kanal göçü online yöne doğru artırılabilir ve bulunduğu kümenin örüntüsü ile de davranışları önceden tahmin edilerek kanal göçünü engelleyici tutundurma çalışmaları yapılabilir. Aynı zamanda önerilen Autoencoder tabanlı Self-organizing map derin öğrenme modeli ile çok çeşitli müşteri profilleri çıkartılarak hepsi için ayrı müşteri kanal göçü stratejileri çıkartılabilir. Aynı zamanda yine sadece fiziksel kanaldan alışveriş yapan müşteriler için benzer profildekiler tespit edilerek çalışmalar yapılması firma için müşteri sadakati ve kanal göçü açısından olumlu etki yaratacaktır.

Türkiye’de gıda perakendeciliği pandemi dönemi itibari ile e-ticaret tarafına yönelim başlamasıyla birlikte sektörün bakış açısını çok fazla değiştirmiştir. E-ticarete müşteriye yönelik tüm çalışmalar müşterinin aylık bir tane daha fazla alışveriş yapması için promosyon ile destekleyerek sipariş vermesini sağlamaktır. Yani herhangi bir kanaldan nasıl bir özelliği olursa olsun yakaladığı müşteriyi tutundurmaya yöneliktir. Bunu fark eden belirli müşteriler sadece promosyon ile alışverişlerini yapmaktadır. En çok yakalayabilecekleri fiziksel kanalda nokta atışı müşteri tespit edilip, müşterilerin kanal göçü yapmalarına yönelik çalışmalar oldukça nadirdir. Fiziksel kanaldaki kitle büyük ve potansiyel olduğundan bu kitleye yapılan çalışmalar fark yaratacaktır.

Oluşturulan modeller içinden müşteri örüntülerini en iyi yansıtan k-ortalama algoritmasıdır. Model ile fiziksel kanaldan alışveriş yapan müşterilerin istenilen örüntülerde olanları çıkartılarak, o müşterilere odaklanmak organik büyümeyi de sağlayacaktır.

Eğer daha ayrıntılı bir model isteniyorsa, Autoencoder tabanlı Self-organizing map kullanmak faydalı olacaktır. Örneğin, sonucunda 70 küme çıkartan parametreler kullanıldığında bu 70 küme için stratejiler oluşturulabilir. Bu kümelerden müşteri sayısı en çok olan 3 küme için ayrıntıları incelenmiştir ve ilerleyen bölümlerde paylaşılacaktır.

Algoritmaları daha ayrıntılı incelemeden önce temel bileşen analizi sonucunda derin öğrenme hariç diğer modellerde ilerlenen 7 değişken bulunmaktadır. Bu değişkenler için, “PC1” değişkeni “cinsiyet” değişkeni ile 0.98 oranında açıkladığı ve pozitif korelasyonda olduğu görülmektedir. “PC2” değişkeni ise fiziksel kanaldaki müşteri örüntülerinin olduğu değişkeni ile -0.982407 oranında açıkladığı ve negatif korelasyonda olduğu görülmektedir. “PC3” değişkeni “dogumyili” değişkeni ile -0.533218 oranında açıkladığı ve negatif korelasyonda olduğu, aynı zamanda alışveriş ortalamasının bulunduğu değişkeni 0.688595 oranında açıkladığı ve pozitif korelasyonda olduğu görülmektedir. “PC4” değişkeni ise doğum yılının olduğu değişkeni ile 0.844595 oranında açıkladığı ve pozitif korelasyonda olduğu görülmektedir. “PC5” değişkeni ise İstanbul ilinde yapılan alışveriş sayılarını bulunduğu değişkeni ile 0.835349 oranında açıkladığı ve pozitif korelasyonda olduğu görülmektedir. “PC6” değişkeni ise İzmir ilinde yapılan alışveriş sayılarını bulunduğu değişkeni ile -0.685774 oranında açıkladığı ve negatif korelasyonda olduğu görülmektedir. Son olarak, “PC7” değişkeni ise Ankara ilinde yapılan alışveriş sayılarını bulunduğu değişkeni ile -0.565811 oranında açıkladığı ve negatif korelasyonda olduğu görülmektedir.


4.1 K-Ortalama Değerlendirme

Bir önceki bölümde algoritma için optimum küme sayısı 4 olarak belirlenmişti. Bu değer ile K-ortalama algoritması uygulandıktan sonra değişkenler bazında grafikler çıkartılmıştır (Şekil 4.1).

Ayrıca bu grafiklerden bazıları algoritma sonucu çıkan merkezler bazında değerlendirilmiştir. Veriye temel bileşen analizi uygulandığından ağırlıklar değişkendir ve genelde değeri yüksek olana göre yorumlansa da diğer ağırlıklara göre de bazı ayrımlar olabilmektedir. Çıkan kümelerin merkezleri belirtilmiştir. (Çizelge 4.1).

Çizelge 4.1 : Değişken bazında küme merkezleri.

Küme	Değişken 1	Değişken 2	Değişken 3	Değişken 4	Değişken 5	Değişken 6	Değişken 7
1	0.634	-0.454	0.0058	0.0049	0.00093	-0.0016	0.00065
2	-0.196	0.539	-0.002	-0.00049	0.00056	-0.0018	-0.00084
3	-0.348	-0.265	-0.0026	-0.0019	-0.00066	0.00125	0.00053
4	0.787	0.353	0.0072	0.0010	-0.00021	0.0020	-0.00089



Şekil 4.1 : Değişken bazında k-ortalama küme sonuçları.

Bu grafikler dışında , aynı zamanda her küme için minimum uzaklıklar çıkartılmıştır. Daha küçük bir minimum küme uzaklığı değeri, küme merkezlerinin daha yakın olduğu ve daha kompakt kümeleme sonuçlarına yol açar. Bu durumda, küme içi benzerlikler artar, ancak küme arası farklılıklar azalmaktadır. Uzaklıklara bakıldığında, minimum uzaklıklar birbirlerine yakın olup büyük bir fark


gözükmemektedir. Küme bazında ortalama minimum uzaklıklar belirtilmiştir (Çizelge 4.2).

Çizelge 4.2 : Küme bazında minimum uzaklık ortalamaları.


Küme	Minimum Uzaklık
1	0.351399
2	0.331006
3	0.356676
4	0.329336

Küme 0,1 ve 2 değerlendirildiğinde, 1 2 değişkenlerine yakın olduğu görülmektedir. (Şekil 4.2). 3. Küme değerlendirildiğinde ise 6 ve 7. Değişkenlere daha yakın olduğu görülmektedir (Şekil 4.3).

Şekiller incelendiğinde, özellikle kümelerde cinsiyet ve doğum yılı üzerinde durduğu görülmektedir. Bu durum, k-ortalama algoritmasının müşteri segmentasyonunda cinsiyet ve doğum yılı gibi demografik faktörleri dikkate aldığını ve bu faktörlere göre müşterileri gruplandırıldığını gösterir. Bunların yanı sıra, diğer kümede il bazında yapılan alışverişlere odaklanılmış ve bu veriler temel alınarak bir küme çıkartılmıştır.




Şekil 4.2 : Bir ve ikinci değişken bazında kümeler.




Şekil 4.3 : Altı ve yedinci değişkenler bazında kümeler.

Oluşturulan kümeler için küme 1 ve 2’de erkek müşteriler yoğunluktayken 3 ve 4’te kadın müşteriler yoğunluktadır (Şekil 4.4). Tüm kümelerde genellikle İstanbul ilinden alışverişler gözükmemektedir. Bunun dışında, tüm kümeler için doğum yılları benzer gözükmemektedir (Şekil 4.5). İlk küme için biraz daha genç ve 2000 sonrası doğumlu müşteriler de yer almaktadır.



Şekil 4.4 : Cinsiyet bazında kümeler.




Şekil 4.5 : Doğum yılı bazında kümeler

Müşterilerin alışveriş yaptıkları formatlara göre incelendiğinde, ilk kümenin daha çok büyük formatlı mağazalardan alışveriş yaptığı, ikinci ve üçüncü kümenin hepsinden, dördüncü kümenin ise daha çok küçük format mağazalarından alışveriş yaptığı görülmüştür.

Çıktılar değerlendirildiğinde, k-ortalama algoritmasının müşteri kanal göçü konusundaki çalışmalarda faydalı olacağı görülmektedir. İlgili birimlere müşteri bazında bilgiler çıkılarak ilgili kümelerdeki müşterilere uygulanan stratejiler uygulanarak doğru kanala göç gerçekleştirilip müşteriden gelen kazancı, sepet büyüklüğünü veya alışveriş sayısı artırılabilir.

4.2 DBSCAN Algoritması Değerlendirme

Bir önceki bölümde belirlenen optimum değerler ile algoritma sonucu 3 küme oluşmuştur. Bu kümelerin çıktıları değişkenler bazında değerlendirilmiştir (Şekil 4.6). Birinci değişken ile 2,3,4,5,6,7 arasındaki ilişkilere baktığımızda bir bölünme görebiliyoruz. Bunun dışında 2. Ve diğer değişkenler arasındaki ilişkiyi incelediğimizde bir kümelenme görebiliyoruz. Sadece iki boyutta baktığımızda 2 küme gibi gözükse de diğer boyutlardan ele alındığında daha fazla küme olabileceği görülmektedir.




Şekil 4.6 : Değişken bazında DBSCAN küme sonuçları.


Bir önceki bölümde de müşteri örüntüleri bazında model çıktıları incelendiğinde, anlamlı bir sonuç çıkmadığı görülmüştü. Bundan sonraki adımda Ddğer değişkenler açısından değerlendirilmiştir.

Oluşturulan kümeler için, ilk küme incelendiğinde kadın ve erkek müşteriler bulunurken, ikincide sadece erkek üçüncüde ise sadece kadın müşteriler bulunmaktadır (Şekil 4.7).

Tüm kümeler incelendiğinde, alışveriş sayısına bakıldığı zaman genellikle İstanbul ilinden alışverişler gözükmektedir. Diğer illerdeki alışveriş oranları oldukça düşüktür. Bunun dışında, tüm kümeler için doğum yılları incelenmiştir. Bu inceleme sonrasında, ilk kümenin daha yaşlı kesime hitap ettiği görülmüştür. Diğer kümelerin ise daha genç kesime hitap ettiği görülmektedir (Şekil 4.8).



Şekil 4.7 : Doğum yılına göre DBSCAN kümeleri.




Şekil 4.8 : Cinsiyet bazında DBSCAN kümeleri.

Son olarak alışveriş yapılan mağaza formatı bazında bakıldığında bir fark tespit edilmemiştir tüm kümeler orantılıdır.

4.3 Birleştirici Hiyerarjik Kümeleme Algoritması Değerlendirme

Bir önceki bölümde belirlenen optimum değerler ile algoritma çalıştırıldığında sonuç olarak 2 küme oluşmuştur. Bu kümelerin çıktıları, tüm değişkenler bazında değerlendirilmiştir (Şekil 4.5). Ek olarak, özellikle Temel bileşen analizindeki

değişkenler incelendiğinde, cinsiyet korelasyonu yüksek değişkenine göre bölündüğü görülmektedir.




Şekil 4.9 : Değişken bazında birleştirici hiyerarjik küme sonuçları.

Sonuçlar ana veride incelendiğinde, cinsiyet bazında ilk küme erkek ikinci küme kadın müşterilerden oluşmaktadır (Şekil 4.10). Bu durum, k-ortalama algoritmasının müşterileri cinsiyete göre başarılı bir şekilde ayırdığını göstermektedir. Örneğin, birinci küme erkek müşterileri temsil ederken, ikinci küme kadın müşterileri temsil etmektedir. Bu ayırım, işletmelerin cinsiyete özgü pazarlama stratejileri geliştirmelerine olanak sağlar.


Doğum yılı bazında incelendiğinde iki kümede de her doğum yılından müşteri var gibi görünmektedir (Şekil 4.11). Bu da k-ortalama algoritmasının müşterileri doğum yılına göre etkili bir şekilde grupladığını gösterir. Her iki kümede de her doğum yılından müşteri bulunması, müşteri segmentasyonunun doğru ve kapsamlı olduğunu gösterir.

Bu durum, işletmelerin müşteri yaş gruplarına yönelik pazarlama stratejileri oluşturmalarına yardımcı olabilir.

Alışveriş yapılan formatlarda ise uygun bir bölünme görünmemiştir. Bu durum, k-ortalama algoritmasının alışveriş formatlarına göre müşteri gruplamasında zorluklar yaşadığını göstermektedir. Algoritmanın bu konuda daha fazla veri ve belirleyici faktörlerle desteklenmesi gerekebilir. İşletmeler, alışveriş formatlarına dayalı pazarlama stratejileri geliştirmek için ek analizler yaparak, müşteri davranışlarını daha iyi anlamak ve segmente etmek için ek yöntemler kullanabilirler.



Şekil 4.10 : Cinsiyet bazında hiyerarjik küme sonuçları.



Şekil 4.11 : Doğum yılı bazında hiyerarjik küme sonuçları.

4.4 Autoencoder Tabanlı Self-organizing Map Modeli Değerlendirme

Autoencoder tabanlı SOM algoritması sonuçları için bu kümelerden müşteri sayısı en çok olan 3 küme için ayrıntıları incelenmiştir. Öncesinde tüm kümeler incelendiğinde erkeklerin bulunduğu 65, kadınların bulunduğu 19 küme görünmektedir (Çizelge 4.3).

Çizelge 4.3 : Cinsiyet bazında SOM kümeleri.

Cinsiyet	Küme Sayısı
Erkek	65
Kadın	19

Küme 1 için, diğer müşterilere göre yaşı daha büyük ve erkek kullanıcılardan oluşmaktadır. Alışverişleri ortalama seviyededir. Alışverişlerin çoğunluğu İstanbul ilinde gerçekleşmiştir. Küme 2 için, orta yaşlı ve alışveriş sayıları ortalamadan yüksektir. Alışverişler İstanbul ilinde olmuştur. Kadın müşterilerden oluşur. Küme 3 için, genç ve erkek müşterilerden oluşmaktadır. Alışveriş ortalamaları diğer müşterilere göre yüksektir. Alışverişler İstanbul ilinde olmuştur.

Gıda perakende sektöründe müşterileri bir kanala yönlendirmek veya tutundurmak için genellikle kampanya sunulmaktadır. Özellikle genç ve erkek müşterilerin bulunduğu küme 3'te sepet bazlı kampanya ile göç gerçekleştirmek için ideal gözükmemektedir. 1. Küme için bu müşterileri mağazada fiziksel olarak iletişime geçmek daha uygundur. Örneğin, alışveriş yaparken kasiyer tarafından çevrimiçi kanalın faydaları anlatarak alışverişten çıkan fişin altında bir kampanya kodu ile müşteri sanal kanala çekilmeye çalışılabilir. Küme 2 için ise, ürün bazlı promosyonlar özellikle deterjan, tuvalet kağıdı, yağ gibi temel ihtiyaç ürünlerinde yapılan indirimler kanal göçü yapmalarını sağlayacaktır.

5. SONUÇ VE ÖNERİLER

Müşteri kanal göçü sorununa yönelik yapılan çalışmalar, özellikle çoklu kanalda faaliyet gösteren firmalar için büyük önem taşımaktadır. Bu önem doğrultusunda, işletmelerin müşteri segmentasyonu ve müşteri kanal göçü konularında makine öğrenmesi yöntemlerini kullanmaları oldukça önemlidir. Makine öğrenmesi, büyük veri setlerinin analiz edilmesi, desenlerin tespit edilmesi ve tahminlerin yapılması gibi karmaşık görevlerde etkili bir araçtır.

Bu çalışmanın amacı, müşteri davranışlarını anlamak ve stratejik kararlar almak için müşteri verilerini kullanmaktır. Yirmi binin üzerindeki müşteri verisi analiz edilmiş ve müşteri alışveriş alışkanlıklarında dört farklı örüntü belirlenmiştir. Bu örüntüler, işletmelere stratejik kararlar verme sürecinde oldukça faydalı olabilecek bilgiler sağlamaktadır.

Daha sonra, k-ortalama, yoğunluk tabanlı kümeleme ve birleştirici hiyerarşik kümeleme gibi farklı kümeleme algoritmaları kullanılarak müşteriler sınıflandırılmıştır. Sonuç olarak, k-ortalama yönteminden çıkan sonucun, kullanılan müşteri verisini en iyi yansıtan yöntem olduğu görülmüştür. Diğer kümeleme modellerinin ürettiği sonuçlar incelendiğinde veriyi doğru kümelemediği görülmektedir. Bu nedenle, k-ortalama algoritması tercih edilmiştir.

Ayrıca, derin öğrenme modeli olan autoencoder tabanlı Self-organizing map kullanılarak daha nokta atışı bir strateji için optimum müşteri kümeleme modeli oluşturulmuştur. Bu model, 70 farklı kümeleme ile müşterilere özelleştirilmiş bir yaklaşım sunabileceği düşünülmektedir.

Bu çalışmanın sonuçları, işletmelere müşteri segmentasyonu ve müşteri kanal göçünü entegre bir şekilde kullanarak pazarlama stratejilerini daha etkili hale getirme imkanı sunmaktadır. Müşterilerin ihtiyaçlarına daha iyi yanıt verebilmek, müşteri memnuniyetini artırmak ve rekabet avantajı elde etmek için bu tür analizler ve stratejik kararlar oldukça önemlidir.

Bu çalışmada, müşteri kanal göçü analizi için autoencoder tabanlı self-organizing map derin öğrenme modeli ve birleştirici hiyerarşik kümeleme algoritması gibi yenilikçi yöntemler kullanılmıştır. Bu yöntemler literatürde daha önce kullanılmadığından literatüre katkı sağlamıştır.

Gelecek çalışmalarda, müşteri kanal göçü konusunda derin öğrenme yöntemlerinin daha fazla kullanılması ve üretilen sonuçların literatüre daha fazla katkı sağlaması beklenmektedir. Bu yeni yöntemlerin kullanılması, müşteri kanal göçü analizlerinin çeşitliliğini ve doğruluğunu artıracaktır. Özellikle Türkiye gıda perakendeciliğinde e-ticaret kanalının odak noktası, müşterilerin bir sipariş daha vermesini sağlamak için promosyonlar kullanmaktır. Ancak, müşteri kanal göçüyle ilgili nokta atışı organik büyümeyi sağlayacak çalışmalar oldukça nadirdir. Bu nedenle, hem fiziksel mağazaları hem de online kanalları kullanan işletmelerin, müşteri kanal göçünü analiz ederek ve stratejik kararlar alarak müşterilerin kanallar arasında geçişini sağlamaları oldukça önemlidir.

Migros Ticaret A.Ş., online kanaldaki en büyük müşteri potansiyeline kendi fiziksel mağazalarından alışveriş yapan müşterileri sahiptir. Bu nedenle, şirket müşteri kanal göçü konusunda çalışmalar yürütmekte ve bu alanda Ar-Ge projeleri gerçekleştirmektedir. Özellikle Migros AR-GE merkezindeki bir Ar-Ge projesi, müşteri kanal göçünü takip etmek ve analiz etmek amacıyla başlatılmıştır.

Ayrıca, 16-28 Ekim 2022 tarihleri arasında gerçekleşen 41. Yöneylem Araştırması Endüstri Mühendisliği Kongresi'ne katılım sağlanmıştır. Denizli'de düzenlenen bu kongrede "Literature Review On Customer Channel Migration And Forecasting In Retail Sector" başlıklı bir çalışma Gizem ÇALIŞKAN tarafından sunulmuştur. Migros Ticaret A.Ş.'nin bu alandaki çalışmaları ve sunumu, sektöre ve akademik çevrelere önemli bir katkı sağlamış ve şirketin müşteri kanal göçü konusundaki uzmanlığını vurgulamıştır.

Bu çalışmaların Migros Ticaret A.Ş. gibi büyük bir perakende şirketi için önemi oldukça büyüktür. Şirket, müşteri davranışlarını anlamak, müşteri kanal göçünü yönetmek ve pazarlama stratejilerini etkili bir şekilde uygulamak için bu tür araştırmaları ve projeleri takip etmektedir. Müşterilerin online kanala olan geçişlerini anlamak ve yönlendirmek, şirketin çevrimiçi platformlarında daha fazla müşteri çekmesine ve sadakatlerini sağlamasına yardımcı olmaktadır.

KAYNAKLAR

- Abhishek, V. T. G. A., Neslin, S. A., Grantham, K. D., McNeil, K. R., & Chaturvedi, S.** (2017). Managing CLV using the migration model framework: Overcoming the “Recency Trap”. *Journal of the Academy of Marketing Science*, 41(3), 320-337.
- Ackermann, S., & von Wangenheim, F.** (2014). Behavioral Consequences of Customer-Initiated Channel Migration. *Journal of Service Research*, 17(3), 262-277. <https://doi.org/10.1177/1094670513519862>
- Alkhatib, K., & Abualigah, S.** (2020). Predictive Model for Cutting Customers Migration from banks: Based on machine learning classification algorithms. *11th International Conference on Information and Communication Systems (ICICS)*, 130, 303-307.
- Ansari, A., Mela, C. F. M., & Neslin, S. A.** (2008). Customer Channel Migration. *Source: Journal of Marketing Research*, 45(1), 60-76.
- Bengio, Y., Courville, A., & Vincent, P.** (2013). Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828. <https://doi.org/10.1109/TPAMI.2013.50>
- Bleier, A., Egger, F. N., & Brito, P. Q.** (2011). Decision process evolution in customer channel choice. *Journal of Interactive Marketing*, 25(4), 188-201.
- Chen, Y., Zhang, J., & Sun, X.** (2017). Reducing the chance of customers leaving by utilizing big data clustering algorithm. *Journal of Intelligent Manufacturing*, 28(4), 951-960.
- Ching, W. K., Ng, M. K., & So, M. M.** (2004). Customer migration, campaign budgeting, revenue estimation: the elasticity of Markov Decision Process on customer lifetime value. *Advanced Modeling and Optimization*.
- Chou, S.-Y., Shen, G. C., Chiu, H.-C., & Chou, Y.-T.** (2016). Multichannel service providers’ strategy: Understanding customers’ switching and free-riding behavior. *Journal of Business Research*, 69(6), 2226-2232. <https://doi.org/10.1016/j.jbusres.2015.12.034>
- De Vries, E. L. E., & Zhang, S.** (2020). The effectiveness of random discounts for migrating customers to the mobile channel. *Journal of Business Research*, 110, 272-281. <https://doi.org/10.1016/j.jbusres.2020.01.041>

- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X.** (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. In *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96)*, 226-231.
- Fornari, E., Fornari, D., Grandi, S., Menegatti, M., & Hofacker, C. F.** (2016). Adding store to web: migration and synergy effects in multi-channel retailing. *International Journal of Retail and Distribution Management*, 44(6), 658-674. <https://doi.org/10.1108/IJRDM-07-2015-0103>
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep learning*. MIT press.
- Han, H., Kim, H. S., & Lee, S.** (2019). Channel migration patterns and the impact on online and offline purchases. *Journal of Business Research*, 101, 382-393.
- Hanehalkı Bilişim Teknolojileri (BT) Kullanım Araştırması.* (2022, Ağustos 26). TÜİK.
- Hastie, T., Tibshirani, R., & Friedman, J.** (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- Huang, L., Lu, X., & Baumann, C.** (2021). Channel migration and online and offline behavior changes in retailing: A latent class analysis. *Journal of Business Research*, 91, 144-154.
- Jain, A. K., Murty, M. N., & Flynn, P. J.** (1999). Data clustering: a review. *ACM Computing Surveys (CSUR)*, 31(3), 264-323.
- Jain, A. K., Narasimha, M. M., & Nandakumar, K.** (2008). Clustering Texts Using an Approximation of the K-Means Algorithm. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(3), 369-378. <https://doi.org/10.1109/TPAMI.2007.1178>
- Jamoussi, M., & Al Salem, M.** (2006). A “customer satisfaction” based migration approach toward NGN. *8th International Conference Advanced Communication Technology, ICACT 2006 - Proceedings*, 1, 97-101. <https://doi.org/10.1109/icact.2006.205927>
- Jolliffe, I. T.** (2002). *Principal component analysis* (2. bs). Springer.
- Kanchanapoom, K., & Chongwatpol, J.** (2022). Integrated customer lifetime value (CLV) and customer migration model to improve customer segmentation. *Journal of Marketing Analytics*. <https://doi.org/10.1057/s41270-022-00158-7>
- Kang, J., Diao, Z., & Zanini, M. T.** (2021). Business-to-business marketing responses to COVID-19 crisis: a business process perspective. *Marketing Intelligence & Planning*, 39(3), 454-468. <https://doi.org/10.1108/MIP-05-2020-0217>
- Kauffman, R., Lee, D., Lee, J., & Yoo, B.** (2009). A hybrid firm’s pricing strategy in electronic commerce under channel migration. *International Journal of*

Electronic Commerce, 14(1), 11-54. <https://doi.org/10.2753/JEC1086-4415140101>

Kaufman, L., & Rousseeuw, P. J. (2009). *Finding Groups in Data: An Introduction to Cluster Analysis*. John Wiley & Sons.

Ketchen, D. J., & Shook, C. L. (2011). The application of cluster analysis in strategic management research: An analysis and critique. *Strategic Management Journal*, 22(2), 127-153.

Kim, H., & Park, Y. (2019). *Examining the effects of customer shopping channel migration on retailers' pricing strategies*. 47, 102-111.

Kimber, C. (t.y.). *Strategic integration of customers and channels*.

Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464-1480. <https://doi.org/10.1109/5.58325>

Korkmaz, E., & Güner, M. (2022). VED Analysis Methods in Stock Control: Application in A University Hospital Covid-19 Services. *Muhasebe ve Finansman Dergisi*, 93, 1-18.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>

Li, J., Konuş, U., Langerak, F., & Weggeman, M. C. D. P. (2017). Customer Channel Migration and Firm Choice: The Effects of Cross-Channel Competition. *International Journal of Electronic Commerce*, 21(1), 8-42. <https://doi.org/10.1080/10864415.2016.1204186>

Liu, M., Cao, E., & Salifou, C. K. (2016). Pricing strategies of a dual-channel supply chain with risk aversion. *Transportation Research Part E: Logistics and Transportation Review*, 90, 108-120. <https://doi.org/10.1016/j.tre.2015.11.007>

Ma, Y., Song, M., & Sun, Y. (2020). How does customer channel migration affect firm value in the retail industry? *Journal of Retailing and Consumer Services*, 55(102105).

Madahi, A., & Sukati, I. (2016). An empirical study of Malaysian consumers' channel-switching intention: Using theory of planned behaviour. *Global Business Review*, 17(3), 489-523. <https://doi.org/10.1177/0972150916630447>

Mark, T., Lemon, K., & Vandenbosch, M. (2014). Customer migration patterns: Evidence from a North American retailer. *Journal of Marketing Theory and Practice*, 22(3), 251-270. <https://doi.org/10.2753/MTP1069-6679220302>

Martinelli, E., De Canio, F., & Nardin, G. (2021). Consumers' Channel Switching Behaviour from Off-line to On-line: The Role of the Fear of Covid-19. *Springer Proceedings in Business and Economics*, 33-40. https://doi.org/10.1007/978-3-030-76935-2_5

- Murynets, I., Ramirez-Marquez, J. E., & Jiang, W.** (2009). Migration of customers owing to a service substitution. *Journal of Targeting, Measurement and Analysis for Marketing*, 17(4), 297-306. <https://doi.org/10.1057/jt.2009.21>
- Müller, E., & Günnemann, S.** (2017). Agglomerative Clustering. In *Proceedings of the IEEE International Conference on Data Mining (ICDM)*, 1175-1180.
- Nguyen, A. T. Van, McClelland, R., & Thuan, N. H.** (2022). Exploring customer experience during channel switching in omnichannel retailing context: A qualitative assessment. *Journal of Retailing and Consumer Services*, 64. <https://doi.org/10.1016/j.jretconser.2021.102803>
- Nunes, B., Viana, D., & Ferreira, F. A.** (2020). Online–offline channel migration in retail: A machine learning approach. *Journal of Business Research*, 117, 758-769.
- Ortaköy, S., & Özsürünç, Z.** (2019). The Effect of Digital Channel Migration, Automation and Centralization on the Efficiency of Operational Staff of Bank Branches. *Procedia Computer Science*, 158, 938-946. <https://doi.org/10.1016/j.procs.2019.09.134>
- Pookulangara, S., Hawley, J., & Xiao, G.** (2011). Explaining multi-channel consumer's channel-migration intention using theory of reasoned action. *International Journal of Retail and Distribution Management*, 39(3), 183-202. <https://doi.org/10.1108/095905511111115024>
- Pourabedin, Z., Foon, Y. S., Chatterjee, S., Sze, J., & Ho, Y.** (t.y.). *Customers' online channel switching behavior: The moderating role of switching cost.*
- Qin, J., Ren, L., Xia, L., Wang, Z., & Chang, H.** (2020). Pricing strategies for dual-channel supply chains under a trade credit policy. *International Transactions in Operational Research*, 27(5), 2469-2508. <https://doi.org/10.1111/itor.12634>
- Rousseeuw, P. J.** (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53-65. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Rousseeuw, P. J.** (1991). *Silhouettes: a graphical representation of the quality of clusters.* 20, 53-65.
- Saeed, K., Azam, F., & Hussain, M.** (2018). A comprehensive review on clustering algorithms. *International Journal of Computer Applications*, 181(20), 1-8.
- Sarel, D., & Marmorstein, H.** (2001). Migrating customers to new distribution channels: The role of communication. *Journal of Financial Services Marketing*, 6, 254-266.
- Shi, Y., & Myer, C.** (2020). Customer Channel Adoption and Migration Behavior in an Extensive Channel Environment: An Abstract. İçinde F. Pantoja, S. Wu, & N. Krey (Ed.), *Developments in Marketing Science: Proceedings of the Academy of Marketing Science* (C. 22, ss. 259-260). Springer International Publishing. https://doi.org/10.1007/978-3-030-42545-6_74

- Sullivan, U. Y., & Thomas, J. S.** (2004). *Customer Migration: An Empirical Investigation Across Multiple Channels*.
http://www.business.uiuc.edu/Working_Papers/papers/04
- Tan, P. N., Steinbach, M., & Kumar, V.** (2006). *Introduction to data mining*. Addison-Wesley.
- Trampe, D., Konuş, U., & Verhoef, P. C.** (2014). Customer Responses to Channel Migration Strategies Toward the E-channel. *Journal of Interactive Marketing*, 28(4), 257-270. <https://doi.org/10.1016/j.intmar.2014.05.001>
- Tran, A. T. N., Nguyen, U. H. D., Ngo, V. M., & Nguyen, H. H.** (2023). Explaining consumers' channel-switching behavior in the post-COVID-19 pandemic era. *Cogent Business and Management*, 10(1).
<https://doi.org/10.1080/23311975.2023.2198068>
- Valentini, S., Montaguti, E., & Neslin, S. A.** (2011). Decision Process Evolution in Customer Channel Choice. *Journal of Marketing*, 75(6), 72-86.
<https://doi.org/10.1509/jm.09.0362>
- Van Nguyen, A. T., Halibas, A. S., McClelland, R., & Thuan, N. H.** (2023). Configurational analysis of conditions influencing customers' channel switching intention in omnichannel retailing: a fuzzy-set analysis. *Quality and Quantity*.
<https://doi.org/10.1007/s11135-023-01633-8>
- Widodo, E., Palullungan, D., & Syairudin, B.** (2019). Implementing PPM framework to customer's switching behaviour in dual-channel service supply chain. *Journal of Physics: Conference Series*, 1367(1).
<https://doi.org/10.1088/1742-6596/1367/1/012043>
- Xu, R., & Wunsch, D.** (2005). Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645-678.
- Yang, J., & Khoo, L. P.** (2020). The effects of online reviews and brand reputation on customer migration intention: A case study of Airbnb. *Journal of Hospitality and Tourism Management*, 42, 66-74.
- Yang, Z., Cheng, A., Li, T., Yang, Z., Cheng, A., & Ting, L.** (2019). Still Targeting Younger Customers? A Field Experiment on Digital Communication Channel Migration. *ICIS 2019 Proceedings*. <https://aisel.aisnet.org/icis2019>
- Zhang, M., & Zhang, J.** (2019). Research on customer channel migration in the omni-channel era: A case study of Chinese online retailing. *Journal of Retailing and Consumer Services*, 49, 202-208.



EKLER

EK A: Analiz sonuçları



EKLER

EK A: Analiz sonuçları

Çizelge A.1: Normallik Testi

Kolmogorov-Smirnova			Shapiro-Wilk		
Statistic	df	Sig.	Statistic	df	Sig.
0,071	196	0,017	0,989	196	0,146

Çizelge A.2: Levene Testi

Skor	Levene İstatistik	df1	df2	Sig.
Ortalamaya Dayalı	4,618	51	102	<,001
Medyana Dayalı	0,489	51	102	0,997
Medyana Dayalı ve Düzeltilmiş df	0,489	51	25,228	0,985
Kırılmış Ortalamaya Dayalı	3,927	51	102	<,001

Bağımlı değişkenin hata varyansının gruplar arasında eşit olduğu boş hipotezini test eder.

a. Bağımlı Değişken: skor

b. Tasarım: Sabit + yöntem + varyans + kümesayi + yöntem * varyans + yöntem * kümesayi + varyans * kümesayi + yöntem * varyans * kümesayi

Çizelge A.3: Denekler Arası Etki Testleri

Kaynak	Tip III Kareler Toplamı	df	Ortalama Kare	F	Sig.
Düzeltilmiş Model	,993a	93	0,011	1,543	0,016
Sabit	10,137	1	10,137	1464,412	<,001
yöntem	0,007	2	0,004	0,541	0,584
varyans	0,042	3	0,014	2,015	0,116
kümesayi	0,519	11	0,047	6,812	<,001
yöntem *	0,068	6	0,011	1,643	0,143
varyans *	0,157	12	0,013	1,893	0,044
kümesayi	0,086	30	0,003	0,416	0,996
yöntem *	0,029	29	0,001	0,144	1
varyans *	0,706	102	0,007		
kümesayi	25,346	196			
Error					
Total					
Düzeltilmiş Toplam	1,699	195			

a. R Squared = ,584 (Adjusted R Squared = ,206)

Çizelge A.4: Yöntem Değişkeni Skor Bazında Post Hoc Testi Çoklu Karşılaştırma

Test	(I) yöntem	(J) yöntem	Ortalama Farkı(I-J)	Std. Hata	Sig.
Tukey HSD	3	2	,0520*	0,01846	0,016
		1	-0,0013	0,01502	0,996
	2	3	-,0520*	0,01846	0,016
		1	-,0533*	0,02148	0,039
	1	3	0,0013	0,01502	0,996
		2	,0533*	0,02148	0,039
Bonferroni	3	2	,0520*	0,01846	0,017
		1	-0,0013	0,01502	1
	2	3	-,0520*	0,01846	0,017
		1	-,0533*	0,02148	0,044
	1	3	0,0013	0,01502	1
		2	,0533*	0,02148	0,044

Gözlenen araçlara dayalı.

Hata terimi, Ortalama Kare(Hata) = ,007'dir.

*. Ortalama fark ,05 düzeyinde anlamlıdır.

Çizelge A.5: Yöntem Bazında Homojen Alt kümeler

Test	Yöntem	N	Altküme	
			1	2
Tukey HSD	2	24	0,3014	
	3	132		0,3535
	1	40		0,3547
	Sig.		1	0,997
Duncan	2	24	0,3014	
	3	132		0,3535
	1	40		0,3547
	Sig.		1	0,945

Çizelge A.6: Varyans Değişkeni Skor Bazında Post Hoc Testi Çoklu Karşılaştırma

Test	(I) varyans	(J) varyans	Ortalama Farkı (I-J)	Std. Hata	Sig.	%95 Güven Aralığı	
						alt limit	üst limit
Tukey HSD	80	85	0,0268	0,01681	0,385	-0,0171	0,0707
		90	0,0024	0,01681	0,999	-0,0415	0,0463
		95	0,0279	0,01681	0,352	-0,016	0,0718
	85	80	-0,0268	0,01681	0,385	-0,0707	0,0171
		90	-0,0244	0,01681	0,469	-0,0684	0,0195
		95	0,001	0,01681	1	-0,0429	0,0449
	90	80	-0,0024	0,01681	0,999	-0,0463	0,0415
		85	0,0244	0,01681	0,469	-0,0195	0,0684
		95	0,0255	0,01681	0,432	-0,0184	0,0694
	95	80	-0,0279	0,01681	0,352	-0,0718	0,016
		85	-0,001	0,01681	1	-0,0449	0,0429
		90	-0,0255	0,01681	0,432	-0,0694	0,0184
Bonferroni	80	85	0,0268	0,01681	0,681	-0,0184	0,0721
		90	0,0024	0,01681	1	-0,0428	0,0476
		95	0,0279	0,01681	0,603	-0,0174	0,0731
	85	80	-0,0268	0,01681	0,681	-0,0721	0,0184
		90	-0,0244	0,01681	0,893	-0,0697	0,0208
		95	0,001	0,01681	1	-0,0442	0,0462
	90	80	-0,0024	0,01681	1	-0,0476	0,0428
		85	0,0244	0,01681	0,893	-0,0208	0,0697
		95	0,0255	0,01681	0,797	-0,0198	0,0707
	95	80	-0,0279	0,01681	0,603	-0,0731	0,0174
		85	-0,001	0,01681	1	-0,0462	0,0442
		90	-0,0255	0,01681	0,797	-0,0707	0,0198

Gözleme dayalı.


Hata terimi, Ortalama Kare(Hata) = ,007'dir.

Çizelge A.7: Varyans Bazında Homojen Alt kümeler

Test	(I) varyans	varyans	N	altküme 1
Tukey HSDa,b	95	49	0,3338	0,3338
	85	49	0,3348	0,3348
	90	49	0,3592	0,3592
	80	49	0,3616	0,3616
		Sig.	0,352	0,352
Duncana,b	95	49	0,3338	0,3338
	85	49	0,3348	0,3348
	90	49	0,3592	0,3592
	80	49	0,3616	0,3616
		Sig.	0,134	0,134



ÖZGEÇMİŞ



Ad-Soyad : Gizem ÇALIŞKAN

ÖĞRENİM DURUMU:

- **Lisans:** 2019, Yıldız Teknik Üniversitesi, Makine Fakültesi, Endüstri Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- **Migros İş Geliştirme Yöneticisi (2019-...)**
 - Teknolojik inovasyon projesi “Mkolay” Product Owner
 - Amazon Go benzeri “MGo” Product Owner
 - MTM metodu ile mağaza süreçlerinin analizi ve verimlilik artırılması
 - Elektrik tüketimi tahminleme ve sınıflandırma platformu oluşturma
 - Hatalı etiket tespit algoritması tasarımı ve prototiplenmesi
 - Stok Doğruluğu algoritma tasarımı ve python ortamında prototiplenmesi
 - Fatura tahsilat ve istanbulkart dolum algoritma tasarımı ve prototiplenmesi
 - M & Mjet Portföy sadeleşme çalışmaları
 - Meyve Sebze maliyet analiz çalışmaları
 - İyi Fikir İyi Proje Platformu Veri Madenciliği Projesi
- **Turkcell Test Mühendisi (2017-2019)**
- **Arçelik Süreç Geliştirme Proje Stajyeri (2018)**
- **Tüpraş Üretim Planlama ve Optimizasyon Stajyeri (2017)**

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Çalışkan, G.** (2022). ”Literature Review On Customer Channel Migration And Forecasting In Retail Sector”. 41. Yöneylem Araştırması ve Endüstri Mühendisliği Ulusal Kongresi.

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Omeroglu, G.** (2019). Systematic Review About Operational Productivity In Retail Sector. Engineering and Technology Management Summit.

- **Omeroglu, G., Ertug, A., & Ozkavukcu, A.** (2020). Systematic Literature Review for Work Sampling with IOT Technology in Retail Store Operations. International Conference on Intelligent and Fuzzy Systems, 1666-1674.
- **Ersoy, Ö., Sezer, U., & Ömeroğlu, G.** (2020). Systematic Review About Self Scanning With Customer Journey Map In Retail Sector. 3rd International Conference on Data Science and Applications (ICONDATA'20), 181–187.
- **Ömeroğlu, G. (2021).** Systematic Review About Stock Inaccuracy In Retail Sector. 4th International Conference on Data Science and Applications (ICONDATA'21).
- **Ozkiris, R., & Omeroglu, G.** (2021, August). Systematic Literature Review for Data-Driven Security Solutions of Self Scanning Applications in Retail Sector. In International Conference on Intelligent and Fuzzy Systems (pp. 910-920). Springer, Cham.
- **Akgün, İ., Özkavukcu, A., Mısır, İ., Ömeroğlu, G., Aktürk, C., & Bayülgen, Ş.** (2021). ÜRÜN AYIRICI ARA TAŞIYICI. 3 TEK PATENT MARKA DANIŞMANLIK A.Ş.