



**T.C.**

**TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ**

**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜKSEK LİSANS PROGRAMI**

**MAKİNE ÖĞRENİMİ İLE E-TİCARETTE ÖNERİ MOTORU VE  
DİJİTAL PAZARLAMA OTOMASYONU**

**YÜKSEK LİSANS TEZİ**

**Mamadi KEİTA**

**Danışman : Dr. Öğr. Üyesi Ebubekir YAŞAR**

**TOKAT– 2025**

## ETİK SÖZLEŐME

Tokat GaziosmanpaŐa Üniversitesi Lisansüstü Eđitim Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Ebubekir YAŐAR danıŐmanlıđında hazırlamıŐ olduđum “Makine Öğrenimi İle E-Ticarette Öneri Motoru Ve Dijital Pazarlama Otomasyonu” adlı Yüksek Lisans/ Doktora tezinin bilimsel etik deđerlere ve kurallara uygun, özgün bir çalıŐma olduđunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceđimi beyan ederim.

.../.../.....

Mamadi KEİTA

## JÜRI KABUL VE ONAY

**Mamadi KEİTA** tarafından hazırlanan “**Makine Öğrenimi ile E-Ticarette Öneri Motoru Ve Dijital Pazarlama Otomasyonu**” adlı tez çalışmasının savunma sınavı 02.07.2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Mekatronik Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmimdir.

### Jüri Üyeleri (Unvanı, Adı Soyadı)

#### İmzası

Üye (Başkan) : Dr. Öğr. Üyesi Ebubekir YAŞAR

Üye : Prof. Dr. Turgut ÖZSEVEN

Üye : Dr. Öğr. Üyesi Bilal ÖZAK

Üye : Dr. Öğr. Üyesi Ebubekir YAŞAR (Danışman)

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

## ÖZET

# MAKİNE ÖĞRENİMİ İLE E-TİCARETTE ÖNERİ MOTORU VE DİJİTAL PAZARLAMA OTOMASYONU

Keita, Mamadi

Yüksek Lisans, Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Ebubekir Yaşar

Temuz 2025, XI + 65 Sayfa

Elektronik ticaret (e-ticaret), artan rekabet ve giderek daha fazla talepkar tüketicilerle karakterize edilen modern ekonominin rağbet edilen bir modeli olmuştur. Bu bağlamda, elektronik ticaretin performansını ve etkinliğini artırmak için çeşitli yöntemler araştırılmaktadır. Binlerce seçenek arasında doğru ürünü, doğru müşteriye önermek, alışveriş için harcanan zamanı kısaltarak firmaların satış oranlarını artırmaktadır. Bu amaçla öneri sistemleri elektronik ticarete son yıllarda üzerinde çalışılan önemli bir konu olmuştur.

Bu tezde, e-ticarete öneri sistemlerinin ve otomatik dijital pazarlamanın son durumunu incelenmiştir. E-ticaret sektöründe müşteri katılımını ve iş sonuçlarını iyileştirmek için farklı öneri sistemleri türlerini, otomatik dijital pazarlama tekniklerini ve bunların entegrasyonu araştırılmıştır. Ek olarak, kullanıcı profillerine çıkarım verileri ekleyerek önerileri iyileştirmek için ilişki kurallarını ve işbirlikçi filtrelemeyi birleştiren bir yaklaşım önerilmiş ve başarımları ölçeklendirilmiştir. Matematiksel metrikler RMSE ve MAE'ye göre, işbirlikçi filtreleme tek başına kullanılan hibrit yöntemini küçük bir farkla geride bıraktığı gözlenmiştir. Ancak hibrit sistemin test sırasında daha fazla öneri kapsamına ve daha fazla öneri çeşitliliğine sahip olduğu gözlenmiştir.

**Anahtar Kelimeler:** Öneri Sistemleri, Dijital Pazarlama, E-ticaret, Kişiselleştirme, Müşteri Deneyimi, Ticari Performans.

## ABSTRACT

### RECOMMENDATION ENGINE AND DIGITAL MARKETING AUTOMATION IN E-COMMERCE WITH MACHINE LEARNING.

Keita, Mamadi

Master's Degree, Department of Mechatronic Engineering

Thesis Advisor: Dr. Ebubekir Yaşar

July 2025, XI + 65 Page

Electronic commerce (e-commerce) has become a pillar of the modern economy, characterized by increased competition and increasingly demanding consumers. In this context, digital marketing and recommendation systems are emerging as strategic tools to differentiate, optimize the customer experience, and improve business performance.

This thesis examines the state of the art of recommendation systems and automated digital marketing in e-commerce. It explores different types of recommender systems, automated digital marketing techniques and their integration to improve customer engagement and business outcomes in the e-commerce industry. In addition, an approach combining association rules and collaborative filtering to improve recommendations by adding inference data to user profiles is proposed and their performance is scaled. According to the mathematical metrics RMSE and MAE, collaborative filtering outperforms the hybrid method used alone by a small margin. However, the hybrid system was observed to have more recommendation coverage and more recommendation diversity during the test.

**Keywords:** Recommendation Systems, Digital Marketing, E-commerce, Personalization, Customer Experience, Commercial Performance.

## ÖNSÖZ

Çalışmalarım boyunca yardım ve katkılarıyla beni yönlendiren değerli danışman hocam Dr. Öğr. Üyesi Ebubekir YAŞAR'a, öğrenim hayatım boyunca tercihlerimin, isteklerimin ve hedeflerimin arkasında duran, beni istediğim doğrultuda desteklemekten asla gocunmayan aileme, maddi manevi her zaman yanımda oldukları ve bunu hissettirdikleri için sonsuz minnet ve teşekkürlerimi sunarım.

MAMADI KEITA

TOKAT-2025

## İÇİNDEKİLER

ETİK SÖZLEŞME .....	ii
JÜRİ KABUL VE ONAY SAYFASI.....	iii
ÖZET .....	iv
ABSTRACT.....	v
ÖNSÖZ.....	vi
İÇİNDEKİLER.....	vii
1. GİRİŞ.....	1
Tezin Amaçları.....	4
Araştırma Yöntemi.....	4
2. LİTERATÜR ÖZETLERİ.....	6
2.1 E-Ticaretin Tanımı Ve Kapsamı .....	6
2.2 E-Ticaretin Kökenleri.....	8
2.3. E-Ticaretin Altın Çağı (2000-2010).....	10
2.4 Dünyada E-Ticaretin Patlaması.....	11
2.5 Makine Öğrenimi .....	11
2.6 Öneri Sistemleri .....	12
2.6.1 Öneri sistemlerinin kullanışlılığı .....	13
2.6.2 Öneri sistemlerinin kullanılmasının bazı nedenleri .....	14
2.6.3 Öneri sistemi türleri.....	15
2.6.4 İçerik Tabanlı Öneri Sistemleri .....	15
2.6.5. İçeriğe dayalı önerinin avantajları .....	18
2.6.6. İçeriğe dayalı önerinin dezavantajları .....	19
2.6.7. İşbirlikçi filtreleme .....	19
2.6.8. Hafızaya dayalı yaklaşım .....	20
2.6.9. Modele dayalı yaklaşım.....	20
2.6.10. Kullanıcıya dayalı işbirlikçi filtreleme .....	21
2.6.11. İçerik tabanlı işbirlikçi filtreleme .....	22
2.6.12. Hibrit öneri sistemleri.....	24
2.6.13. Öneri sistemi için değerlendirme ölçütleri .....	24
2.6.14. Hatırlatma .....	24
2.6.15. Kesinlik.....	25
2.6.16. Kök Ortalama Karesel Hata (RMSE) .....	25

2.6.17. Ortalama mutlak hata (MAE).....	25
2.7. Dijital Pazarlama.....	25
2.7.1. Dijital pazarlama stratejisi geliştirme.....	27
2.7.2. Arama motoru optimizasyonu (SEO).....	28
2.7.3. Sosyal ağlar .....	28
2.7.4. İçerik pazarlaması.....	29
2.7.5. E-Posta pazarlaması.....	29
2.7.6. Stratejik web sitesi geliştirme.....	29
2.7.7. E-ticarette dijital pazarlama otomasyonu .....	29
2.7.8. E-ticarette dijital pazarlama stratejilerini otomatikleştirmek için makine öğreniminin uygulanması .....	30
2.7.9. Müşteri segmentasyonu .....	31
2.7.10. Kişiselleştirmenin satış ve dönüşüm oranına etkisi.....	33
2.7.11 Pazarlama içeriği için üretken yapay zeka kullanımı .....	34
2.7.12. E-ticarette öneri sistemleri ve otomasyonun önemi .....	34
2.7.13. Öneri sistemleri ve otomatikleştirilmiş dijital pazarlamanın entegrasyonu .....	35
2.7.14. Önerilere dayalı otomatik iş akışları.....	35
2.7.15. Gerçek zamanlı veri analizi ve optimizasyonu.....	36
2.8 E-ticarette öneri sistemlerinin etkinliğine ilişkin ampirik çalışmalar .....	36
2.8.1 Satış ve dönüşüm oranına etkisi .....	36
2.8.2 Müşteri memnuniyeti ve sadakatine etkisi .....	37
2.9 Otomatik pazarlama kampanyalarının etkinliği .....	37
3. MATERYAL VE METOD.....	38
3.1. Tezde Kullanılan Makine Öğrenimi Kitaplıkları .....	38
3.1.1 Pandas.....	38
3.1.2 NumPy.....	38
3.1.3. Matplotlib .....	39
3.1.4. Seaborn.....	39
3.1.5. Sklearn.....	39
3.1.6. Surprise .....	39
3.2 Verilerin Eldesi ve Hazırlanması .....	39
3.3 Eksik Değerlerin İşlenmesi .....	40
3.4 Veri Görselleştirme .....	42
3.5 Veri Madenciliği Ön İşleme.....	43

3.5.1. İçerik tabanlı işbirlikçi filtreleme ve ilişki kuralları öneri sisteminin uygulanması.....	45
3.5.2. Veri toplama ve ön işleme.....	45
3.5.3. Metin verilerinin dijital vektörlerinin oluşturulması .....	46
3.5.4. Kullanıcı profili oluşturma .....	46
3.5.5. Birliktelik Kurallarının Uygulanması.....	47
3.5.6. Tezde kullanılan yaklaşımın 4 temel adımı.....	47
3.5.7. Benzerlik hesaplaması .....	48
3.5.8. Top-N ürün önerileri.....	48
3.5.9. Sistem değerlendirmesi .....	48
3.5.10. İçerik tabanlı öneri sistemini çevrimdışı değerlendirme .....	48
3.5.11. İşbirlikçi filtrelemenin uygulanması.....	49
3.5.12. Veri toplama ve ön işleme.....	49
3.5.13. Yöntem .....	49
3.5.14 Pazarlama otomasyonu için yerleşik makine öğrenimi .....	49
3.5.15 E-posta pazarlaması.....	50
4. BULGULAR.....	52
4.1. İşbirlikçi Filtreleme.....	52
4.1.1. Model tabanlı yaklaşım çevrimdışı değerlendirme .....	52
4.1.2 Hafızaya dayalı yaklaşım çevrimiçi değerlendirme .....	53
4.1.3 Kullanıcı tabanlı işbirlikçi filtreleme.....	53
4.1.4 Surprise kütüphanesinden nmf yöntemi ile kullanıcı tabanlı işbirlikçi filtreleme.....	55
4.1.5 Öğe tabanlı işbirlikçi filtreleme sistemi .....	55
4.2. Çıkarılan Verilerle Öğe Tabanlı Öneri Filtreleme .....	56
4.3. Basit İçerik Tabanlı Öneri Sistemi.....	57
5. TARTIŞMA VE SONUÇ .....	58
KAYNAKLAR .....	61

## TABLULAR LİSTESİ

Tablo No	Sayfa No
Tablo 2.1: En popüler e-ticaret kategorileri [11].....	8
Tablo 3.1: Örnek müşteri modeli.....	50
Tablo 3.2: Güncelleme sonrası istemci modeli.....	50
Tablo 4.1: Kosinüs benzerliği ile yapılan testlerin sonuçları.....	52
Tablo 4.2: Pearson benzerliği ile yapılan testlerin sonuçları.....	53
Tablo 4.3: Surprise kütüphanesi olmadan işbirlikçi filtrelemenin performans sonuçları.....	53
Tablo 4.4: NMF yöntemini kullanan kullanıcı tabanlı işbirlikçi filtrelemenin Performans sonuçları.....	55
Tablo 4.5: Sistem performans ölçümleri (öğe tabanlı CF).....	56
Tablo 4.6: Sistem performans ölçümleri (hybrit).....	57
Tablo 4.7: Kosinüs benzerliği ile içerik tabanlı öneri sisteminin performansı.....	57

## ŞEKİLLER LİSTESİ

Şekil No	Sayfa No
Şekil 2.1: Öneri sistemleri (Fereira ve diğ., 2020).....	13
Şekil 2.2: Farklı öneri teknikleri.....	15
Şekil 2.3: İçerik dayalı filtreleme.....	16
Şekil 2.4: İşbirliğine dayalı filtrelemenin farklı teknikleri.....	20
Şekil 2.5: Kullanıcı tabanlı işbirlikçi filtreleme sistemleri.....	21
Şekil 2.6: İçeriğe Tabanlı işbirlikçi Filtreleme.....	23
Şekil 2.7: Müşteri segmentasyonunun farklı türleri.....	32
Şekil 3.1: Amazon.csv dosya veri yapısı.....	40
Şekil 3.2: Eksik değerler.....	41
Şekil 3.3: Tamamlanmış değerler.....	42
Şekil 3.4: Fiyat ve Derecelendirmelerin Dağılım Grafiği.....	42
Şekil 3.5: Veri kümesindeki her bir benzersiz derecelendirme değerinin sıklığı.....	43
Şekil 3.6: ürünün değerlendirme değerlerinin dağılımı.....	43
Şekil 3.7: En çok puan alan 15 ürün.....	44
Şekil 3.8: En yaygın 5 kategori.....	44
Şekil 3.9: Aykırı ürünler.....	45
Şekil 4.1: kosinüs benzerliği ile tahmin hatalarının dağılımı.....	52
Şekil 4.2: Pearson korelasyonu ile tahmin hatalarının dağılımı.....	52
Şekil 4.3: NMF ile tahmin hatalarının dağılımı.....	55
Şekil 4.4: Tahmin hatalarının dağılımı.....	56

## 1. GİRİŞ

E-ticaretin yükselişi perakende dünyasını dönüştürdü ve tüketicilere çok çeşitli ürün ve hizmetlere sınırsız erişim sağladı. Ancak bu kadar çok seçenek, çevrimiçi işletmeler için önemli bir zorluğu da beraberinde getiriyor: Bilgiye boğulan bir tüketicinin dikkatini çekmek ve öne çıkmak. Çevrimiçi teknikler ve stratejiler bütünü kapsayan dijital pazarlama, potansiyel müşterilere etkili bir şekilde ulaşmak ve kalıcı ilişkiler kurmak için bir çözüm olarak karşımıza çıkıyor. Aynı zamanda, başlangıçta bilgi aşırı yüklenmesini önlemek amacıyla geliştirilen öneri sistemleri, müşteri deneyimini kişiselleştirmek ve alıcıları ilgili ürünlere yönlendirmek için güçlü araçlara dönüşmüştür.

Tavsiye sistemlerinin dijital pazarlama stratejilerine entegre edilmesi, e-ticaret için umut vadeden bir sinerjiyi temsil ediyor. Nitekim bu sistemler, web siteleri, e-postalar, çevrimiçi reklamlar ve sosyal ağlar gibi farklı dijital pazarlama kanalları aracılığıyla müşterilere kişiselleştirilmiş öneriler sunulmasını mümkün kılıyor. Bu artan kişiselleştirme, müşteri katılımını iyileştirmeyi, dönüşüm oranlarını yükseltmeyi, müşteri sadakati oluşturmayı ve sonuç olarak e-ticaret şirketlerinin ticari performansını optimize etmeyi amaçlıyor.

Sanayi Devrimi'nin ardından bilim ve teknolojiadaki gelişmeler, özellikle 1990'lı yılların başında internetin icadıyla yeni bir boyut kazandı. İnternet ile tanışan birçok firma, kısa sürede işlerini bu platforma taşıma konusunda büyük avantaj elde etti. ve aslında e-ticaretin ilk adımlarını attık. E-ticaretin kısa vadede yaygınlaşmasındaki temel etken, işletme maliyetlerini düşürmesi ve daha fazla müşteriye ulaşmayı sağlamasıdır. Sonuç olarak e-ticaretin bu hızlı yükselişi birçok sektörün de ilerlemesine yol açmıştır. Özellikle lojistik ve finans sektörleri e-ticaretin bu büyümesine kayıtsız kalamadı ve paralel bir gelişme yaşayarak e-ticaret sektörünün en yakın destekçisi oldu. E-ticaret pazarlama çalışmalarına da yeni bir boyut kazandırdı. Geleneksel pazarlama yöntemlerine ilişkin çalışmalar da buna bağlı olarak gelişmiştir. İşletmeler e-ticaret yoluyla daha fazla kitleye yayılmak istediklerinde pazarlamanın dijital tarafı keşfedildi. Özellikle günümüzde şirketler ve reklam ajansları sosyal ağlar (Twitter, Facebook, Instagram vb.) aracılığıyla tüketicilere daha hızlı ve etkili bir şekilde ulaşmaktadır (Cenk E., 2015).

Bir yetişkin günde kaç karar verir? Araştırmalara göre bir bebek günde 3.000 karar verirken, bir yetişkinin verdiği karar sayısı 35.000'e ulaşmaktadır(Sahakian, B.J. &

LaBuzetta, J.N., 2013). Bu karşılaştırmaya günümüz insanının teknolojik koşullarını da katarsak, pek çok insanın vermek zorunda olduğu hemen her kararda kendisini bir labirentin içinde bulduğunu söyleyebiliriz. Teknolojinin insan hayatını ne kadar kolaylaştırdığı aşikar ama gelinen noktada hemen her şeyin teknolojileşmesi, günümüz insanını yeni bir çıkmaza itiyor. Bu noktada öneri sistemlerinin doğuşu, teknolojinin teknoloji tarafından kolaylaştırılması olarak yorumlanabilir. Robert Allen'in 1990 yılında hazırladığı bir raporda "bilgi filtreleme sistemleri" olarak tanımlanan sistemler, gerçekte günümüzde birçok şirketin günlük işleyişi ve gelişimi için vazgeçilmez kabul edilen öneri sistemleridir (Allen, R.B., 1990). Daha dünya 2000'li yıllara gelmeden birçok bilim adamını bilgi yığınlarını filtrelemeyi düşünmeye sevk eden bilgi çağı, günümüzde şüphesiz bilgi teknolojisinin geliştirdiği yeni filtreleme teknolojilerine ihtiyaç duymaktadır. Fukushima'yı 1975 yılında insan beynindeki sinir hücrelerinin nasıl çalıştığı mantığıyla makinelerin öğrenmesinin mümkün olup olmayacağı sorusunu sormaya iten merak, sahada kullanılan makine öğrenmesi ve makinelerin bilgi alışverişine olanak sağlayan derin öğrenme ile yanıt buldu. kendi başlarına öğrenirler.

E-ticaret analitiği, eyleme dönüştürülebilir öngörüler üretmek amacıyla büyük miktarda veriyi analiz etmek için tasarlanmış herhangi bir araç veya stratejidir. E-ticaret neredeyse tamamen sanal bir alanda var olduğundan, özellikle müşteri davranışlarıyla ilgili karmaşık ve kapsamlı veri setleri üretir. Mart 2019 ile Mart 2020 arasında temel malların çevrimiçi satın alımlarındaki %200 artışla birlikte artık ölçmek, analiz etmek ve incelemek için her zamankinden daha fazla tüketici verisine sahibiz. 2017'de önceki 5.000 yılın toplamından daha fazla veri oluşturuldu (Anonim, 2025).

E-ticaret, aşağıdaki gibi çeşitli kısıtlamaların üstesinden gelerek ticarette devrim yarattı:

- Zaman: E-ticaret siteleri 24 saat hizmet vermekte olup, müşteri alışverişini günün veya gecenin her saatinde gerçekleştirebilmektedir.
- Mesafe: Müşteri, alışverişlerini yapmak için seyahat etmek zorunda kalmaz, zamandan, enerjiden ve her şeyden önemlisi paradan tasarruf eder.

Ayrıca diğer müşterilerin geri bildirimleri (Diğer müşterilerin ürünler hakkındaki yorumları) gibi daha önemli bir şeyi de sunar.

Ancak e-perakendeciler müşteri davranışlarını anlamakta zorluk çekiyorlar. Onları belirli miktarlarda satın almaya iten şey nedir, neden belirli markaları diğerlerine tercih ederler,

neden sıklıkla belirli zamanlarda satın alırlar, müşteri neden bir markayı diğerine tercih eder? neden bir ürünü değil de diğerini satın alıyorlar? satın alma neden belirli bir süre için yapılıyor? Seçimlerinizi ve satın almalarınızı etkileyen faktörler nelerdir? Neden her zaman belirli ürünleri diğerleriyle birlikte satın alıyor? E-perakendeci, bu müşterilere kaliteli bir hizmet sunabilmek için bu davranışları anlamalıdır; örneğin: müşterinin aramasını kolaylaştırmak için bu ürün sayfalarını yeniden düzenlemek, önerilerde bulunmak veya ürün sunmak. Araştırma süresinden tasarruf etmek için öneriler.

Bu davranışlar çok karmaşıktır çünkü fiyatlar, teslimat süreleri, ürünün bulunabilirliği, teslimat süreleri, ürün derecelendirmeleri, diğer müşterilerin görüşleri gibi e-ticaret sitesinin içindeki faktörlerden etkilenirler. vb. ve müşterinin bütçesi, uluslararası etkinlikler (örneğin kara Cuma), tatiller gibi e-ticaret sitesi dışındaki faktörler.

Müşteri davranışları hakkında daha fazla bilgi edinmek için derinlemesine bir analiz gereklidir. Müşteri davranışının ayrıntılı bir analizi, sitedeki yolculuklarının anlaşılmasını içerir. Davranış analizi, çevrimiçi perakencilerin müşteri ihtiyaçlarını keşfetmesine ve anlamasına yardımcı olur.

Müşteri davranışını anlamak genellikle web sitenizdeki yolculuklarının analiz edilmesiyle (müşteri oturumunun analizi) başlar; buna "tıklama akışı" da denir. Bunun için müşteriden soyadı, adı, yaşı, işi vb. açık bilgilerin toplanması gerekmektedir. Bu bilgilerin çoğu formlar aracılığıyla toplanır ve müşterinin kendisi tarafından sağlanır. Ancak müşterinin davranışını doğru bir şekilde analiz etmek ve anlamak için en önemlisi onun örtülü bilgisidir: Müşterinin ziyaret ettiği sayfa sayısı ve her biri için veya bir ürün için harcanan zaman, hangi ürünü beğendiği (beğendiği), hangi markanın olduğu. ürünü sık sık satın alıyor mu vb.

Öneri sistemleri, kayıt formları, web taraması, çevrimiçi kullanıcı davranış günlükleri, IP ve coğrafi izleme ve diğer birçok kanal dahil olmak üzere çeşitli kanallar aracılığıyla toplanabilecek girdi verilerine dayanır.

Bu bilgiler genellikle JavaScript'te (clientSide) yazılan izleme algoritmaları kullanılarak toplanır. Toplanan veri miktarı gerçekten muazzam olabilir. Doğru müşteriye doğru ürünü tavsiye etmek için bu verileri analiz etmek ve anlamak, veri madenciliği, yapay zeka ve makine öğrenmesi gibi özel teknikleri gerektirir. Bu teknikler, öneri sistemleri (kullanıcı tercihlerini tahmin etmek için kullanılan bilgi filtreleme sistemi) oluşturmak için birleştirilir.

Aslında, zaman içinde farklı filtreleme ve kümeleme algoritmalarına dayalı olarak çeşitli öneri sistemleri geliştirilmiştir. YouTube, izleyici memnuniyetini değerlendirmek ve önerileri geliştirmek amacıyla 2008 yılında öneri sistemini tasarladı ve yıllar içinde güncelleyip geliştirdi. Amazon, 2000 yılında E-ticaret platformunu kurarken öneri sistemlerini kullanmaya başladı.

Amazon, Netflix ve Twitter tarafından kullanılan işbirlikçi filtreleme, özellikle uygulama kolaylığı nedeniyle en popüler öneri sistemlerinden biridir. Ancak, soğuk başlatma, veri kıtlığı ve veri yanlışlığı gibi önemli zorluklar sunar.

Soğuk başlatma sorununu çözmek için birçok kişi en popüler ürünler, içerik tabanlı öneriler vb. gibi alternatif yöntemler önermektedir. Veri kıtlığı sorununu ele almak için yeni kullanıcılardan çıkarılan derecelendirme verilerinin eklenmesinden oluşan gerçek zamanlı öneri gibi çözümler önerilmiştir. Ancak, çok az kullanıcının ürünleri derecelendirmek için zaman ayırması nedeniyle derecelendirme verilerinin kıtlığı bu çözümü daha az etkili hale getirir.

### **Tezin Amaçları**

Bu tezin amacı, müşteri deneyiminin etkili bir şekilde kişiselleştirilmesini ve e-ticaret şirketlerinin web sitelerine yapılan ziyaretlerin artırılmasını sağlayacak, ilgili öneriler sunabilen etkili bir öneri sistemi sağlamaktır. Ve e-posta pazarlama kampanyalarının maliyetlerini azaltmaktır. Tezin ana hedefleri aşağıda maddelenmiştir.

1. E-ticarette öneri sistemlerinin ve otomatik dijital pazarlamanın etkinliğine ilişkin ampirik kanıtları, bilimsel literatür ve vaka çalışmaları kullanarak incelemek.
2. Kullanıcılara ilgili ürünleri önerebilen etkili bir öneri sistemi sağlamak.
3. E-posta pazarlama kampanyaları için daha iyi müşteri segmentasyonu amacıyla makine öğrenimini kullanan basit ve etkili bir sistem sağlamak.

### **Araştırma Yöntemi**

Bu çalışmada, veri madenciliği ve makine öğrenmesi tekniklerinin bir araya getirilmesiyle, müşteri işlem verileri ile ürün inceleme verileri arasındaki kalıpları ve

eğilimleri keşfederek müşterilere ilgili öneriler sunabilen etkili bir öneri sistemi oluşturulmuştur. Farklı müşteriler arasındaki benzerlikleri keşfetmek ve onları farklı sınıflara (kümelere) ayırmak için de aynı süreç kullanılmaktadır. Böylece hedefli pazarlama kampanyalarıyla bu farklı müşteri sınıflarına ulaşmak mümkün olabilmektedir.



## 2. LİTERATÜR ÖZETLERİ

### 2.1 E-Ticaretin Tanımı Ve Kapsamı

E-ticaretin pek çok tanımı olmasına karşın en basit haliyle; telekomünikasyon ağları üzerinden ürünlerin üretimi, reklamı, satışı ve dağıtımının yapılması olarak tanımlanabilir (Subaşı, H.H., 2012).

E-ticaret, mal ve hizmet satın alma ve satma şeklimizi kökten değiştirdi. 1960-1970 yıllarında kurulan şirket, teknolojik gelişmelerin ve tüketici davranışlarındaki değişimlerin etkisiyle katlanarak büyüme kaydetti.

E-ticaretin başlangıcı, Fransa'da Minitel gibi elektronik veri değişimi ve mesafeli satış sistemlerinin oluşturulmasıyla 1960'lara dayanmaktadır(WiziShop, 2021). Ancak e-ticaretin gerçek anlamda yaygınlaşması 1990'ların başında World Wide Web'in ortaya çıkmasıyla gerçekleşti. 1995 yılında kurulan Amazon ve eBay gibi platformlar, çevrimiçi ticarete devrim yaparak alım satımda yeni bir çağın başlangıcını oluşturdu.

İnternetin demokratikleşmesi ve erişim maliyetlerinin düşmesi, giderek daha fazla sayıda tüketicinin çevrimiçi alışverişin avantajlarını keşfetmesine olanak sağladı: kolaylık, daha geniş seçenek yelpazesi ve çoğu zaman daha rekabetçi fiyatlar. Aynı zamanda, büyük perakendecilerden küçük butiklere kadar giderek daha fazla işletme, daha geniş bir kitleye ulaşmak için çevrimiçi imkanların önemini fark etti.

E-ticaretin büyümesi yıllar geçtikçe ivme kazanırken, son rakamlar da bunun canlılığını ortaya koyuyor. Fransa'da küresel e-ticaret geliri 2024 yılında bir önceki yıla göre %9,6 artışla 175,3 milyar avroya ulaştı. İşlem sayısı da artarak 2024 yılında 2,6 milyara ulaşacak ve bir önceki yıla göre %10 artacak (Jacuński, M., 2018). E-ticaretin geleneksel perakende işletmelerine göre üç temel avantajı bulunmaktadır.

1. Öncelikle e-ticaret, zaman ve mekan sınırlarını ortadan kaldırarak, 7/24 saat çalışma moduyla tüketicilere benzersiz bir satın alma özgürlüğü sağlıyor;
2. Karlılık avantajı, şirketin ara bağlantı ve işletme maliyetlerini azaltarak hem karlılığı artırması, hem de tüketicilere fayda sağlaması;
3. Bilgi, multimedya ekranları, kullanıcı derecelendirme sistemi ve akıllı öneri sisteminin entegre edilebilmesi, bilgi asimetrisini önemli ölçüde azaltıyor.

Bu özellikler bir araya gelerek e-ticareti modern ticaret sisteminin vazgeçilmez bir parçası haline getirmiş, küresel ticaret yapılarını ve tüketici davranışlarını yeniden şekillendirmeye devam etmiştir (Anonim, 2025).

[Baily ve diğerleri, 1994] tarafından yayınlanan bir makalede, analizlerine dayanarak e-ticaretin geliştirmesi gereken 5 satın alma hakkının ne olması gerektiği açıklanmaktadır:

- Doğru fiyat
- Zamanında teslim
- İyi kalite
- Doğru miktar
- Doğru kaynaktan.

Türkiye İstatistik Kurumu'nun raporuna göre, 2021 yılında internet kullanan kişilerin %44,3'ü mal ve hizmet satın almak için interneti kullanırken, 2020 yılında bu oran %36,5 olmuştu. Aynı istatistiklere göre, kişilerin %70,7'si başta giyim, ve aksesuar olmak üzere alışverişlerini internet üzerinden sağlamaktadır. Bunların aralarında %40,8'i yemek siparişini de zaman zaman internet üzerinden verdiğini belirtmiştir. Ayrıca Türkiye ticaretinin yaklaşık %18'ini e-ticaret faaliyetleri oluşturmaktadır (Mordor Intelligence, “<https://www.mordorintelligence.com/tr/endustri-raporlari/turkiye-eticaret-pazari>”). eticaret.gov.tr verilerine göre, Türkiye'de perakende e-ticaretin payı Aralık 2021'de %20,4'e ulaşırken, be değer Ocak 2020'de %11,7 civarındaydı.

Tablo 2.1. En popüler e-ticaret kategorileri (Anonim, 2025)

Kategoriler	Tanım
B2B(Business to Business)	B2B modeli, hammadde temini ve toptan satış gibi tedarik zinciri faaliyetlerini de içeren işletmeden işletmeye yani ticari işlemlere odaklanır. Yüksek değerli, düşük frekanslı işlemleri, karmaşık sözleşme süreçlerini ve uzun vadeli ilişkileri içerir. Örnekler: Alibaba International, HC.com.
B2C (Business to Consumer)	Bu model, şirketlerin doğrudan son kullanıcılara satış yapmasını içerir. Ödeme, lojistik ve müşteri hizmetleri sistemlerine yönelik destekle kullanıcı deneyimini optimize etmeye odaklanır. Örnekler: Amazon, Jindong.
C2C(Costumer to Customer)	Tüketiciden tüketiciye anlamına gelen bir pazaryeri ticaret modelidir. Alıcı ve satıcıları birleştiren sistem alım satım üzerinden belirli bir komisyonla çalışır. Asıl zorluk güvenilir bir kredi sistemi kurmaktır. Örnekler: N11, Trendyol, Amazon...
C2B (Consumer-to-Business)	Tüketicilerin talebi başlattığı ters bir modeldir. Bu modelde tüketiciler işletmecilere mal veya hizmet sunarlar. Bu kategoride üretim firmalarının taleplere cevap verebilmesi için esnek üretim kapasitesine ihtiyacı vardır. Örnek: Upwork, Fiverr, TaskRabbit...

## 2.2 E-Ticaretin Kökenleri

E-ticaret veya elektronik ticaret, ekonominin vazgeçilmez bir sektörü ve önemli bir ayağı olup, milyarlarca insanın hayatının ayrılmaz bir parçasıdır. E-ticaret kavramı, İnternetin ilk günlerinden bu yana büyüyüp gelişti. Ve bunu bir önceki bölümde belirttiğimiz gibi pek çok istatistik kanıtıyor.

E-ticaretin tarihi 50 yılı aşkın bir süreye dayanıyor ve günümüzdeki seviyelere gelmesinde etkili olan pek çok önemli etken vardır. Bu dönemde müşterilerin ve

işletmelerin web üzerinde etkileşim kurma biçimleri pek çok yeniliklerle değişti (WiziShop, 2021)

Teknoloji uzmanları, 1960'lı yıllarda Elektronik Veri Değişimi'nin (EDI) yayılmasıyla e-ticaretin tohumlarını ekmiş odular. Bu sistem sipariş ve faturalara ait verilerin dijital ortamda aktarılmasına olanak sağlamıştır. Tarihsel gelişimine bakıldığında bu, elektronik işlemlerin ilk örneğiydi.

Daha sonra 1969 yılında Dr. John R. Goltz ve Jeffrey Wilkins, ilk İnternet ticaret hizmetlerinden biri olan CompuServe'i kurdular. Sonraki yirmi yıl içerisinde CompuServe e-posta pazarlamasının lideri haline geldi. Ayrıca e-ticaret ve online satış hizmetlerinin (WiziShop, 2021) gelişmesinde de önemli rol oynadılar ve 1979'da İngiliz mühendis Michael Aldrich'in yenilikçi deneyleri daha da devrimseldi - televizyon ve bilgisayar bağlantısının dönüşümü sayesinde, online alışverişin teknik prototipi olarak kabul edilen mesafeli satış sisteminin ilk kez gerçekleştirilmesini sağlamışlardır (Anonim, 2025).

1982 yılında Alexander Randall ve Cameron Hall, kullanıcıların öncelikle bilgisayar parçalarını alıp satmak ve takas etmek için kullandıkları ilk çevrimiçi ticaret şirketi olan Boston Computer Exchange'i kurdular.

Yine 1982 yılında Fransız geliştiriciler, günümüz internetinin başlıca öncülerinden biri olan Minitel'i piyasaya sürdüler. Minitel, kullanıcıların telefon hattı üzerinden erişebildiği bir Videotex terminali kullanıyordu. Videotex, metin bilgilerinin genellikle telefon veya kablolu televizyon hatları üzerinden iletildiği ve bir televizyon veya video görüntüleme terminalinde görüntülediği bir elektronik veri alma sistemidir. 1990'ların sonuna gelindiğinde hizmetin yaklaşık 25 milyon kullanıcısı vardı. Ancak hizmet, 1994 yılında tanıtılması planlanan İnternet ile rekabet edemediği için yavaş yavaş geriledi (T.L. Saaty, 2008).

1989 yılında Tim Berners-Lee tarafından internet tarayıcısı aracılığıyla web sayfalarına erişime olanak sağlayan dünya çapındaki web'in (www) icat edilmesi, 90'ların en önemli olaylarından biri olarak karşımıza çıkmaktadır (Amandine Dujardin, 2024).

Google ortaya çıkmadan önce, Marc Andreessen ve Kim Clark dünyanın ilk web tarayıcısı olan Netscape Navigator'ı piyasaya sürdüler. Netscape tarayıcısı, 1990'lı yıllarda Windows cihazlardaki birincil web tarayıcısıydı.

Ortaya çıkışından itibaren internet giderek daha demokratik hale geliyor ve internet dünyanın her yerinden kullanıcılarla doluyordu. Dolayısıyla 1990'lı yıllarda internetin yükselişi e-ticaretin gelişmesinin anahtarı oldu. 1991 yılında World Wide Web halka açık hale geldi ve 11 Ağustos 1994'te Güvenli Yuva Katmanı (SSL) protokolünün tanıtılmasıyla ilk güvenli çevrimiçi işlem tamamlandı. Bu güvenlik teknolojisi, online ticaretin yaygınlaşmasına kesin bir kapı açıyordu. World Wide Web'in 3w'si, www.kwantic.fr gibi her site adının önünde bulunan baş harflere karşılık gelir. Dönemin kitap devi Amazon'da 1994 yılında kurulmuş, büyük ölçekli e-ticaretin temellerini atmış ve e-ticaret pazarında öncü konuma gelmiştir. Bu fırsat, onun bugün bildiğimiz online satış devi haline gelmesini sağlamıştır.

### **2.3. E-Ticaretin Altın Çağı (2000-2010)**

2000'li yıllar, teknolojik yenilikler ve online satışlardaki üstel büyümeyle e-ticaretin başarısı için en belirleyici dönem olmasa da dönüm noktası olmuştur. Dolayısıyla o yıllarda online ticaretin yükselişe geçmesi, onu güvenli ve karlı bir tüketim yöntemi olarak ortaya koymuştur.

2000 yılı Amazon ve eBay gibi e-ticaret devlerinin yükselişine tanıklık etti. Amazon, ürün yelpazesini kitapların ötesine taşıyarak, ürünlerini çeşitlendirmeyi ve günümüzde bildiğimiz şekliyle "dijital Ali Baba'nın mağarası" olmayı hedeflemiştir.

eBay firması ise insanların akıllarına gelebilecek hemen her şeyi alıp satabilecekleri bir platform oluşturmuştur. O zamanlar, biraz nadir bir şey ararken bu platforma yönelmek yaygındı. Özellikle farklı milletlerden ikinci el eşyalar insanlara, hayatlarında ilk kez gördükleri ürünleri alabilme fırsatı sunuyordu.

Sosyal medyanın gelişi ve demokratikleşmesi e-ticaret için yeni fırsatlar oluşturdu. Facebook gibi platformlar işletmelerin müşterileriyle doğrudan bağlantı kurmasına olanak tanırken, YouTube gibi platformlar ise video pazarlaması için fırsatlar sundu. İşletmeler görünürlüklerini artırmak ve tüketicilerle etkileşim kurmak amacıyla sosyal medyayı e-ticaret stratejilerine entegre etmeye başladılar. Bugün bile YouTube, bir numaralı en karlı dijital pazarlama reklam platformu olarak gelişmeye devam ediyor. Instagram veya Tiktok gibi diğer sosyal ağlar ise özellikle influencer'ların yükselişi sayesinde artık B2C E-ticaret sektörünün lideri konumuna gelmiştir.

Kısacası e-ticaretin başlangıcı, ilk online mağazaların kurulmasına zemin hazırlayan İnternet ve Web'in ortaya çıkmasıyla başladı. O tarihten bu yana mobil ve sosyal ağların yükselişyle sektör katlanarak büyüdü. Günümüzde e-ticaret, tüketicilerin ihtiyaç ve beklentilerini karşılamak için sürekli gelişen, küresel ekonominin önemli bir sektörü haline gelmiştir.

## **2.4 Dünyada E-Ticaretin Patlaması**

2022'deki COVID-19 kriziyle birlikte e-ticaret, Avrupa'da ve dünya çapında büyük bir genişleme yaşadı ve küresel e-ticaretin ölçeğini katlanarak artıran beklenmedik bir ivme kazandı. Tüketiciler fiziksel mağazalara gitmekten kaçınmak için giderek daha fazla internete yöneliyordu. O zamandan beri şirketler fiziksel mağazalar ile çevrimiçi mağazaları birleştiren çok kanallı stratejiler geliştirmeye başladılar (Amandine Dujardin, 2024) (WiziShop, 2021).

Ancak e-ticaretin bu kadar hızlı yaygınlaşması ve çevrimiçi verinin bu kadar artması yeni bir sorunu da beraberinde getiriyordu. Müşterilere satın alma süreçlerinde nasıl yardımcı olabilirsiniz? Onların ihtiyaçlarını nasıl öngörebiliriz? Doğru ürünü bulmalarına nasıl yardımcı olabiliriz? Ve tüm bu soruların cevabı günümüzde makine öğrenmesi ve öneri sistemlerinde aranmaktadır.

## **2.5 Makine Öğrenimi**

Makine öğrenmesi, 1959 yılında bilgisayar biliminin bir alt dalı olarak ortaya çıkmıştır. Makine öğrenmesi, yapıya bağlı olarak verilere dayalı tahminlerde bulunabilen algoritmalar oluşturma sistemidir. Bu algoritmalar, verilere dayalı tahminlerde bulunmak ve kararlar almak için kullanılır. Girdilerden modeller oluşturarak çalışır ve makinelerin insan öğrenme sistemini öğrenmesinin mümkün olup olmadığı fikrine dayanır (Minculete, G. & Olar, P., 2018).

Müşteri tercihlerini anlamak için teklifleri kişiselleştirmek amacıyla makine öğrenmesi kullanılıyor. Makine öğrenimi algoritmaları, müşteri verilerini inceleyerek bireysel tercihleri tahmin etme ve her müşterinin farklı gereksinimlerine uygun ürün veya hizmetler için kişiselleştirilmiş öneriler sunma yeteneğine sahiptir (Bhatnagar & Tyagi, 2021).

En popüler 3 makine öğrenmesi algoritması türü şunlardır:

- Regresyon: Bir deęişkenin bir veya daha fazlasına göre ilişkisini bulmak için kullanılır. Örneęin, bir evin fiyatını yüzey alanı, kat sayısı, konumu vb. gibi özelliklere göre tahmin etmek. Sorun, eğitim verilerine dayalı bir hesaplama fonksiyonunu tahmin etmektir.
- Karar ağaçları: Bunlar, sınıflandırma problemlerinin yanı sıra regresyon problemlerinde kararları ve karar almayı görsel ve açık bir şekilde temsil etmek için kullanılır.
- Yapay sinir ağları: Yapay sinir ağı, insan beyninin işleyişinden esinlenerek oluşturulmuş bir bilgisayar modelidir. Konuşma tanıma, nesne tanıma veya spam tespiti gibi karmaşık sorunları çözmek için makine öğreniminde kullanılır (Anonim, 2023).

## 2.6 Öneri Sistemleri

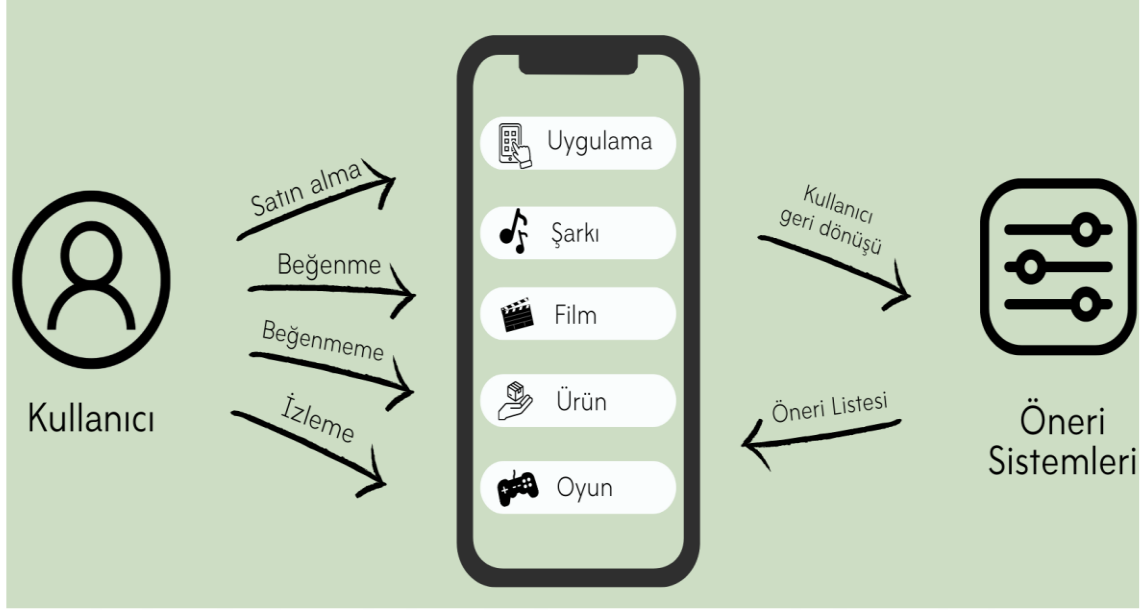
Son yıllarda bilgi hacminde inanılmaz bir büyüme yaşanıyor. İnternet destekli medya sayesinde bilgi akışı inanılmaz bir hıza ulaştı. Bu şekilde insanlar her alanda çok sayıda alternatifle karşı karşıya kalmaktadır. Daha önce herhangi bir ürüne, habere veya bilgiye erişmek için çaba sarf etmek gerekirken, bugün aynı çabayı, hatta belki daha fazlasını, mevcut bilgi hacmini filtrelemek için harcamak gerekiyor (Allen, R.B., 1990).

Tavsiye sistemleri, seçimlerimizde karar almamızı kolaylaştıran bir destek aracı olarak ortaya çıkmıştır. Öneri sistemlerinin tasarımında kullanılan teknikler, hizmet verilen alana ve mevcut verilerin karakteristik özelliklerine bağlı olarak deęişmektedir (Allen, R.B., 1990).

Öneri sistemi, öneri motoru, öneri aracısı veya öneri algoritması olarak da bilinen, bireylerin tercihlerini, ilgi alanlarını, zevklerini ve önceki arama ve satın alma geçmişini gibi gözlemlenen davranışlarını dikkate alarak belirli kullanıcılara en uygun ürünleri önermek için kullanılan bir yazılım teknolojisidir (Aggarwal, 2016; Jannach, D., Zanker, M., Felfernig, A., Friedrich, G., 2011). Grundy adı verilen ilk öneri sistemi 1979 yılında oluşturuldu. Grundy, kullanıcıların mükemmel kitabı bulmalarına yardımcı olmak için tasarlanmış bilgisayarlı bir kütüphaneydi. Grundy, kullanıcıları demografik özelliklerine, daha önce okuduklarına ve ilgi alanlarına göre, uygun kitaplarla eşleştirmek için kalıp yargılar oluşturmuştur (Rich, 1979).

İlk Grundy öneri sisteminden bu yana, öneri sistemleri her zaman aynı hedefle gelişmeye devam etti: Müşteri deneyiminin en iyi şekilde kişiselleştirilmesini sağlamak.

Öneri sistemleri günümüzde e-ticaret, perakende, akış hizmetleri, bankacılık ve telekomünikasyon gibi farklı alanlarda, kullanıcıların tercihlerini tahmin ederek ve bir dizi algoritma aracılığıyla öneriler sunarak bilgileri filtrelemelerine yardımcı olmak amacıyla yaygın olarak kullanılmaktadır (Pearl Pu, Li Chen, Rong Hu, 2011).



Şekil 2.1. Öneri sistemleri  
(Ferreira ve diğ., 2020)

### 2.6.1 Öneri sistemlerinin kullanışlılığı

Öneri sistemi, kullanıcıya kullanmak istediği belirli bir öge hakkında öneriler sunar. Bu tanım artık bir sistemin oynayabileceği farklı rolleri temsil ederek geliştirilebilir. Öneri sistemi kullanıcıya bağlı olarak farklı roller oynar; örneğin; Expedia.com ve Visitfinland.com gibi bir seyahat aracısının kullandığı öneri sistemi genellikle geliri artırmak için kullanılırken, sistemleri kullanan müşterinin amacı, bir destinasyonu ziyareti sırasında uygun bir otel ve ilginç etkinlikler/turistik yerler bulmaktır (Sachi Nandan Mohanty et al., 2020).

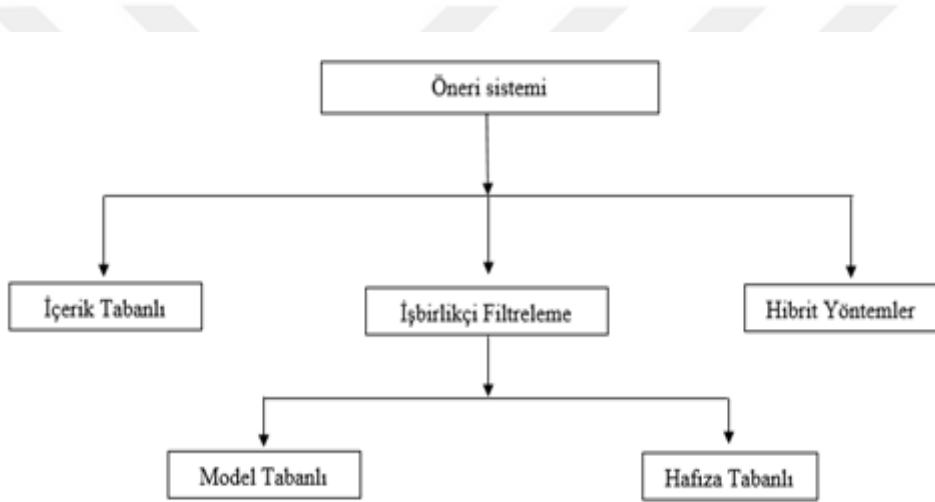
## 2.6.2 Öneri sistemlerinin kullanılmasının bazı nedenleri

1. *Ürün satışlarını artırmak*: Satış temsilcisinin temel amacı satışları artırmak, başka bir deyişle referans olmadan satılamayan ürünleri de satmaktır. Öneriler, önerilen ürün ve hizmetlerin müşterinin gereksinimlerini karşılması esas alınarak sağlanır. Ticari olmayan öneriler benzer amaçlarla kullanılmaktadır. Sitesindeki haber okuyucu sayısını artırmak isteyen bir içerik yazarı örneğini ele alalım. Öneri sistemini kullanan hizmet sağlayıcının amacı, siteye göz atan kullanıcı sayısına göre ürün veya hizmetleri tercih eden kullanıcı sayısını artırmaktır.
2. *Çeşitli ürün satışı*: Öneri sistemleri, ayrıca kullanıcının belirli bir SKU(stok tutuma birimi) olmadan bulunması zor olabilecek ürünleri bulmasına da yardımcı olur. Örneğin Netflix'te kullanılan öneri sistemi, en popüler filmleri değil, listedeki maksimum sayıda filmi kiralamayı hedefliyor. Hizmet sağlayıcı kullanıcının zevklerine uymayan videolar önerme riskini alamayacağından, bir öneri sistemi olmadan bu tür önerilerde bulunmak zor olabilir. Bu sayede öneri sistemi popüler olmayan filmleri de önermek zorunda kalmaktadır.
3. *Kullanıcı memnuniyeti*: Öneri sistemi, kullanıcının uygulama veya web sitesiyle ilgili deneyimini iyileştirmeye yardımcı olur. İlginç, anlamlı ve konuyla ilgili öneriler sunar ve daha iyi insan-makine etkileşimi sağlar. Etkili öneriler, yani doğru ve etkileşimli bir kullanıcı arayüzü, sistemin kullanımını ve önerilerin dikkate alınma şansını artırmaktadır.
4. *Kullanıcı sadakati*: Bir müşteri her zaman geçmiş kullanıcılarını tanımlayan ve onlara saygı duyulan/değer verilen bir müşteri gibi davranan bir web sitesini veya uygulamayı kullanmayı tercih eder. Bu, öneri sisteminin ortak bir özelliğidir; çünkü ürün incelemeleri gibi önceki etkileşimler sırasında kullanıcıdan elde edilen verileri dikkate alarak önerileri/önerileri hesaplar. Dolayısıyla müşteri belirli bir siteyi ne kadar çok kullanırsa modeli o kadar iyileşir, yani sonuç kullanıcının tercihlerine göre daha kişiselleştirilmiş olur.
5. *Kullanıcı ihtiyaçlarını daha iyi anlamak*: Öneri sistemi, sistem tarafından yapılan tahminleri, toplayarak kullanıcı tercihlerini öğrenen kişi olarak hareket eder. İşletme sahipleri daha sonra bu bilgileri envanter yönetimini veya ürün üretimini iyileştirmek için yeniden kullanabilirler (Sachi Nandan Mohanty et al., 2020).

6. Tavsiye sistemleri, önerilerde bulunmak için farklı türdeki bilgileri aktif olarak toplayan bilgi çıkarma sistemidir. Gerçekler çoğunlukla nelerin önerileceği ve hangi tüketicilerin bu önerileri alacağı ile ilgilidir. Mevcut veri kaynakları çok geniş ve çeşitlidir; tavsiyelerde bulunmak için bunların kullanımı büyük ölçüde yararlanılacak tavsiye tekniklerine bağlıdır.

### 2.6.3 Öneri sistemi türleri

Sorun alanı, kullanılan bilgi ve en önemlisi tahmin yapmak için kullanılan öneri algoritması açısından farklılık gösteren farklı türde öneri sistemleri vardır. Resim 2’de gösterildiği gibi esas olarak iki tür öneri sistemi vardır; içerik tabanlı (ÖS) yöntemleri ve işbirlikçi filtreleme yöntemleri.



Şekil 2.2. Farklı öneri teknikleri

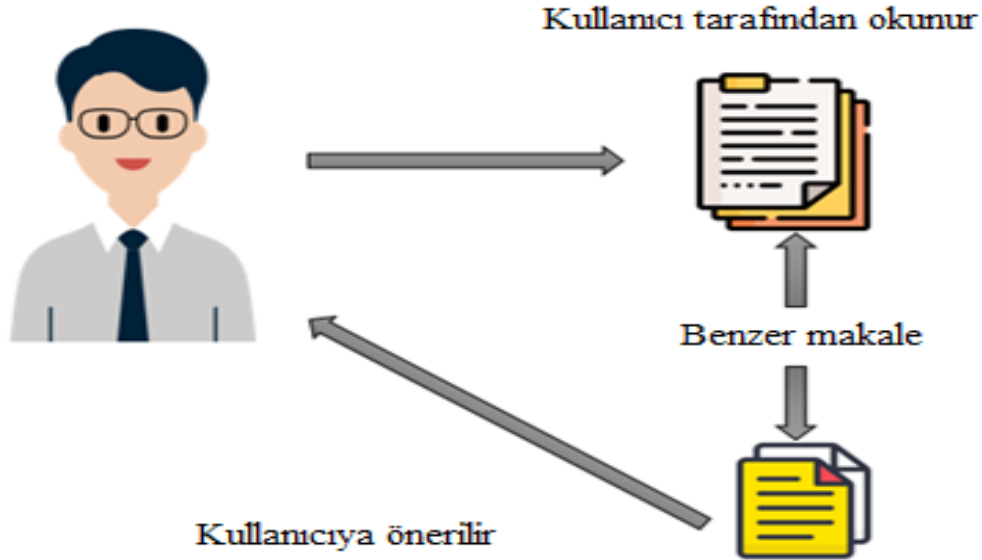
### 2.6.4 İçerik Tabanlı Öneri Sistemleri

Ürün bazlı filtreleme olarak da adlandırılan içerik bazlı filtreleme teknikleri, kullanıcıya geçmişte satın aldığı veya tükettiği ürünlere göre benzer ürünleri önerir.

Kullanıcı tarafından gönderilen önceki yanıtlara göre sistem, öğeler arasındaki özelliklerin benzerliğini analiz ederek önerilerde bulunmayı öğrenir. Örneğin, kullanıcının farklı film türlerini derecelendirmesine bağlı olarak sistem, kullanıcı tarafından olumlu olarak değerlendirilen türü tavsiye etmeyi öğrenecektir. İçerik tabanlı öneri sistemi, kullanıcı tarafından daha önce derecelendirilen öğelere dayalı olarak bir kullanıcı profili oluşturur. Bir kullanıcı profili, kullanıcının ilgi alanlarını temsil eder ve aynı zamanda yeni ilgi alanlarına uyum sağlama yeteneğine de sahiptir. Kullanıcı

profilinin içerik nesnesinin özellikleriyle eşleştirilmesi öneri sürecinin temelini oluşturmaktadır. Bu sürecin sonucu kullanıcının nesneye olan ilgisini ifade eden bir yargıdır ve bu sayede kullanıcı ilgi alanlarının doğru olarak belirlenmesi, bilgi erişim sürecinin yararlılığına dönüşecektir. Örneğin, bir kullanıcının belirli bir sayfayla ilgilenip ilgilenmediğini belirleyerek web sonuçlarını filtrelemek için kullanılabilir.

Öğe tabanlı veya öğeden öğeye yaklaşım, bir kullanıcının bir öğeye ilişkin tercihini, kullanıcının benzer öğeleri nasıl derecelendirdiğine dayanarak türetir. İşbirliği filtrelemeden farklı olarak, içerik tabanlı öneri, bu özelliklere ağırlık biçiminde önem atayan bir profille birlikte öğe açıklamalarının kullanılabilirliğine dayanır. Bu, kullanıcıların çeşitli öğeler veya ürünler için genel olarak kriterleri ve ilişkili ağırlıkları belirlediği ve daha sonra bu öğelerin ve ürünlerin belirli örnekleri için tercihlerin sıralı bir listesini oluşturmak için kullanılabilen analitik hiyerarşi süreci gibi çok kriterli karar alma modellerinin bir çeşididir. Bu yaklaşımın uygulanmasında uygun benzerlik ölçütlerinin tanımlanması büyük önem taşımaktadır (T.L. Saaty, 2008).



Şekil 2.3. İçerik tabanlı filtreleme

Öneri süreci her biri ayrı ayrı ele alınan 3 adımdan oluşur.

- 1) *İçerik analizi*: Verilerin yapılandırılması amacıyla ön işleme yapılması gerekir. İçerik ayrıştırıcının temel sorumluluğu, kaynaktan gelen içeriği

sonraki işlem adımlarına uygun bir biçimde temsil etmektir. Özellik çıkarma teknikleri, öge yapısını orijinalden hedefe (örneğin, anahtar kelime vektörleri olarak temsil edilen web sayfaları) doğru değiştirmek için kullanılır. Bu gösterim bir sonraki adıma girdi olarak uygulanır.

- 2) *Öğrenme*: Bu modül, önceki bileşenden elde edilen verileri genelleştirerek kullanıcı profilini oluşturur. Kullanıcıların hem olumlu hem de olumsuz geçmiş tercihlerine dayalı bir model oluşturmaya yardımcı olan genelleme stratejisini öğrenmek için makine öğrenimi teknikleri kullanılır. Örneğin, bir web sayfası tavsiye sisteminin profil öğrencisi, olumlu ve olumsuz geri bildirimleri kullanıcı profilini temsil eden bir prototip vektörde birleştiren bir alaka geri bildirim yöntemini uygulayacaktır.
- 3) *Filtreleme Bileşeni*: Bu modül, ilgili öğeleri türetmek için kullanıcı profilini kullanır. Bu, profil tavsiye edilecek öğelerle eşleştirerek yapılır. Benzerlik ölçümlerine dayanarak ikili veya sürekli olarak ilgili bir karar üretilir.

İçerik öneri sistemleri, öneri fikrini kullanıcının satın aldığı veya beğendiği öğelere dayalı geçmiş verilerinden öğrenir. Tahmin yapmada kullanıcı ve öge özellikleri eşit derecede önemlidir.

Duygu puanı gibi özelliklerin çıkarılması için TF-IDF(Terim Frekansı-Ters Belge Frekansı) puanları kullanılmaktadır. Bu yaklaşımda her kullanıcının ve her ögenin profili oluşturularak iki vektör elde edilir.

- 1) *Öge vektörü*: N uzunluğunda ve yüksek TF-IDF'ye sahip kelimeler için 1, aksi takdirde 0 değerini içeren bir vektördür.
- 2) *Kullanıcı vektörü*: Her kelimenin bulunma olasılığını içeren  $1 \times N$  vektör. Kullanıcı vektörü ögenin niteliklerine dayanmaktadır. Daha sonra aşağıdaki yöntemler kullanılarak kullanıcı ile makale arasındaki benzerlik hesaplanır:

**A) Kosinüs Benzerliği**: Kullanıcı ile öge arasındaki benzerliği ölçmek için kullanılır. Bu yöntem kullanıcı ögesi benzerliğini sağlar. Özellikle bilgi alma ve metin madenciliği gibi yüksek boyutlu özelliklere sahip olduğumuzda en uygundur. Değer aralığı -1 ile 1 arasındadır ve iki yaklaşım vardır:

- *Top-n yaklaşımı*: Bu yaklaşıma göre n en iyi ürün tavsiye edilir ve “n” değeri kullanıcı tarafından belirlenir (Aras, M.E., 2010).

- *Derecelendirme ölçeği yaklaşımı:* Bu yaklaşımda önceden belirlenmiş bir eşik belirlenmekte ve bu eşğin üzerinde değere sahip tüm maddeler Denklem 1'e göre önerilmektedir.

$$\text{consine}(x, y) = \frac{\sum_{i=1}^n X_i Y_i}{\sqrt{\sum_{i=1}^n X_i} \sqrt{\sum_{i=1}^n Y_i}} \quad 1$$

**B) Jaccard Benzerliği:** Bu benzerlik Denklem 2 kullanılarak hesaplanır. Yöntem, öge vektörlerini birbiriyle karşılaştırır ve en benzer öğeyi döndürür. Bu yalnızca ikili vektörlerde kullanışlıdır. Derecelendirmelerin veya sıralamaların birden fazla değeri varsa bu yöntem geçerli değildir.

$$J(X, Y) = \frac{|X \cap Y|}{|X \cup Y|} \quad 2$$

**C) Öklid Uzaklığı**

$$\text{Öklid uzaklığı} = \sqrt{(X_1 - Y_1)^2 + \dots + (X_n - Y_n)^2} \quad 3$$

**D) Pearson Korelasyonu:** Denklem 4'te verilen formül kullanılarak hesaplanır. İki element arasındaki korelasyonu gösterir. Daha yüksek korelasyon, daha yüksek benzerlik anlamına gelir.

$$r(u, v) = \frac{\sum (u_i - \bar{u})(v_i - \bar{v})}{\sqrt{\sum (u_i - \bar{u})^2} \sqrt{\sum (v_i - \bar{v})^2}} \quad 4$$

Denklemden geçen parametreler, r, Pearson korelasyon katsayısı,  $u_i$  ve  $v_i$  sırasıyla U ve V değişkenleri için ayrı veri noktaları,  $\mu_u$  ve  $\mu_v$  sırasıyla U ve V değişkenlerinin ortalamalarını ifade eder.

### 2.6.5. İçeriğe dayalı önerinin avantajları

*Kullanıcı Bağımsızlığı:* İçerik bazlı öneri sistemi, yalnızca kullanıcının puanına veya geçmişteki satın alma işlemlerine göre bir kullanıcı profili oluşturur. Kendisiyle aynı ilgi alanlarına sahip kullanıcının profilini oluştururken hiçbir komşu dikkate alınmaz.

*Yeni Öge:* İlk inceleme sorunu yaşanmaz, yani bir öge herhangi bir kullanıcı tarafından derecelendirilmemiş olsa bile yine de o öğeyi kullanıcıya önerebilir.

## 2.6.6. İeriĐe dayalı nerinin dezavantajları

*Sınırlı ierik analizi:* İerik tabanlı neri sistemlerinin eksikliklerinden biri de geyle iliŐkilendirilen ieriĐin sayı ve zellik tr aısından sınırlı olmasıdır. neride bulunmak iin alan bilgisi de nemlidir.

*AŐırı uzmanlaŐma:* İeriĐe dayalı neri sistemleri halihazırda tketicilere benzer geleri nerme eĐilimindedir, bylece bir “filtre balonu” oluŐturulur ve kullanıcının eŐitli ieriklere maruz kalması sınırlanır.

*KiŐiselleŐtirme eksikliĐi:* Sistem yalnızca ge zelliklerine dayandıĐından, hassas kullanıcı tercihlerini veya zevk nanslarını yakalayamayabilir ve bu da daha az doĐru nerilere yol aabilir.

*SoĐuk baŐlangı sorunu:* Yeni bir kullanıcı veya ge tanıtıldıĐında sistemin neride bulunmak iin yeterli verisi olmaması, ilgili nerilerin yapılmasını zorlaŐtırır.

*Madde tanımlarına gvenmek:* Madde tanımlarının kalitesi ve doĐruluĐu, neri sisteminin etkinliĐi üzerinde nemli bir etkiye sahip olabilir. YanlıŐ veya eksik aıklamalar, yetersiz nerilere yol aabilir.

*Sınırlı leklenebilirlik:* ge ve kullanıcı sayısı arttıĐa sistemin hesaplama karmaŐıklıĐı ve bellek gereksinimleri artabilir ve leklendirmeyi zorlaŐtırabilir.

## 2.6.7. İŐbirliki filtreleme

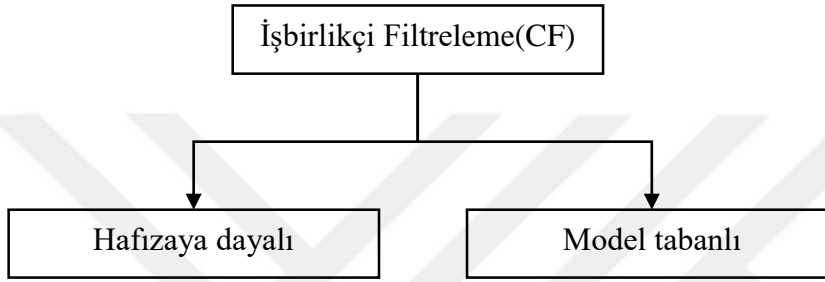
İŐbirliĐine dayalı filtreleme, ortak ilgi alanlarına sahip diĐer kullanıcılar tarafından satın alınan veya tketiciler gelere gre nerilerde bulunur.

Bu yaklaŐım, neri yapmak iin “kullanıcı davranıŐını” kullanır. Bu yaklaŐımda kullanıcılara veya makalelere karŐılık gelen herhangi bir iŐlevsellik yoktur. Bir fayda matrisi kullanır ve herhangi bir ek bilgiden baĐımsız olduĐundan endstrilerde en sık kullanılır.

İŐbirliki filtreleme, kullanıcının sistemdeki her bir geyle etkileŐimlerini haritalamak iin bir matris kullanır. Sistem daha sonra bu matristen deĐerleri ıkararak bunları vektr uzayında veri noktaları olarak gsterir. Daha sonra eŐitli gstergeler noktalar arasındaki

mesafenin ölçülmesine olanak vererek kullanıcı-kullanıcı ve öge-öge benzerliğinin hesaplanmasına olanak tanır.

İçerik bazlı öneri sisteminin sınırlamaları işbirlikçi yaklaşımla aşılabılır, örneğin içeriği mevcut olmayan makaleler için tahminler yapılabilir. Bu öğeleri tavsiye etmek için diğer kullanıcıların yorumlarını kullanır. Bu sistemler bir makalenin kalitesini hakem incelemesine dayalı olarak değerlendirir. Ayrıca diğer kullanıcılar içeriğe ilgi gösterdiği sürece farklı içeriğe sahip ürünler de önerebilir. Şekil 4’de gösterildiği gibi işbirlikçi filtrelemenin iki kategorisi vardır:



Şekil 2.4. İşbirliğine dayalı filtrelemenin sınıflandırılması.

### 2.6.8. Hafızaya dayalı yaklaşım

Bilgiye dayalı sistemler, kullanıcının ihtiyaçlarına ve ilgili bilgilere dayanarak öge önerileri sağlar. Genellikle sistemin kullanıcı hakkındaki benzersiz bilgilere dayanarak önerilerde bulunduğu çıkarıma dayalı olarak çalışır.

Hafızaya dayalı öneri sistemleri, içeriğe dayalı öneri sistemlerine çok benzer ve iki yöntem arasındaki ayrım çizgisini ayırt etmek zor olabilir. Ancak bilgiye dayalı sistemler benzersizdir. Çünkü kullanıcıların ne istediklerini doğrudan belirtmelerine olanak tanır ve öğeler ile kullanıcılar arasındaki etkileşimlerin geçmiş verilerine bağlı değildir.

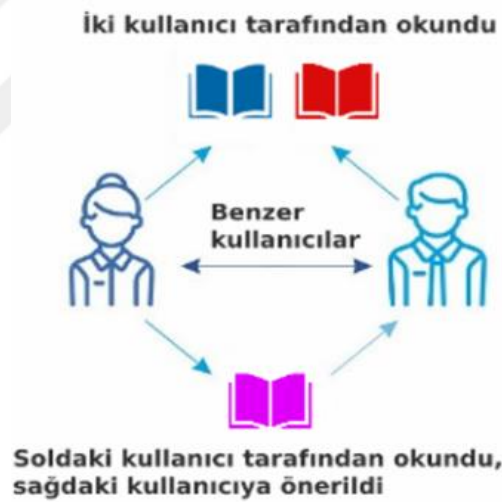
### 2.6.9. Modele dayalı yaklaşım

Müşterinin her ürünü nasıl derecelendirdiğini tahmin etmek ve hesaplamak için makine modelleri kullanılır. Bu sistem algoritmaları, müşteri derecelendirmelerine göre derecelendirilmemiş ürünleri tahmin etmek için makine öğrenimini temel alır. Bu algoritmalar ayrıca matris çarpanlarına ayırma tabanlı algoritmalar, derin öğrenme yöntemleri ve kümeleme algoritmaları olmak üzere farklı alt kategorilere ayrılır.

Model tabanlı teknik, puanlama matrisini en aza indirmek için istatistiksel bir sistem ve makine öğrenimi yaklaşımını uygular.

### 2.6.10. Kullanıcıya dayalı işbirlikçi filtreleme

Kullanıcı tabanlı filtreleme, hedef kullanıcıya, kullanıcı davranış tercihlerine göre öğeler önerir. Öneri algoritması hedef kullanıcının geçmiş davranışlarını diğer kullanıcıların davranışlarıyla karşılaştırır. Daha doğrusu, sistem her kullanıcıya hedef kullanıcıyla algılanan benzerliği temsil eden bir ağırlık atar: Bunlar hedef kullanıcının komşularıdır. Daha sonra en yüksek ağırlıklara sahip n kullanıcıyı seçer ve seçilen komşuların davranışlarının ağırlıklı ortalamasından kullanıcı davranışının tahminini hesaplar. Sistem bu öngörüye dayanarak hedef kullanıcıya ürün önerilerinde bulunur. Prensip şudur: Hedef kullanıcı geçmişte bu grup gibi davrandıysa, yeni öğelerle de aynı şekilde davranacaktır. Öğe-kullanıcı matrisinin satırları arasında kullanıcı bazlı benzerlik fonksiyonları hesaplanır (Aras, M.E., 2010; Donald J. Kridel, Daniel R. Dolk, David Castillo, 2013).



Şekil 2.5. Kullanıcı tabanlı işbirlikçi filtreleme sistemleri.

$u$  kullanıcısının  $i$  maddesine ilişkin puanını,  $u$ 'ya benzer kullanıcıların puanlarına dayanarak tahmin etmek için aşağıdaki Denklem 5 kullanılır.

$$\hat{r}_{ui} = \bar{r}_u + \frac{\sum_{v \in N_u} sim(u, v) * (r_{vi} - \bar{r}_v)}{\sum_{v \in N_u} |sim(u, v)|} \quad 5$$

Denklemdaki parametreler;  $\bar{r}_u$ ,  $u$  tarafından ortalama kullanıcı puanı,  $N_u$ ,  $u$ 'ya benzer tüm kullanıcı sayısı,  $\text{sim}(u,v)$ ,  $u$  ve  $v$  arasındaki benzerlik,  $r_{vi}$ , kullanıcı  $u$ 'nın  $i$  maddesine verdiği puan değerini gösterir.

## Benzerlik Ölçüleri

1. **Pearson korelasyonu** (kullanıcı yanlılığını dikkate alarak ayarlanır):

$$\text{sim}(u, v) = \frac{\sum_{i \in I_{uv}} (r_{ui} - \bar{r}_u) * (r_{vi} - \bar{r}_v)}{\sqrt{\sum_{i \in I_{uv}} (r_{ui} - \bar{r}_u)^2} * \sqrt{\sum_{i \in I_{uv}} (r_{vi} - \bar{r}_v)^2}} \quad 6$$

Denkleme ait parametrelerden  $I_{uv}$ , hem  $u$  hem de  $v$  tarafından derecelendirilen öğeleri temsil eder.

2. **Kosinüs Benzerliği**

$$\text{sim}(u, v) = \frac{r_u * r_v}{||r_u|| * ||r_v||} \quad 7$$

Denkleme ait parametrelerden  $r_u$ ,  $U$  notalarının vektörü.

### 2.6.11. İçerik tabanlı işbirlikçi filtreleme

Öğe bazında veya madde madde filtreleme yaklaşımı, kullanıcının benzer öğelere ilişkin değerlendirmesine dayanarak bir öğeye ilişkin tercihini belirler. İşbirlikçi filtrelemenin aksine, içerik tabanlı öneri, bu özelliklere ağırlık biçiminde önem atayan bir profil ile birlikte, öğe açıklamalarının kullanılabilirliğine dayanır. Bu, kullanıcıların çeşitli öğeler veya ürünler için genel olarak kriterleri ve ilişkili ağırlıkları belirlediği ve daha sonra bu öğelerin ve ürünlerin belirli örnekleri için tercihlerin sıralı bir listesini oluşturmak için kullanılabilen analitik hiyerarşi süreci (T.L. Saaty, 2008) gibi çok kriterli karar alma modellerinin bir çeşididir.

Bu yaklaşımın amacı, öğelerin nitelikleri ile kullanıcının yerleşik tercihleri arasındaki benzerliğe dayanarak ilgili öneriler sunmaktır. Örneğin, bir video akışı platformu bağlamında, içerik tabanlı filtreleme algoritmaları, kullanıcının daha önce izlediği ve ilgi çekici bulduğu filmlere veya dizilere benzer filmleri veya dizileri önerme yeteneğine sahiptir (Thamar Leonard, 2024).



Şekil 2.6. İçeriğe tabanlı işbirlikçi filtreleme.

$u$ 'nun  $i$ 'ye ilişkin puanını,  $u$ 'nun  $i$ 'ye benzer maddelerdeki puanlarını kullanarak tahmin etmek için Denklem 8 kullanılır.

$$\hat{r}_{ui} = \bar{r}_i + \frac{\sum_{j \in N_i} sim(i, j) * (r_{uj} - \bar{r}_j)}{\sum_{j \in N_i} |sim(i, j)|} \quad 8$$

Denkleme ait parametrelerden  $\bar{r}_i$ , madde  $i$ 'e ait puanların ortalamasını,  $N_i$ ,  $i$ 'ye benzer öğelerin kümesini,  $sim(i, j)$ ,  $i$  ve  $j$  arasındaki benzerlik miktarını gösterir.

### **Benzerlik Ölçümleri**

1. **Ayarlanmış Kosinüs Benzerliği** (kullanıcı önyargısını hesaba katar)

$$sim(i, j) = \frac{\sum_{u \in u_{ij}} (r_{ui} - \bar{r}_u) (r_{uj} - \bar{r}_u)}{\sqrt{\sum_{u \in u_{ij}} (r_{ui} - \bar{r}_u)^2} * \sqrt{\sum_{u \in u_{ij}} (r_{uj} - \bar{r}_u)^2}} \quad 9$$

Denkleme ait parametrelerden  $u_{ij}$ , hem  $i$  hem de  $j$  olarak derecelendiren kullanıcı sayılarını gösterir.

2. **Pearson Korelasyonu**

$$sim(i, j) = \frac{\sum_{u \in u_{ij}} (r_{ui} - \bar{r}_i) * (r_{uj} - \bar{r}_j)}{\sqrt{\sum_{i \in u_{ij}} (r_{ui} - \bar{r}_i)^2} * \sqrt{\sum_{i \in u_{ij}} (r_{uj} - \bar{r}_j)^2}} \quad 10$$

Denkleme ait parametrelerden  $u_{ij}$ , hem  $i$  maddesini hem de  $j$  maddesini derecelendiren tüm kullanıcı sayısı,  $r_{ui}$ , kullanıcı  $u$ 'nun  $i$  maddesine verdiği puan değeri,  $\bar{r}_i$ , madde  $i$  için puanların ortalaması (tüm kullanıcılar için),  $\bar{r}_j$ ,  $j$  maddesine ait puanların ortalamasını gösterir.

### 2.6.12. Hibrit öneri sistemleri

1994 yılında Stanford öğrencileri tarafından geliştirilen Fab ile ortaya konan hibrit öneri sistemleri, içerik tabanlı öneri sistemleriyle işbirlikçi öneri sistemlerinin birleştirilerek iyileştirilmiş bir öneri sistemini mümkün kılmıştır (Balabanovic ve Shoham, 1997).

Hem işbirlikçi hem de içerik tabanlı filtreleme yaklaşımlarının sınırlamalarını aşmak için hibrit sistemler her iki yaklaşımın avantajlarını birleştirir. İşbirlikçi filtrelemeyi ve içerik tabanlı filtrelemeyi paralel olarak kullanabilir veya bunları sıralı veya ağırlıklı bir şekilde birleştirebilir. Örneğin, bir hibrit sistem yeni kullanıcılar veya yeni öğeler için içerik tabanlı filtrelemeyi kullanabilir (soğuk başlangıç) ve yeterli etkileşim verisi mevcut olduğunda işbirlikçi filtrelemeye geçebilir.

Hibrit sistemler, her yaklaşımın güçlü yanlarını değerlendirip zayıf yanlarını azaltarak daha iyi öneri performansı ve daha fazla güvenilirlik ve doğru bilgi sağlayabilir. Birçok e-ticaret platformu ürün önerilerini optimize etmek için hibrit öneri sistemlerini kullanıyor.

### 2.6.13. Öneri sistemi için değerlendirme ölçütleri

Öneri sistemini değerlendirmek için ortalama mutlak hata, kök ortalama kare hata, kesinlik, hatırlatma, F1 puanı (F1-score) vb. gibi farklı ölçütler kullanılır (Cartelis, 2024; Donald J. Kridel, Daniel R. Dolk, David Castillo, 2013).

### 2.6.14. Hatırlatma

Kullanıcıların gerçekten beğendiği ürünlerin ve gerçekten önerilen ürünlerin yüzdesi olarak tanımlanır.

$$\text{Hatırlatma} = \frac{t_p}{t_p + f_n} \quad 11$$

Burada,  $t_p$ , öneri sistem tarafından bir kullanıcıya önerilen ürün sayısını ifade eder ve  $t_p + f_n$ , kullanıcılar tarafından beğenilen toplam ürün sayısını ifade eder. Hatırlama değeri ne kadar yüksekse, tavsiye sonucu o kadar iyi olduğunu gösterir.

### 2.6.15. Kesinlik

Sistem tarafından önerilen tüm ürünler içerisinde kullanıcı tarafından gerçekten beğenilen ürünlerin toplam sayısı olarak tanımlanır.

$$\text{kesinlik} = \frac{t_p}{t_p + f_n} \quad 12$$

Burada,  $t_p$ , öneri sistemi tarafından bir kullanıcıya önerilen ürün sayısını ve  $t_p + f_n$ , önerilen toplam ürün sayısını ifade eder. Kesinlik ne kadar yüksekse öneri kadar iyidir.

### 2.6.16. Kök Ortalama Karesel Hata (RMSE)

Tahmin edilen değerlerdeki hatayı ölçmek için kullanılır.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\text{tahmin edilen}_i - \text{Gerçek}_i)^2}{N}} \quad 13$$

Burada "Tahmin edilen" model tarafından verilen değerdir ve "Gerçek" orijinal değerdir. RMSE değeri ne kadar küçükse o kadar iyidir.

### 2.6.17. Ortalama mutlak hata (MAE)

Ortalama mutlak hata, gerçek ve öngörülen değer arasındaki farkı hesaplamak için kullanılır. MAE değeri ne kadar küçükse o kadar iyi tavsiye edilir.

$$\text{MAE} = \frac{1}{N} \sum |Tahmini - Gerçek| \quad 14$$

## 2.7. Dijital Pazarlama

Arzular tüketicilerin kişisel özellikleri ve içinde yaşadıkları toplumlar tarafından şekillenir. Satın alma gücüyle birleşen arzular talebe dönüşür ve tüketiciler kendilerine en fazla tatmin sağlayacak ürün/mal ve hizmetleri tercih ederler (Epsilon Marketing, 2017). Ancak sanayi devrimi ve hemen ardından gelen dönemlerde, ürünlerin tüketici ihtiyaçlarını karşıladığı, ancak her tüketiciye veya tüketici grubuna özgü olmadığı, temel ihtiyaçları karşıladığı bir arz ve talep ortamı ortaya çıkmıştır (Airey D., 2020).

Sanayi devrimi ve onu hemen izleyen dönemlerden farklı olarak, 21. yüzyılda pazarlamacıların talebe yanıt olarak arzı yönetme işi artık eskisi kadar kolay gözükmemektedir. Bu dönemde tüketiciler oldukça bilgili oluyor ve bir ürün grubuna yönelik birden fazla teklifi değerlendirebiliyorlar. Tüketicilerin istekleri ve dolayısıyla

talepleri birbirinden çok farklıdır ve bu talepler pazarı belirlemektedir. Arzın bu taleplere cevap vermesi gerekir (Subaşı, H.H., 2012). Artık şirketlerin sadece ürünü veya hizmeti tanımlayıp satış şeklinde bir geri dönüş elde etmesi mümkün değildir; Müşteri katılımıyla geliştirilen ve müşterilere üstün değer sağlayan ürün ve hizmetler oluşturulmalıdır (Deshpande, M. and G. Karypis, 2001).

Dijital pazarlama, ürün veya hizmetlerin başta internet olmak üzere çeşitli elektronik medya aracılığıyla tanıtılması anlamına gelir. İçerik pazarlaması, sosyal medya reklamları, e-posta kampanyaları ve arama motoru optimizasyonu (SEO) gibi stratejiler aracılığıyla hedef kitleye ulaşmak için çevrimiçi kanalları kullanır. Bu çevrimiçi kanallar arasında etkileşimleri ve dönüşümleri teşvik etmek için tasarlanmış sosyal medya, e-posta, SEO ve tıklama başına ödeme (PPC) yer almaktadır (Magdalena D., 2025).

Son on yılda satın alma davranışları kökten değişmiştir. Gittikçe daha fazla tüketici alışveriş yolculuğuna çevrimiçi olarak başlıyor (ve çoğunlukla çevrimiçi olarak sonlandırıyor), bu da dijital pazarlamanın önemini ve etkinliğini ortaya koyuyor. Satın alma alışkanlıklarındaki ve tüketicilerdeki bu evrim, dijital pazarlamayı, büyüklüğü veya faaliyet sektörü ne olursa olsun, modern pazarda rekabetçi kalmak isteyen her işletme için olmazsa olmaz bir ihtiyaç haline getirmiştir (Anonim, 2025). Dijital pazarlama, web siteleri, arama motorları, sosyal medya ve e-postalar gibi dijital kanallar üzerinden veri odaklı stratejilerle müşterilere ulaşmayı hedefler. İşletmeler, müşteri yolculuğunun farklı aşamalarındaki potansiyel alıcılara yankı uyandıran, alakalı ve kişiselleştirilmiş mesajlar oluşturmak için bu hedeflenen bilgileri kullanır. Bu süreç, etkileşimi ve dönüşümleri artıran içerik oluşturmanın yanı sıra kampanya performansını ölçmek için verileri analiz etmeyi de içerir (Magdalena D., 2025).

Dijital pazarlama, tüketicilere ürün veya hizmetleri tanıtmak için dijital kanalların kullanılmasıdır. İnternetin ve web siteleri, sosyal ağlar, mobil siteler, akıllı telefon ve tablet uygulamaları, GPS, podcast'ler ve çevrimiçi videolar gibi bağlantılı nesnelere kullanımının geliştirilmesine dayanmaktadır.

Büyük verinin ortaya çıkışıyla birlikte dijital pazarlamanın daha kesin ve etkili olduğu kanıtlanmıştır. Dijital pazarlama, farklı kaynaklardan büyük verileri toplar ve işler. Doğru veri işleme sayesinde müşterilerle daha doğru ve daha düşük maliyetlerle iletişime geçilir. Veriye dayalı pazarlama, dijital pazarlamanın önemli bir parçası haline gelirken, pazarlama bağlamındaki büyük verilere veri yönetimi platformu (DMP) ismi

verilmektedir. Çeşitli çevrimiçi ve çevrimdışı kaynaklardan alınan müşteri verileri, web analiz araçları, mobil web, mobil uygulamalar, e-ticaret portalları, davranışsal ve demografik verilerden toplanır.

Büyük verinin temel avantajı müşteri özelliklerinin daha iyi anlaşılmasını sağlamasıdır. Şirketler, demografik bilgilerin (konum) yanı sıra yaş, cinsiyet gibi kişisel bilgilerin ile birlikte, müşterilerin dijital davranışlarını da takip edebilmektedir. Büyük veri sayesinde müşterilerin yaşam döngüsü ve davranışları anlaşılmaktadır. Müşteriler, ürün veya hizmet ilgilerini ve tercihlerini çeşitli kanallar aracılığıyla kamuoyuna detaylandırarak her gün gönüllü olarak büyük miktarda veri üretmektedirler (Anshari, M., N. Almunawar, 2018).

Dijital pazarlama, ürün ve hizmetlerin dijital medya üzerinden pazarlanmasıdır. İnternetin avantajı yeni pazarlama fırsatları oluşturmuştur. Dijital teknolojilerin yükselişiyle birlikte müşteriler, şirketlerin kendileriyle daha fazla ilişki kurarak gereksinimlerini karşılama beklendektedir. Ayrıca işletmelerin ihtiyaçlarını ve isteklerini anlamalarını istemektedirler (Kotler, P. & Keller, K., 2012).

Dijital pazarlama, sürekli değişen bir ortamda iş hedeflerine ulaşmak isteyen işletmeler için önemli bir araçtır. Etkili ve ölçülebilir bir strateji geliştirmek için farklı dijital pazarlama türlerini, sorunlarını ve zorluklarını anlamak önemlidir.

### **2.7.1. Dijital pazarlama stratejisi geliştirme**

İyi bir dijital pazarlama stratejisi, satın alma, güvence altına alma ve daha fazla kazanç elde etme amacıyla fırsattan yararlanan tüm işletme türleri için gereklidir (Chaffey, D., Ellis-Chadwick, F., 2019).

Dijital pazarlamanın karmaşıklığı, özellikle büyük girişimler ve büyük girişimler için dijital pazarlama stratejisinin tanımlanmasının vazgeçilmez bir nedenidir. İyi bir pazarlama stratejisi, işletmenin hedeflerini yönlendiren bir hücredir. Dr. Dave Chaffey, dijital pazarlama için sayısal ve teknolojik hedeflere ulaşmayı sağlayacak stratejiler tanımını yapmıştır (Chaffey, D., Ellis-Chadwick, F., 2019).

Sonuç olarak, tüm ilk aşama net ve ölçülebilir bir hedefi tanımlamaktadır. Örneğin, 3 ay içinde %20 müşteri olumlu dönüşlerini artırın...vb.

İkinci adım, bu hedeflere ulaşmak için yerinde bir strateji oluşturmaktır. Bunun için izleyici kitlesine ulaşmak amacıyla imkanları değerlendirmek gerekir.

### 2.7.2. Arama motoru optimizasyonu (SEO)

Arama motorları (SEO) için optimizasyon, doğal arama sonuçları aracılığıyla bir web sitesinin ve bir web sayfasının görünürlüğünü iyileştirmeye izin veren bir süreçtir (Minculete, G. & Olar, P., 2018).

İyi bir SEO stratejisi şunlardan oluşur:

- Kullanıcıların sorularına yanıt veren kaliteli, alakalı ve kapsamlı içerikler oluşturmak.
- Tıklamaları teşvik etmek için arama sonuçlarında görünen etkili başlıklar ve açıklamalar oluşturmak.
- Daha hızlı yükleme için açıklayıcı alternatif metinler kullanmak ve resim dosya boyutlarını optimize etmek.
- Yükleme sürelerini optimize etmek; çünkü daha hızlı siteler daha iyi bir kullanıcı deneyimi sağlar ve arama motorları tarafından daha çok tercih edilirler.
- Sitenin tüm cihazlarda duyarlı ve kolay gezinilebilir olduğundan emin olmak.
- Diğer saygın web sitelerinden içeriğe bağlantı vermeye teşvik etmek. Bu "güven oyları" arama motorlarına sitenizin güvenilir ve değerli olduğunu bildirmekle mümkündür.

Google'ın Webspam ekibinin başkanı Matt Cutts, çeşitli forumlarda, SEO uzmanlarının artık web sitelerinin yükleme hızının indeksleme algoritmalarında önemli bir faktör olarak değerlendirdiğini belirtmiştir (Minculete, G. & Olar, P., 2018).

### 2.7.3. Sosyal ağlar

Günümüzde sosyal medya, bireylerin ve markaların iletişim kurma biçimini kökten değiştirmiştir. Sosyal medya platformları kullanıcıların bilgi paylaşmasına, etkileşimde bulunmasına ve topluluklar oluşturmasına olanak tanır. Türkiye'de sosyal medya kullanımı hızla artıyor; Bu durum aynı zamanda dijital pazarlama stratejilerinin de yeniden şekillenmesine yol açmaktadır.

Son yıllarda Türkiye'de internet kullanıcı sayısı ölçüsü 77,3 milyon değerlerine ulaşmıştır. Bu kullanıcıların yüzde 75'inden fazlası sosyal medya platformlarını aktif

olarak kullanılmaktadır. Son yıllarda sosyal medya kullanıcı sayısında önemli bir artış gözlemleniyor. Özellikle sosyal medya kullanıcı sayısı son bir yılda yüzde 1,7 artarak 58,5 milyona ulaştı.

Türkiye'de sosyal medya kullanıcıları arasında en çok tercih edilen platformlar arasında Instagram 58,4 milyon, YouTube 57,5 milyon, TikTok 40,2 milyon, Facebook 34,8 milyon, Platform X ise 19,7 milyon kullanıcıya sahip olduğu rapor edilmiştir. Dijital pazarlama stratejilerini belirlerken bu rakamlar, dikkate alınması gereken önemli faktörlerdir (Anonim, 2025).

#### **2.7.4. İçerik pazarlaması**

İçerik pazarlaması, daha iyi bir çevrimiçi varlığa yol açan SEO'nun temeli olarak yüksek kaliteli içeriğe olan ihtiyacını vurgulamaktadır (LITMUX, 2014). Kaliteli içeriğe sahip olmak yalnızca SEO'nun değil aynı zamanda müşteri sadakatinin sağlanmasında da önemli bir rol oynamaktadır.

#### **2.7.5. E-Posta pazarlaması**

E-posta pazarlaması, her türlü dijital pazarlama stratejisinin en önemli unsurlarından biridir. Sosyal medyanın giderek önem kazanmasına rağmen ziyaretçileri müşteriye dönüştürmenin en iyi yolu olmaya devam ediyor. E-posta pazarlaması, bir şirketin ürün veya hizmetlerini satın almış tüm gerçek veya tüzel kişilerle iletişim halinde kalmasını sağlar (Minculete, G. & Olar, P., 2018).

#### **2.7.6. Stratejik web sitesi geliştirme**

Web sitesi kişisel bir blog, bir işletme web sitesi veya otomatik bir pazarlama sistemi (WordPress veya Tumblr gibi) tarafından yönetilen bir site olabilir. Bir web sitesi bir işletmenin hem başlangıç noktası, hem de bitiş noktasıdır. Örneğin, Minculete ve Olar'a (2018) göre, bir şirketin satış temsilcileri bir web sitesini tanıtmak (başlangıç noktası) ve ziyaretçileri çekmek (hedef) için bir dijital pazarlama kampanyası başlatabilir (LITMUX, 2014).

#### **2.7.7. E-ticarette dijital pazarlama otomasyonu**

Pazarlama trendleri giderek daha çok veri odaklı pazarlamaya ve dijital kanallar üzerinden satışa doğru yöneliyor. Makine Öğrenimi, daha fazla analiz ve öneri becerisi

sağlayarak pazarlama ve satış sürecini, daha doğrusu yatırım getirisini (ROI) optimize etmemize olanak tanır (etic-insa.com). Makine öğrenmesinin (ML) avantajı, bilgisayarların programlanmadan öğrenmelerine olanak sağlamasıdır. Böylece eldeki verileri, süreçleri iyileştirmek, yeni (daha kaliteli) veriler toplamak vb. için kullanılabilirler (Jacek Piotrowski, 2021).

E-ticarette dijital pazarlama otomasyonu, pazarlama çabalarını optimize etmek için otomasyon yazılımlarının kullanılması anlamına gelir. Pazarlama çabalarının kolaylaştırılmasında, verimliliğin artırılmasında ve müşterilerle kişiselleştirilmiş iletişimin kolaylaştırılmasında önemli bir rol oynar. Dijital pazarlama otomasyonunun temel alanları arasında, müşterilere davranışlarına ve tercihlerine göre kişiselleştirilmiş mesajların gönderilmesine olanak tanıyan e-posta pazarlama otomasyonu yer alır. Sosyal medya pazarlama otomasyonu, çeşitli platformlarda içerik planlamaya ve yayınlamaya olanak tanır (Jacek Piotrowski, 2021). Ücretli reklam otomasyonu, reklam tekliflerini ve hedeflemeyi optimize etmek için algoritmalar kullanır. İçerik oluşturma ve kişiselleştirme otomasyonu, pazarlama içeriğini farklı hedef kitle segmentlerine göre oluşturmak ve uyarlamak için yapay zekayı kullanır. Son olarak, müşteri ilişkileri yönetimi (CRM) otomasyonu rutin görevlerin otomatikleştirilmesine ve müşteri etkileşimlerinin iyileştirilmesine yardımcı olur.

Dijital pazarlama otomasyonu, makine öğrenimi (ML) destekli daha akıllı özellikleri bünyesine katmak için basit kurallara dayalı sistemlerin ötesine geçmektedir. Bu değişim, dinamik müşteri segmentasyonuna, kişiselleştirilmiş içerik oluşturmaya ve gerçek zamanlı kampanya optimizasyonuna olanak vererek daha etkili pazarlama sonuçlarına yol açmaktadır. Makine öğrenimine dayalı otomasyon sistemleri, büyük miktardaki müşteri verisini analiz ederek kalıpları ve tercihleri belirleyebilir ve böylece işletmelerin son derece kişiselleştirilmiş mesajlar ve teklifler sunmasını sağlayabilirler. Müşteri davranışına ve piyasa eğilimlerine dinamik olarak uyum sağlama yeteneği, önceden tanımlanmış kurallara ve segmentlere dayanan geleneksel otomasyon sistemlerine kıyasla önemli bir öneme sahiptir (Jacek Piotrowski, 2021).

### **2.7.8. E-ticarette dijital pazarlama stratejilerini otomatikleştirmek için makine öğreniminin uygulanması**

Dijital pazarlamanın amacı, şirket web sitelerine yapılan ziyaretleri artırmak, bu ziyaretleri satın almaya dönüştürmek ve müşterilerle düzenli ilişki kurarak müşteri

sadakatini oluřturmaktır (SMAIL Mehdi, M., 2023). Pazarlamacılar bu hedefe ulaşmak için hedef kitleye ulaşma, içerik oluřturma, performans takibi, dönüşüm optimizasyonu, yeniden hedefleme stratejileri, marka sadakati vb. gibi çeřitli stratejileri kullanırlar.

E-ticaret alanında, potansiyel müşterilere (müşteri adaylarına), SEO aracılığıyla web sitesini duyurmak yalnızca ilk adımdır; ancak web sitesini ziyaret ettiklerinde tekrar gelmek istemeleri temel amaçtır. Bunun için sitenin görsel yönü ve içerik kalitesinin yanı sıra, hedef kitlenin sadakatini sađlayan en önemli nokta, içeriğin hedef kitlenin tercihlerine göre kişiselleřtirilmesidir. İřte bu noktada makine öğrenimi ve öneri sistemleri devreye girmektedir.

Nitekim yukarıda da değinildiđi gibi, makine öğrenimi (ML) tekniklerini kullanan öneri sistemleri, kullanıcıların davranıřlarını inceleyerek tercihlerini anlar ve böylece kullanıcılara gerçekten beğenebilecekleri ürünleri önerir. McKinsey & Company tarafından yapılan bir arařtırmaya göre Amazon satıřlarının %35'i tavsiyelere dayanıyor. Bu, milyarlarca dolarlık bir řirketteki satıřların üçte birinden fazlası anlamına gelmektedir. Öneri sistemlerinin önemini gösteren Accenture'ın bir diđer raporuna göre ise tüketicilerin %91'i, kendilerini tanıyan, hatırlayan ve uygun öneriler sunan markalardan satın alma eğiliminde olduđunu vurguluyor (Jacek Piotrowski, 2021).

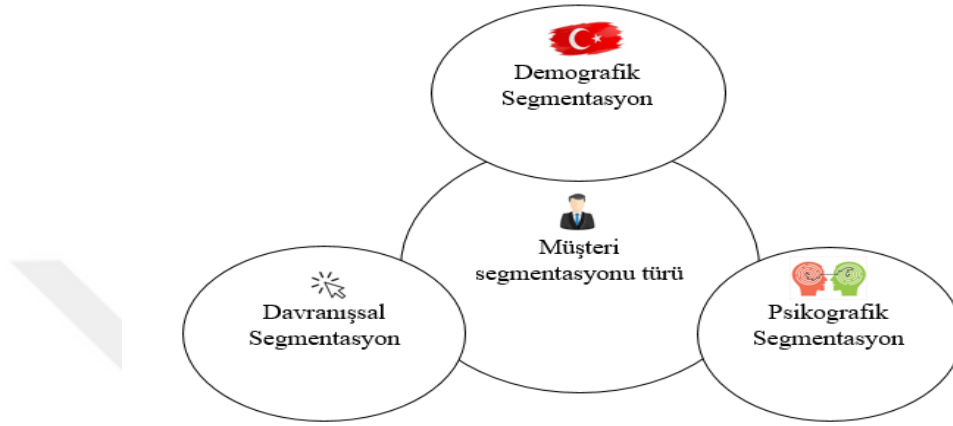
Makine öğrenimi, hedefli pazarlama dünyasında řletmelerin müşterilere ulaşarak, yalnızca her iki taraf için de daha keyifli deđil, aynı zamanda çok daha karlı bir iliřki bařlatmasını, kurmasını ve büyütmesini sađlıyor. Müřteri iliřkilerinin iletişim, edinme, dönüşüm, destek ve sadakat gibi temel ařamaları, alışveriř sitesini potansiyel müşteri mıknaatısı haline getirmek ve aynı zamanda optimum kullanıcı deneyimini sađlamak için hedefli pazarlama öğelerini içermelidir (etic-insa.com).

Nitekim kişiselleřtirme, e-ticaret sektöründe müşteri iliřkileri yönetimi (CRM) stratejisinin merkezi bir unsuru haline gelmiřtir. řirketlerin etkileřimlerini ve tekliflerini bireysel müşteri tercihlerine göre uyarlayarak müşteri deneyimini iyileřtirmelerine olanak tanır, böylece müşteri sadakatini güçlendirmeye ve son derece rekabetçi bir ortamda satıřları artırmaya yardımcı olur (Wierenga, B., Van der Lans, R., 2017).

### **2.7.9. Müřteri segmentasyonu**

Müşteri segmentasyonu, müşterileri satın alma davranıřı, demografik kriterler veya profil gibi ortak özelliklere göre daha küçük gruplara (segmentlere) ayırmayı içerir. Burada

amaç daha iyi iletişim ve kişiselleştirmedir. Genel mesajlara güvenmek yerine, her bir segmentin ihtiyaçlarına ve tercihlerine göre uyarlanmış pazarlama kampanyaları ve stratejileri tasarlamaya olanak tanır. Pazar segmentasyonunun geniş pazar özelliklerine odaklanmasının aksine, müşteri segmentasyonu şirketin mevcut müşterilerine odaklanır. Bu nedenle müşteri segmentasyonu, kişiselleştirme ve müşteri deneyiminin optimize edilmesinde önemli bir rol oynar.



Şekil 2.7. Müşteri segmentasyonunun farklı türleri.

Raporda (Adobe Trust 2022), müşterilerin %58'inin kendilerine kişiselleştirilmiş deneyimler sunmayan bir markanın ürünlerini satın almayı bıraktığı belirtiliyor. Bu, deneyimlerin müşteri beklentilerine göre uyarlanmasının önemini vurgulamaktadır (Anonim, 2023).

Makine Öğrenimini (ML) müşteri segmentasyonuna entegre etmek birçok önemli fayda sağlar. ML algoritmaları, geleneksel kurallara dayalı veya hipoteze dayalı yöntemlerin gözden kaçırabileceği kalıpları ve segmentleri belirlemek için çeşitli kaynaklardan (işlemsel, davranışsal, demografik vb.) gelen büyük miktardaki müşteri verisini analiz edebilir. Bu, daha homojen özelliklere ve ihtiyaçlara sahip daha hassas ve daha küçük segmentlerin (mikro segmentler) oluşturulmasına olanak tanır (Cenk E., 2015). Şirketler, her segmentin ihtiyaç ve tercihlerini daha iyi anlayarak pazarlama mesajlarını, ürün ve hizmet tekliflerini ve genel müşteri deneyimini kişiselleştirebilirler. Daha kişiselleştirilmiş bir deneyim daha fazla memnuniyete, artan sadakate ve potansiyel olarak artan satışlara yol açar.

### 2.7.10. Kişiselleştirmenin satış ve dönüşüm oranına etkisi

Çok sayıda araştırma, öneri sistemlerinin e-ticarette satış ve dönüşüm oranları üzerinde önemli bir olumlu etkiye sahip olabileceğini göstermiştir. 28 araştırmanın incelendiği bir meta-analizde, öneri sistemlerinin satışları ortalama %9,15, dönüşüm oranlarını ise %1,5 oranında artırdığı görülmüştür. Amazon'da yapılan bir vaka çalışması, satışların %35'inin ürün tavsiyelerinden kaynaklandığını göstermiştir. Diğer araştırmalarda ise %20'lik artışlar saptandığı görülmüştür (Barilliance, 2014; Epsilon Marketing, 2017).

Tüketicilerin %80'ninin kişiselleştirilmiş deneyimler sunan bir şirketten satın alma olasılığı daha yüksektir (Molly H., Amanda D., 2023). Pazarlamacıların %98'i kişiselleştirmenin müşteri ilişkilerini iyileştirmeye yardımcı olduğunu düşünüyor (Evergage, Kişiselleştirme Trendleri Anketi - 2018). Aynı ankette %53'ü dönüşüm oranı, potansiyel müşteri yaratma ve gelir dahil üzere temel performans göstergelerinde (KPI'lar) %10'dan fazla bir artış görmektedir. Kişiselleştirilmiş ürün önerilerinin satın alma oranında, kişiselleştirilmemiş ürün önerilerine kıyasla %170 artış gözlenmiştir (Barilliance, 2014).

18 ila 64 yaş aralığındaki 1.000 tüketiciyle 2017 yılında yapılan bir çevrimiçi ankete göre, kişiselleştirmenin çekiciliği oldukça güçlü olarak saptanmıştır. Katılımcıların %80'i kişiselleştirilmiş deneyimler sunan bir şirketle iş yapma olasılıklarının daha yüksek olduğunu, %90'ı ise kişiselleştirmeyi çekici bulduğunu söylemiştir.. Kişiselleştirme ile satın alma davranışı arasındaki ilişkiyi daha derinlemesine incelemek için Epsilon, anket verilerini 2.700'den fazla üyesi ve milyarlarca işlemi bulunan Epsilon'un Abacus firmasından alınan işlem verileriyle ilişkilendirdi. İşlemsel analiz sonuçları, kişiselleştirilmiş deneyimleri oldukça ilgi çekici bulan tüketicilerin bir markanın en değerli müşterileri olma olasılığının on kat daha fazla olduğunu, yani yılda 15'ten fazla işlem yapması beklenen kişiler olduğunu gösteriyor. Ayrıca, şirketlerin kişiselleştirilmiş deneyimler sunmada çok başarılı olduğuna inanan katılımcılar üç kat daha sık satın alma yapıyor olduğuna rastlanmıştır (Barilliance, 2014)..

Ancak öneri sistemlerinin etkinliği, öneri sisteminin türü, sektör, ürün türü, veri kalitesi ve kullanıcı arayüzü tasarımı gibi çeşitli faktörlere bağlı olarak değişebilmektedir. Bazı araştırmalar, "filtre balonlarının" oluşmasını önlemek ve yeni ürünlerin keşfini teşvik etmek amacıyla önerilerde çeşitliliğin önemini vurgulamaktadır.

### **2.7.11 Pazarlama içeriği için üretken yapay zeka kullanımı**

Üretken yapay zeka, yaratıcı ve analitik görevlerin benzeri görülmemiş bir şekilde otomasyonunu sağlayarak dijital pazarlamanın temel taşlarından biri haline gelmiştir. HubSpot araştırmasına göre, pazarlamacıların %43'ü içerik oluşturmada yapay zekayı kullanırken, %34'ü bunu araştırma için kullanmıştır (Inventiv-IT, 2025). Özellikle otomatik ve kişiselleştirilmiş pazarlama içeriği oluşturmada yeni olanaklar sunan büyük dil modelleri (LLM) bu konuda önelidir. Üretken yapay zeka, yeni fikirler ve içerik varyasyonları üreterek yaratıcılığı ve inovasyonu teşvik eder. Pazarlama ekipleri, güncel trendlere ve hedef kitlelerinin ilgi alanlarına göre arama motoru optimizasyonu (SEO) başlıkları veya konuları önermek için bunu kullanabilir. Üretken yapay zeka, logolar veya reklamlar için konseptler de önerebilir ve pazarlama ekiplerine seçim yapmaları ve geliştirmeleri için çok çeşitli seçenekler sunabilirler (Molly H., Amanda D., 2023).

Üretken yapay zeka, iş süreçlerini optimize etmek ve müşteri etkileşimini güçlendirmek için birden fazla yol sunarak, pazarlama departmanlarının tüketicilerle iletişim kurma ve onlardan öğrenme biçimini dönüştürmektedir. Pazarlamada üretken yapay zekanın kullanılmasının bazı temel faydaları şunlardır (Molly H., Amanda D., 2023; Michael, 2025):

- Otomasyon sayesinde artan verimlilik
- Hiper kişiselleştirilmiş pazarlama
- Ölçeklenebilirlik
- Karlılık
- Veri odaklı kararlar
- İyileştirilmiş müşteri deneyimi
- Gerçek zamanlı adaptasyon

Üretken yapay zeka, yüksek düzeyde kişiselleştirme ve kaliteyi korurken, büyük ölçekte pazarlama içeriği oluşturmayı otomatikleştirebilir. Ancak burada yapay zeka tarafından üretilen içeriğin alakalı, doğru, etik ve marka dostu olmasını sağlamak önemlidir.

### **2.7.12. E-ticarette öneri sistemleri ve otomasyonun önemi**

Doymuş e-ticaret ortamında, işletmelerin öne çıkması ve kişiselleştirilmiş ve alakalı bir müşteri deneyimi sunması hayati önem taşıyor. Bu yaklaşımda öneri sistemleri merkezi bir rol oynar. Kullanıcıların satın alma geçmişi, tarama davranışları ve tercihleri gibi

verilerini analiz ederek her bir bireyin ilgisini çekebilecek ürün veya içerikleri önerirler. Tavsiye sistemleri, kişiselleştirilmiş öneriler sunarak ürün keşfini iyileştirir, müşteri katılımını artırır, ek satışları ve çapraz satışları yönlendirir ve marka sadakatini güçlendirir (Molly H., Amanda D., 2023).

Aynı zamanda dijital pazarlama otomasyonu, müşteri etkileşimlerini büyük ölçekte etkili bir şekilde yönetmek için vazgeçilmez hale geldi. Otomasyon, tekrarlayan pazarlama süreçlerini optimize etmeye, iletişimleri kişiselleştirmeye, hedef kitleleri segmentlere ayırmaya ve ilgili mesajları doğru zamanda ve doğru kanalda iletmeye yardımcı olur. E-ticaret işletmeleri, öneri sistemlerini dijital pazarlama otomasyonu ile birleştirerek kişiselleştirilmiş ve ilgi çekici müşteri yolculukları oluşturabilir, kaynaklarını optimize edebilir ve pazarlama yatırım getirisini artırabilir (Anonim,2025).

### **2.7.13. Öneri sistemleri ve otomatikleştirilmiş dijital pazarlamanın entegrasyonu**

Gerçekten kişiselleştirilmiş ve etkili e-ticaret pazarlama stratejileri oluşturmak için öneri sistemleri ile otomatik dijital pazarlamayı entegre etmek şarttır. Şirketler bu iki yaklaşımı birleştirerek, her müşterinin davranışına ve tercihlerine göre farklı pazarlama kanallarında kişiselleştirilmiş önerilerin sunulmasını otomatikleştirebilirler.

### **2.7.14. Önerilere dayalı otomatik iş akışları**

Öneri sistemlerinin dijital pazarlama otomasyonu ile bütünleştirilmesi, önerilerle tetiklenen otomatik iş akışlarının oluşturulmasına olanak tanır. Örneğin :

Öneri takip e-postaları: Bir öneri sistemi web sitesinde bir kullanıcıya bir ürün önerdikten sonra, birkaç gün sonra ürünü hatırlatmak ve satın almayı teşvik etmek için bir takip e-postası gönderilebilir.

Kişiselleştirilmiş Görüntülü Reklamlar: Ürün önerileri, kullanıcının daha önce görüntülediği veya beğendiği ürünlere dayalı olarak üçüncü taraf web sitelerinde veya sosyal ağlarda kişiselleştirilmiş görüntülü reklamları hedeflemek için kullanılabilir.

Mobil anlık bildirimler: E-ticaret mobil uygulamaları, kullanıcılara tercihlerine veya konumlarına göre ürün veya özel teklifler öneren kişiselleştirilmiş anlık bildirimler gönderebilir.

Bu otomatik iş akışları, ilgili önerilerin doğru zamanda ve doğru kanalda iletilmesini sağlayarak müşteri etkileşimi ve satışlar üzerindeki etkilerini en üst düzeye çıkarır.

### **2.7.15. Gerçek zamanlı veri analizi ve optimizasyonu**

Öneri sistemleri ve otomatik dijital pazarlamanın entegrasyonu, müşteri davranışı, tavsiye performansı ve pazarlama kampanyası etkinliği hakkında büyük miktarda veri üretir. Bu veriler, öneri sistemlerini, otomatik iş akışlarını ve genel pazarlama stratejilerini optimize etmek için gerçek zamanlı olarak analiz etmeli.

- Örneğin, veri analizi şunları ortaya çıkarabilir:
- Farklı müşteri segmentleri için hangi tür öneriler en etkili?
- Hangi pazarlama kanalları öneriler için en iyi yatırım getirisini sağlar?
- Tavsiyeleri iletmek veya otomatik pazarlama mesajları göndermek için en uygun zamanlar nelerdir?
- Performansı iyileştirmek için öneri algoritmaları veya otomasyon kuralları nasıl ayarlanır.
- Veri odaklı bu geri bildirim döngüsü, öneri sistemlerinin ve otomatik dijital pazarlama stratejilerinin sürekli iyileştirilmesini ve kademeli olarak iyileştirilmesini sağlar (Jacuński, M., 2018)

### **2.8 E-ticarette öneri sistemlerinin etkinliğine ilişkin ampirik çalışmalar**

Çok sayıda ampirik çalışma, e-ticarette öneri sistemlerinin etkinliğini inceleyerek, çeşitli iş ve müşteri etkileşimi metrikleri üzerindeki etkilerini ölçmüştür.

#### **2.8.1 Satış ve dönüşüm oranına etkisi**

Birçok çalışma, öneri sistemlerinin e-ticarette satış ve dönüşüm oranları üzerinde önemli bir olumlu etkiye sahip olabileceğini göstermiştir. 28 araştırmanın incelendiği bir meta-analizde, tavsiye sistemlerinin satışları ortalama %9,15, dönüşüm oranlarını ise %1,5 oranında artırdığı bulundu. Amazon'da yapılan bir vaka çalışması, satışların %35'inin ürün önerilerinden geldiğini gösterdi. Diğer araştırmalar, kişiselleştirilmiş öneriler sayesinde satış artırımlarında ve çapraz satışlarda %20 ila %30 oranında artış olduğunu göstermiştir.

Ancak öneri sistemlerinin etkinliği, öneri sisteminin türü, sektör, ürün türü, veri kalitesi ve kullanıcı arayüzü tasarımı gibi çeşitli faktörlere bağlı olarak değişebilmektedir. Bazı

arařtırmalarda, "filtre baloncuęu" oluřumunu engellemek ve yeni őrlerin keřfini teřvik etmek amacıyla őrlerde eřitlilięin őrni vurgulanıyor.

### **2.8.2 Műşteri memnuniyeti ve sadakatine etkisi**

Őneri sistemlerinin satıřlara olan etkisinin yanı sıra műşteri memnuniyeti ve sadakatini de olumlu yōnde etkileyebileęi belirtiliyor. Tavsiye sistemleri, daha kiřiselleřtirilmiř ve alakalı alıřveriř deneyimleri sunarak műşterilerin katma deęer algısını iyileřtirebilir ve marka baęlılıklarını gűçlendirebilir.

Tüketici anketleri, oęu műşterinin kiřiselleřtirilmiř őr őrlerine deęer verdięini ve bunları yeni őrleri keřfetmede ve bilinli satın alma kararları vermede yararlı bulunduęunu ortaya koymuřtur. Kiřiselleřtirilmiř őrler alan műşteriler alıřveriř deneyimlerinden daha memnun olma eęilimindedir ve aynı evrimii perakendeciden tekrar alıřveriř yapma olasılıkları daha yűksektir.

Ancak műdahaleci veya alakasız őrlerin ters tepebileęini ve műşteri deneyimine zarar verebileęini unutmamak őrnelidir. Bu nedenle kullanıcıların mahremiyetine saygılı, alakalı ve dikkatli őreri sistemleri tasarlamak bűyűk őrnem tařıyor.

### **2.9 Otomatik pazarlama kampanyalarının etkinlięi**

Őzellikle e-posta pazarlaması alanında, otomasyon pazarlama kampanyalarının etkinlięini inceleyen ok sayıda alıřma bulunmaktadır. Sonular, otomatik pazarlama e-postalarının, otomatik olmayan veya genel pazarlama e-postalarına kıyasla őrnemli őrűde daha yűksekte aılma oranları, tıklama oranları ve dōnűřűm oranları őrretme eęiliminde olduęunu gōstermektedir.

Bir e-ticaret řirketinde yapılan bir vaka alıřmasında, otomatik terk edilmiř alıřveriř sepeti e-postalarının terk edilmiř alıřveriř sepetlerinin %29'unu kurtardıęı ve geliri %11 oranında artırdıęı bulundu. Dięer arařtırmalar, yeni abone katılımını artırmada otomatik karřılama e-postalarının ve apraz satıř ve ek satıřları artırmada otomatik őr őreri e-postalarının etkinlięini vurgulamıřtır.

Ancak, otomatik pazarlama kampanyalarının etkinlięi aynı zamanda hedef kitle segmentasyonunun kalitesine, ierik kiřiselleřtirmesine, gōnderim zamanlamasına ve mesajın alaka dűzeyine de baęlıdır. Kōtű tasarlanmıř veya ařırı műdahaleci kampanyalar spam olarak algılanabilir ve marka imajına zarar verebilir.

### 3. MATERYAL VE METOD

Çalışma üç aşamada planlandı:

1. Model tabanlı işbirlikçi filtreleme.
2. Hafıza tabanlı işbirlikçi filtreleme.
3. Öğe tabanlı ve ilişki kuralı tabanlı işbirlikçi filtrelemeyi birleştiren bir hibrit sistem.

İlk aşamada, Surprise kütüphanesinden NormalPredictor, KNNBasic, KNNWithMeans, KNNWithZScore, KNNBaseline, SVD, BaselineOnly, SVDpp, NMF ve SlopeOne algoritmaları model tabanlı işbirlikçi filtrelemeyi tasarlamak için kullanıldı. Bu algoritmalara dayanarak elde edilen öneri sisteminin performansı RMSE ve MAE metrikleri kullanılarak ölçüldü. Bu ilk aşamada, Surprise kütüphanesi kullanılarak model tabanlı işbirlikçi filtreleme uygulanması yapılmıştır.

İkinci aşama iki adet işbirlikçi filtreleme tasarlanmıştır. Bunlardan birisi, Surprise kütüphanesinden NMF algoritması ve Surprise kütüphanesi kullanılmadan ikinci bir kullanıcı tabanlı işbirlikçi filtreleme sistemi tasarlanmıştır. Her iki sistem de farklı ölçütler kullanılarak değerlendirilmiştir. Daha sonra içerik tabanlı işbirlikçi filtreleme sistemi tasarlandı ve değerlendirildi.

Üçüncü aşamada, içerik tabanlı işbirlikçi filtreleme ve ilişki kurallarını birleştiren bir hibrit sistem uygulanarak ve değerlendirilmiştir.

#### 3.1. Tezde Kullanılan Makine Öğrenimi Kitaplıkları

**3.1.1 Pandas:** Pandas, Python için güçlü ve esnek bir açık kaynaklı veri analizi ve manipülasyon kütüphanesidir. Elektronik tablolar ve SQL tabloları gibi tablo halindeki veriler de dahil olmak üzere yapılandırılmış verileri verimli bir şekilde yönetmek için etiketli veri yapıları (R data.frame nesnelere benzer) ve istatistiksel işlevler sağlar.

**3.1.2 NumPy:** NumPy, Python'da bilimsel hesaplama için temel pakettir. Çok boyutlu bir dizi nesnesi, çeşitli türetilmiş nesnelere (gizli diziler ve matrisler gibi) ve diziler üzerinde matematiksel, mantıksal, şekil manipülasyonu, sıralama, seçim, G/Ç dahil olmak üzere hızlı işlemler için çeşitli rutinler sağlayan bir Python kütüphanesidir. Temel doğrusal cebir, temel istatistiksel işlemlere ait çeşitli fonksiyonları içerir.

**3.1.3. Matplotlib:** Matplotlib, statik, animasyonlu ve etkileşimli görselleştirmeler oluşturmaya yönelik kapsamlı bir Python kütüphanesidir. Çok çeşitli çizim araçları ve özellikleri sunması onu veri analizi ve bilimsel hesaplama için popüler bir seçim haline getirmektedir.

**3.1.4. Seaborn:** Matplotlib'i temel alan bir Python veri görselleştirme kütüphanesidir. Çekici ve bilgilendirici istatistiksel grafikler çizmek için üst düzey bir arayüz sağlar. Seaborn özellikle veri kümelerini görselleştirmek ve keşfetmek için çok uygundur ve sıklıkla pandaların veri yapılarıyla birlikte kullanılır.

**3.1.5. Sklearn:** Scikit-learn, Python için açık kaynaklı bir makine öğrenimi ve veri modelleme kütüphanesidir. Aşağıdakiler de dahil olmak üzere çeşitli sınıflandırma, regresyon ve kümeleme algoritmaları sağlar. Denetimli öğrenme: doğrusal regresyon, lojistik regresyon, karar ağaçları, rastgele ormanlar, destek vektör makineleri (SVM), vb. Denetimsiz öğrenme: K-Means kümelemesi, hiyerarşik kümeleme, DBSCAN vb.

**3.1.6. Surprise:** Surprise kitaplığı, içerik öneri sistemlerini işlemek için tasarlanmış bir Python kitaplığıdır. Derecelendirme tahmin algoritmaları ve öneri sistemleri oluşturmak ve analiz etmek için araçlar sağlar. Kütüphane, klasik benzerlik algoritmaları ve matris çarpanlarına ayırmaya (SVD, NMF, vb.) dayalı algoritmalar dahil olmak üzere, derecelendirme tahmini için bir tahmin ediciler (veya tahmin algoritmaları) koleksiyonuna sahiptir. Ayrıca Surprise, çapraz doğrulama yineleyicileri ve kütüphane içi ölçümler (mutlak ortalama ve ortalama karekök hataları gibi) gibi model performansını değerlendirmeye yönelik araçlar içerir.

## **3.2 Verilerin Eldesi ve Hazırlanması**

Bu projenin amaçları doğrultusunda, ürün öneri sistemini tasarlamak için Kaggle sitesinden elde edilen Amazon ürünlerine ilişkin veriler kullanılmıştır. Aşağıda Resim 8.'de veri yapısı gösterilmiştir.

```

Data columns (total 16 columns):
#   Column                Non-Null Count  Dtype
---  -
0   product_id            1465 non-null   bool
1   product_name          1465 non-null   bool
2   category              1465 non-null   bool
3   discounted_price      1465 non-null   bool
4   actual_price          1465 non-null   bool
5   discount_percentage   1465 non-null   bool
6   rating                1465 non-null   bool
7   rating_count          1465 non-null   bool
8   about_product        1465 non-null   bool
9   user_id               1465 non-null   bool
10  user_name             1465 non-null   bool
11  review_id             1465 non-null   bool
12  review_title          1465 non-null   bool
13  review_content        1465 non-null   bool
14  img_link              1465 non-null   bool
15  product_link          1465 non-null   bool
dtypes: bool(16)

```

Şekil 3.1. Amazon.csv dosya veri yapısı

Çalışmada veriyapısına ait tüm sütunlar dikkate alınmayacaktır. İşbirliğine dayalı filtrelemeye dayalı öneri sisteminin tasarımında yalnızca 3 sütun kullanılacaktır. Bunlar;

1. **.product\_id**
2. **.kullanıcı kimliği**
3. **.derecelendirme**

Bu üç veri, kullanıcılar ve ürünler arasındaki etkileşimi sağlamak için oluşturulmuştur. Hangi kullanıcı hangi ürünü beğendi, memnuniyet düzeyi ne oldu? gibi soruların cevabını vermektedir.

İçerik bazlı öneri sisteminin tasarımında ürün açıklama sütunu, ürün adı, kategori gibi diğer sütunlar dikkate alınmıştır. Bu farklı sütunlar, analiz ve benzerlik arama amacıyla tek bir sütunda birleştirilmiştir.

### 3.3 Eksik Değerlerin İşlenmesi

Eksik değerlerin ele alınması veri analizinde önemli bir konudur. Bu sorunu çözmek için her birinin avantajları ve dezavantajları olan çeşitli stratejiler vardır.

Orijinal verilerde "rating\_count" sütunundaki değerler String türündeydi. Sayısal değere dönüştürüldüğünde eksik değerler bulundu. Bu sorunu aşmak için bir ürünün ortalama yorum sayısı ve veri setindeki tüm ürünlerin ortalama yorum puanı hesaplandı. Bu bilgiler

eksik deęerleri doldurmak için kullanılır. Bu, makine öğrenimi algoritmalarını uygulamadan önce eksik verileri işlemek için kullanılan yaygın bir veri temizleme teknięidir.

Veri analizinde eksik deęerlerin ele alınması çok önemlidir. Tanımlanamayan deęerleri temsil eden NaN'leri doldurmak için verilerin ortalamasını almak yaygın bir yöntemdir. Bu yöntem şu avantajlara sahiptir.

1. Veri kümesi boyutunu korur. Eksik deęerleri olan satırları silmek yerine korunurlar.
2. Ortalamanın doldurulması, özellikle veriler rastgele eksikse, eksik verilerin analiz üzerindeki etkisini azaltabilir.

"Gerçek\_fiyat" sütununda deęerler dize biçiminde olduęu için temizlemek amacıyla, para birimi sembolünü ve virgölü kaldırmak için bir alt program yazılmıştır.

product_id	0
product_name	0
category	0
discounted_price	0
actual_price	1465
discount_percentage	0
rating	1
rating_count	1139
about_product	0
user_id	0
user_name	0
review_id	0
review_title	0

Şekil 3.2. Eksik deęerler

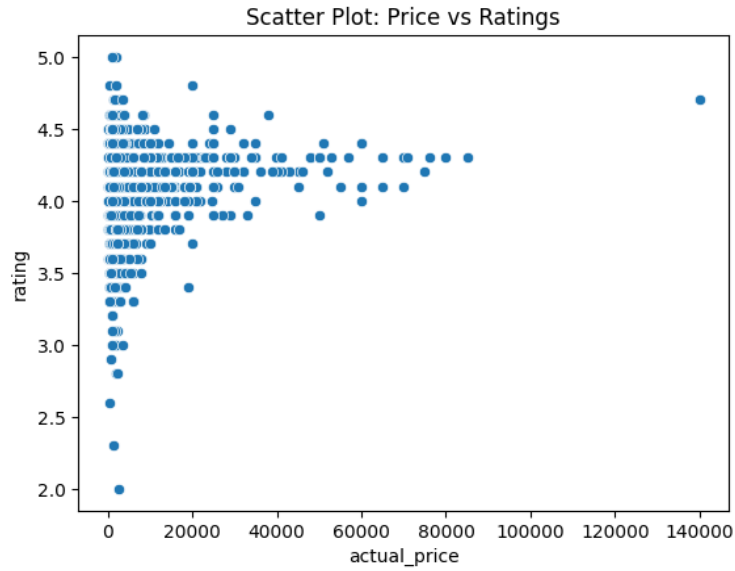
Bu işlemlerden sonra verilerin fazla/eksik deęerler içermedięinden emin olunarak öneri sistemleri algoritmalarında güvenle kullanılmıştır.

product_id	0
product_name	0
category	0
discounted_price	0
actual_price	0
discount_percentage	0
rating	0
rating_count	0
about_product	0
user_id	0
user_name	0
review_id	0

Şekil 3.3. Tamamlanmış değerler.

### 3.4 Veri Görselleştirme

"Gerçek\_fiyat" ve "derecelendirme" sütunları bir grafik üzerinde noktalar halinde çizilir. Ortaya çıkan dağılım grafiği, ürün fiyatlarının müşteri puanlarıyla nasıl ilişkili olabileceğini gösterir. Bu tür görselleştirme, daha pahalı ürünlerin daha iyi derecelendirme alması veya tam tersi gibi bir trendin olup olmadığını görmek için kullanışlıdır.



Şekil 3.4. Fiyat ve derecelendirmelerin dağılım grafiği


### 3.5 Veri Madenciliği Ön İşleme

Veri ön işlemeden sonra, verilerin daha iyi anlaşılması için bazı veri analizleri yapılmıştır. Resim 12. bize her değerlendirme değerinin veri içerisinde kaç kez tekrarlandığını göstermektedir.

rating	
4.1	244
4.3	230
4.2	228
4.0	181
4.4	123
3.9	123
3.8	86
4.5	75
3.7	42
3.6	35
3.5	26
4.6	17
3.3	16
3.4	10
4.7	6
3.1	4
3.0	4
5.0	3
4.8	3
3.2	2
2.8	2
2.6	1
2.9	1
2.3	1
2.0	1

Şekil 3.5. Veri kümesindeki her bir benzersiz derecelendirme değerinin sıklığı.

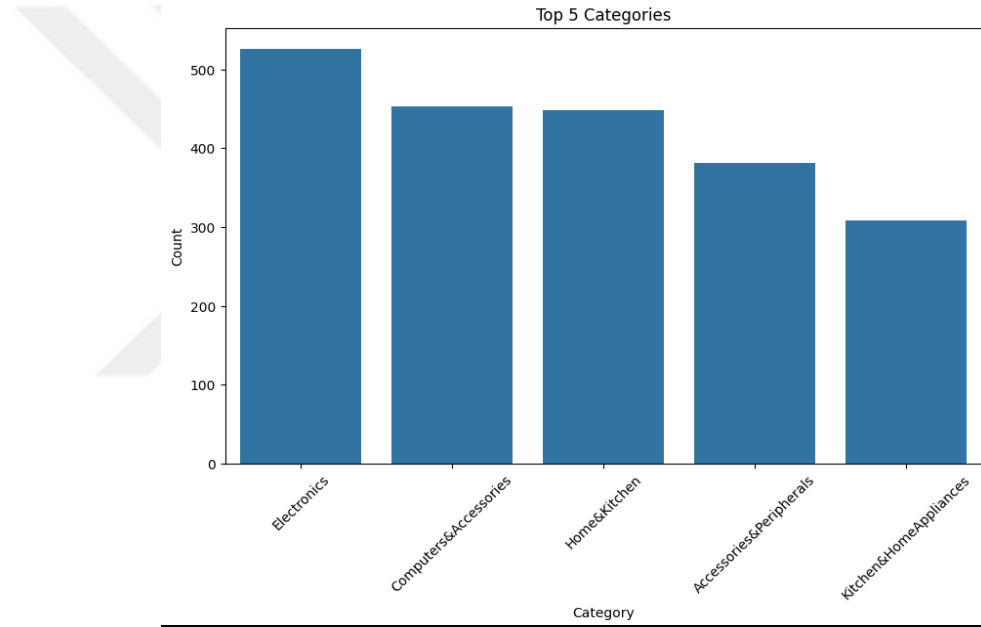
Resim 13.'te, [4,-4.5] değer aralığının etrafında yüksek tepe noktalarının olması kullanıcıların bu aralıkta derecelendirmeler atamaya yönelik güçlü bir eğilimine işaret etmektedir.



Şekil 3.6. Ürün değerlendirme dağılımı.

product_name	rating	rating_count
Duracell USB Lightning Apple Certified (Mfi) Br...	4.5	2445.000000
Zoul USB C 60W Fast Charging 3A 6ft/2M Long Typ...	4.3	1948.000000
Ambrane 2 in 1 Type-C & Micro USB Cable with 60...	4.1	1806.000000
Fire-Boltt Ninja Call Pro Plus 1.83" Smart Watc...	4.2	1741.088957
Fire-Boltt Phoenix Smart Watch with Bluetooth C...	4.3	1392.871166
Wecool Unbreakable 3 in 1 Charging Cable with 3...	4.2	1312.000000
Sounce 65W OnePlus Dash Warp Charge Cable, 6.5A...	4.0	1151.000000
SWAPKART Fast Charging Cable and Data Sync USB ...	3.9	1072.000000
boAt A400 USB Type-C to USB-A 2.0 Male Data Cab...	4.3	1044.653374
Sounce Fast Phone Charging Cable & Data Sync US...	3.9	1044.653374
Ambrane Unbreakable 60W / 3A Fast Charging 1.5m...	4.0	1044.653374
pTron Solero TB301 3A Type-C Data and Fast Char...	3.9	1044.653374
MI Usb Type-C Cable Smartphone (Black)	4.3	1044.653374
Wayona Nylon Braided USB to Lightning Fast Char...	4.2	1044.653374
Pinnaclz Original Combo of 2 Micro USB Fast Cha...	4.0	1044.653374

Şekil 3.7. En çok puan alan 15 ürün



Şekil 3.8. En yaygın 5 kategori.

Mesafelerin ortalaması ve standart sapması hesaplanıp, eşik değeri ortalama değerin belirli sayıda (tam olarak 2) üzerinde ayarlandığında, 10 üründen oluşan bir listenin aykırı değerler içerdiği görülmüştür.

Outlier product names: 764 SKYWALL 81.28 cm (32 inches) HD Ready Smart LE...  
856 Samsung 138 cm (55 inches) Crystal 4K Series U...  
1123 MI 138.8 cm (55 inches) 5X Series 4K Ultra HD ...  
1171 Sony Bravia 164 cm (65 inches) 4K Ultra HD Sma...  
1231 Samsung 138 cm (55 inches) Crystal 4K Neo Seri...  
1287 LG 139 cm (55 inches) 4K Ultra HD Smart LED TV...  
1379 VU 139 cm (55 inches) The GloLED Series 4K Sma...  
1381 VU 138 cm (55 inches) Premium Series 4K Ultra ...  
1393 VU 164 cm (65 inches) The GloLED Series 4K Sma...  
1414 Personal Size Blender, Portable Blender, Batte...  
1447 WANBO X1 Pro (Upgraded) | Native 1080P Full HD...

Şekil 3.9. Aykırı ürünler.

### 3.5.1. İçerik tabanlı işbirlikçi filtreleme ve ilişki kuralları öneri sisteminin uygulanması

Öneri sistemimizin tasarımında işbirlikçi filtreleme (CF) ve ilişki kuralları birleştirildi. Amaç, veri seyrekliğini azaltmak için çıkarılan etkileşimleri eklemektir. Birlikte kullanılan kuralları genellikle alışveriş sepeti analizinde kullanılır. Sıkça satın alınan veya birlikte kullanılan eşyaları bulmamızı sağlar. Örneğin, kullanıcılar sıklıkla A ve B'yi birlikte satın alıyorsa, A ve B arasında bir ilişki olduğunu söyleyebiliriz. Bu durumda, bir kullanıcının etkileşim geçmişinde A varsa, buna B'yi ekleyebiliriz.

İster kullanıcı tabanlı ister içerik tabanlı olsun, işbirlikçi filtrelemedeki sorun, veri yoğunluğunun düşük olmasıdır. Kullanıcı-öge etkileşim matrisi küçük olduğunda, benzerlikleri bulmak için yeterli veri olmadığından işbirlikçi filtreleme iyi çalışmayabilir. İlişkilendirme kurallarına dayalı çıkarımsal etkileşimleri ekleyerek matrisi yoğunlaştırabiliriz, bu da FC'nin (işbirlikli filtreleme) performansını iyileştirir.

### 3.5.2. Veri toplama ve ön işleme

Bu aşama, önerilecek öğeleri (ürünleri veya eşyaları) en iyi tanımlayan ilgili özelliklerin tanımlanmasını ve toplanmasını içerir. Ürünlerimiz için bu özellikler isim, açıklama, kategori gibi bilgileri içerir. Bu bilgiler toplanır ve genellikle "özellikler" adı verilen tek bir bilgi haline getirilir. Daha sonra bu "özellik" verileri temizlenir ve dönüştürülerek sistem için kullanılabilir hale getirilir. Bu bölümün ilk kısmında bu temizlik ve dönüşüm özellikle eksik veya hatalı değerlerin yönetimi gerçekleştirilir.

Daha sonra kullanıcıların etkileşim verileri toplanarak kullanıcı profili oluşturulmuştur. Kullanıcı profili oluşturmanın bu aşamasında, işlem verilerini de dikkate alarak hangi öğelerin birlikte en sık satın alındığını belirlemek için ilişkilendirme kurallarını uygulanmıştır. İlişkilendirme kuralı öğrenmesi, büyük veritabanlarındaki değişkenler arasındaki ilişkileri keşfetmek için kural tabanlı bir yöntemdir. Örneğin, pazar sepeti analizinde, müşteriler A ürünü satın alırsa, genellikle B ürünü de satın alırlar. Daha sonra, örneğin kullanıcının profilinde A ürünü varsa ve A ile B sıklıkla birlikte satın alınıyorsa, B ürünü de profiline ekleriz.

Plan şu şekilde: Bir kullanıcı A öğesiyle etkileşime girdiğinde, ilişki kurallarını kullanarak A ile ilişkili tüm öğeleri (örneğin B) ararız ve bunları kullanıcının etkileşimlerine ekleriz. Daha sonra bu zenginleştirilmiş verilere işbirlikçi filtreleme uygulanır.

### 3.5.3. Metin verilerinin dijital vektörlerinin oluşturulması

Elementlerin (ürünlerin) özelliklerinin dijital vektör gösterimi için TF-IDF (Terim Frekansı-Ters Belge Frekansı) uygulandı. TF-IDF, bir belge koleksiyonu veya gövdesi içindeki bir belgedeki bir kelimenin önemini değerlendirmek için kullanılan istatistiksel bir ölçüdür.

### 3.5.4. Kullanıcı profili oluşturma

Kullanıcı profili oluşturma, kullanıcı etkileşim verilerinin toplanıp bir araya getirilmesi ile yapılır. Yani görüntülenen, satın alınan, beğenilen, değerlendirilen ürünler... daha önce toplanan bu verilere de ön işleme ve dijital vektör gösterimi gibi aynı yöntemler uygulanarak ağırlıklı toplam değeri aşağıdaki denklem yardımıyla hesaplanır.

$$\text{Kullanıcı Profili} = \frac{\sum(\text{Not}_i + \text{vektör}_i)}{\sum \text{Not}_i} \quad 15$$

Denklemdaki pay, ürünlerin vektör toplamının, her birinin notuyla çarpılmasıyla elde edilmiştir. Paydada ise sadece notların toplamı yer almıştır. Bu yüksek notların aşırı baskın olmasını önlemek için bir normalleştirme adımı olarak uygulanmasıyla oluşur.

### 3.5.5. Birliktelik Kurallarının Uygulanması

Birliktelik kuralları uygulanırken çeşitli fonksiyonlar yardımıyla hesaplamalar gerçekleştirilir. Bunlar sırasıyla aşağıda verilmiştir.

- Support(A) değeri, A ile etkileşim olasılığının hesaplanması.

$$support(A) = \frac{T(A)}{N} \quad 16$$

Denklemdaki T(A), A'yı içeren işlemlerin toplamı ve N, işlemlerin kümesini ifade eder.

- Support (A→B): Hem A hem de B ile etkileşim olasılığının hesaplanması.

$$support(A \rightarrow B) = \frac{T(A/B)}{N} \quad 17$$

Denklemdaki T(A/B), değeri A ve B'yi içeren işlemlerin kümesini ifade etmektedir.

- Confidence(A→B): A ile etkileşime girilmişken B ile etkileşime girme olasılığının hesaplanması.

$$confidence(A \rightarrow B) = \frac{support(A \rightarrow B)}{support(A)} \quad 18$$

- Lift(A→B): A ve B arasındaki korelasyonun hesaplanması[36].

$$Lift(A \rightarrow B) = \frac{support(A \rightarrow B)}{support(A) * support(B)} \quad 19$$

(Erdoğan U., 2025).

### Artırılmış kullanıcı etkileşimi vektörü

Artırılmış kullanıcı etkileşim vektör hesaplanmasında parçalı bir fonksiyon olan Denklem 20. kullanılır.

$$V'_{uj} = \begin{cases} 1 & \text{eğer } j \text{ ile etkileşime girdiyse.} \\ \sum_{j \rightarrow i \in R} confidence(i \rightarrow j) & \text{Aksi takdirde.} \end{cases} \quad 20$$

Denklemda R, U'nun i ile etkileşime girdiği kurallar kümesini göstermektedir.

### 3.5.6. Tezde kullanılan yaklaşımın 4 temel adımı

1. **Çıkarımsal Etkileşimler:** Her kullanıcının etkileşimleri incelenerek, kullanıcının etkileşime girdiği her bir ögenin bir ilişki kuralının öncülü olup olmadığı kontrol ediliyor. Eğer geçerliyse, bu kuralın sonucu, kullanıcıyı ilgilendirebilecek potansiyel bir unsur olarak ele alınır ve kullanıcı daha önce bununla etkileşime girmemişse, bu çıkarımsal bir etkileşim olarak eklenir.

2. **Veri zenginleştirme:** Orijinal kullanıcı etkileşimleri ve çıkarılan etkileşimler birleştirilerek zenginleştirilmiş bir veri seti oluşturulur.
3. **Artırılmış Kullanıcı-Öge Matrisi:** Bu artırılmış verilerden bir kullanıcı-öge matrisi oluşturulur. Çıkarılan etkileşimler nedeniyle bu matris orijinal matristen daha yoğun hale gelir.
4. **İşbirlikçi Filtreleme:** Son olarak, bu genişletilmiş kullanıcı-öge matrisine, öge tabanlı işbirlikçi filtreleme uygulanır. Ögeler arasındaki benzerlik, kullanıcı etkileşimlerine (çıkarılanlar dahil) dayanarak hesaplanır ve bir kullanıcı için, etkileşimde bulunduğu ögelere ve benzerliklerine göre öneriler oluşturulur.

Bu yaklaşım, bazı boşlukları doldurmak için öge ilişkilerinden yararlanarak soğuk başlatma sorununu (bir kullanıcının çok az etkileşimi olması) ve seyreklik sorununu (kullanıcı-öge matrisinde çok sayıda eksik değer olması) hafifletmeye yardımcı olur.

### **3.5.7. Benzerlik hesaplaması**

Benzerlik hesaplaması için daha önce oluşturulan elemanların (ürünlerin) vektörleri, kullanıcı profilindeki vektörlerle karşılaştırılır. Bu amaçla kosinüs benzerliği, Öklid uzaklığı gibi ölçütlere başvurulmuştur.

### **3.5.8. Top-N ürün önerileri**

Kullanıcının daha önce beğendiği veya satın aldığı ürünler kaldırılır ve kullanıcıya en fazla benzerliğe sahip Top-N ürünleri önerilir. Kullanıcılara Top-N ürünleri önermek, avantaj olarak bilginin aşırı yüklenmesini önleyerek karar vermeyi kolaylaştırmayı sağlar.

### **3.5.9. Sistem değerlendirmesi**

Bir öneri sisteminin performansının farklı yönlerini değerlendirmek için çeşitli ölçütler kullanılır. Genellikle bir kullanıcının hangi unsurlarla olumlu etkileşime gireceğini tahmin etme yeteneğine odaklanılır.

### **3.5.10. İçerik tabanlı öneri sistemini çevrimdışı değerlendirme**

Çevrimdışı değerlendirme için, içerik tabanlı öneri sistemini değerlendirmek amacıyla doğruluk, geri çağırma ve F1 puanı gibi sıralama tabanlı metrikler kullanılmıştır ve sonuçlar Tablo 10'teki sonuç bölümünde sunulmuştur.

### **3.5.11. İşbirlikçi filtrelemenin uygulanması**

Buradaki temel fikir, iki kullanıcının bir ürüne aynı ilgiyi göstermesi durumunda, diğerlerine de aynı ilgiyi gösterme olasılığının yüksek olmasıdır.

### **3.5.12. Veri toplama ve ön işleme**

Öneri sisteminin eğitilmesi ve test edilmesi için Kaggle'dan indirilen kullanıcı-öğe derecelendirme verileri kullanılmıştır.

### **3.5.13. Yöntem**

Kullanıcı tabanlı işbirlikçi filtrelemeyi uygulamak için ilk önce Surprise kütüphanesinden NMF algoritması kullanıldı. Daha sonra Surprise kütüphanesi olmadan ikinci bir sistem kullanıldı.

### **3.5.14 Pazarlama otomasyonu için yerleşik makine öğrenimi**

Dijital pazarlamada ML'nin olası uygulama alanları arasında müşteri segmentasyonu, kişiselleştirilmiş öneriler, e-posta kampanyası optimizasyonu ve reklam teklifi yer almaktadır.

Müşterileri farklı gruplara (kümelere) ayırmanın amacı, daha sonra e-posta gönderme, içerik kişiselleştirme vb. gibi çeşitli pazarlama kampanyaları için doğru hedefleri seçebilmektir. Bunun için müşteri modelimizin yaş, tarama süresi, toplam satın alma gibi nitelikleri, sklearn kümeleme ve DBSCAN'ın k-ortalamlar algoritmaları için sınıflandırma kriteri olarak kullanıldı. Daha sonra müşterinin ait olduğu segmentin kaydedildiği yeni bir nitelik olan “segment” eklenerek müşteri modeli güncellenir. Bu süreç, her istemcinin hemen hemen her zaman doğru kümede olmasını sağlamak için Celery kütüphanesi kullanılarak periyodik olarak yinelenir. Segmentasyonun temel amacı, örneğin aynı promosyon teklifi için hedeflenebilecek benzer müşterilere sahip olmaktır.

Tablo 3.1. Örnek müşteri modeli

Müşteri
...
yaş
Tarama_zamanı
Toplam_satın_almalar

Tablo 3.1, ona atamak istediğimiz ayrıntı düzeyine bağlı olarak çeşitli alanlardan (veya niteliklerden) oluşan bir müşteri modelini göstermektedir. “Tarama\_zamanı”, “Toplam\_satın\_almalar” gibi bu farklı alanlar (nitelikler) müşteri segmentini belirlemek için kullanılır.

Tablo 3.2. Güncelleme sonrası istemci modeli.

Müşteri
...
yaş
Tarama_zamanı
Toplam_satın_almalar
küme

Tablo 3.2, müşteri modeline yeni bir niteliğin, nitelik (karakteristik) "Küme"nin eklendiğini göstermektedir. Bu, ait oldukları müşteri sınıfını veya grubunu belirler.

### 3.5.15 E-posta pazarlaması

Segmentasyon sonrasında içerik tabanlı öneri sistemi ile her segmentin tercihlerine göre ürün önerilerinde bulunuluyor. Aslında siteye her yeni ürün yüklendiğinde, django sinyal bileşeni olayı yakalar ve yeni ürün ile kullanıcı profili arasındaki benzerliği hesaplayan içerik tabanlı öneri algoritmasını çalıştırır. Benzerliği yüksek olan kullanıcı profiline ürün detay bağlantısının yer aldığı e-posta gönderilir.

Yeniden etkileşim kampanyası için ilk adım, bir müşterinin dönüştürülmemiş olarak kabul edilebileceği kriterleri tanımlamaktır. Bu nedenle aşağıdaki kriterler korunmuştur.

- İki ay boyunca alışveriş yapmayan müşteriler.

**Etkin Olmama = Güncel Tarih - Son Satın Alma Tarihi**

- Son iki e-postayla etkileşime girmeyen müşteriler
- 30 gün önce alışveriş sepetini terk eden müşteriler

**Sepet Terk Edilmesi = Mevcut Tarih - Son Sepet Etkinliği Tarihi**

Bu kriterler üzerinden yeni bir segmentasyon yapılır ve her segmente kişiselleştirilmiş bir e-posta gönderilir.



## 4. BULGULAR

Çalışmanın ilk aşamasında, model bazlı filtreleme için derecelendirme tahmin algoritmalarının oluşturulması ve analiz aşamalarında kullanılan Surprise kütüphanesi kullanılmıştır. Surprise kütüphanesi, temel benzerlik algoritmalarının yanı sıra SVD ve NMF gibi matris çarpanlarına ayırmaya dayalı algoritmaları da içerir (Lee ve Seung, 2001). Kullanım kolaylığı sayesinde az sayıda kodla öneri sistemi uygulamasına olanak sağlayan bir kütüphanedir.

Bu modeli anlamak için işbirlikçi filtreleme açıklanmış ve temel işbirlikçi filtreleme yöntemlerine yer verilmiştir.

### 4.1. İşbirlikçi Filtreleme

#### 4.1.1. Model tabanlı yaklaşım çevrimdışı değerlendirme

Çalışmanın ilk aşamasında kosinüs benzerlik ölçüsü kullanılarak SVD, SVDpp, SlopeOne, NMF, NormalPredictor, KNNBaseline, KNNBasic, KNNWithMeans ve KNNWithZScore algoritmaları üzerinde deneyler yürütülmüştür. Cross\_validate yöntemi ile test verileri üzerinde yapılan öneri, RMSE (Ortalama Karekök Hata Hesaplaması) ve MAE (Mutlak Ortalama Hata) ölçütleri ile hesaplanmıştır.

RMSE ve MAE öneri performans hesaplamalarının sonuçları ve her algoritmanın işlem süreleri Tablo 7 ve 8'de gösterilmiştir.

Tablo 4.1. Kosinüs benzerliği ile yapılan testlerin sonuçları.

Algoritmalar	Test_RMSE	Test_MAE	Fit_time	Test_time
SVD	1.0419	0.8786	0.00	0.00
SVDpp	1.0616	0.8575	0.00	0.00
SlopeOne	1.2540	1.0189	0.00	0.00
NMF	1.2370	1.0339	0.00	0.00
NormalPredictor	1.4270	1.1944	0.00	0.00
KNNBaseline	1.0455	0.8586	0.00	0.00
KNNBasic	1.1606	0.9272	0.00	0.00

Tablo 4.1.'de KNNBaseline ve SVD algoritmalarının daha düşük RMSE ve MAE puanlarıyla verilerimiz üzerinde en iyi performansı gösterdiğini görebiliriz.

Tablo 4.2. Pearson benzerliđi ile yapılan testlerin sonuçları.

Algoritmalar	Test_RMSE	Test_MAE	Fit_time	Test_time
SVD	1.0819	0.8563	0.00	0.00
SVDpp	1.0595	0.8749	0.00	0.00
SlopeOne	1.1134	0.9223	0.00	0.00
NMF	1.2782	1.0872	0.00	0.00
NormalPredictor	1.3586	1.0299	0.00	0.00
KNNBaseline	1.0054	0.7948	0.00	0.00
KNNBasic	1.1964	0.9368	0.00	0.00

Tablo 4.2.'de KNNBaseline'ın en iyi performansa sahip olduđu daha düşük RMSE ve MAE puanlarıyla açıkça görölmektedir.

#### 4.1.2 Hafızaya dayalı yaklaşım çevrimiçi deđerlendirme

Online deđerlendirme için 100 kullanıcı web sitesine kayıt oldu ve ürünlere puan verdi. 100 kişiden %85'i yapılan önerileri yerinde buldu.


#### 4.1.3 Kullanıcı tabanlı işbirlikçi filtreleme

Surprise kütüphanesi kullanmadan yapılan işbirlikçi filtrelemenin performans sonuçları aşağıdaki gibi elde edilmiştir.

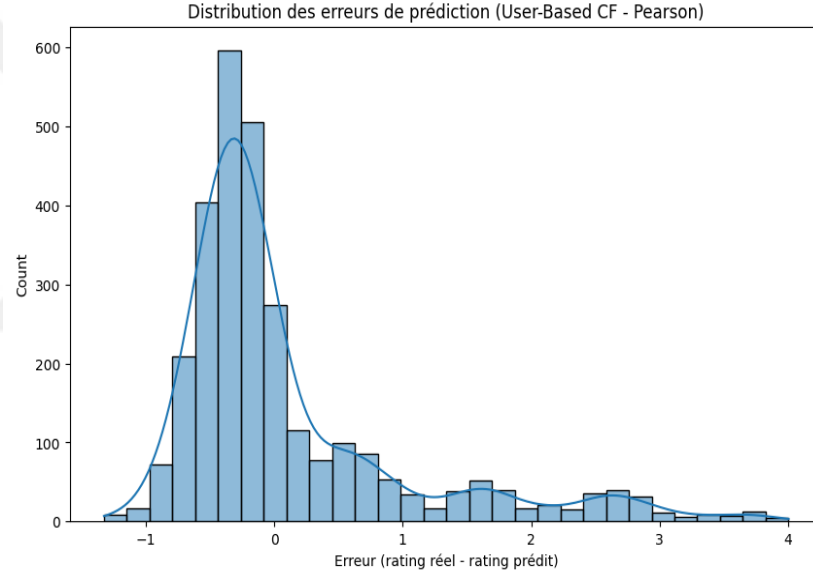
Tablo 4.3. Surprise kütüphanesi olmadan işbirlikçi filtrelemenin performans sonuçları.

Ölçüt	Test_RMSE	Test_MAE
Kosinüs	0.929	0.574
Pearson	0.928	0.616

Tablo 4.3., ya göre kosinüs benzerliđi ölçüsüyle, RMSE'nin 0,929 ve MAE'nin 0,575 olmasıyla daha iyi sonuçlar elde edilmiştir. Pearson korelasyonu için ise RMSE'nin 0,928 ve MAE'nin 0,616 olmasıyla iyi sonuçlar elde edilmiştir.



Şekil 4.1. Kosinüs benzerliği ile tahmin hatalarının dağılımı.



Şekil 4.2. Pearson korelasyonu ile tahmin hatalarının dağılımı.

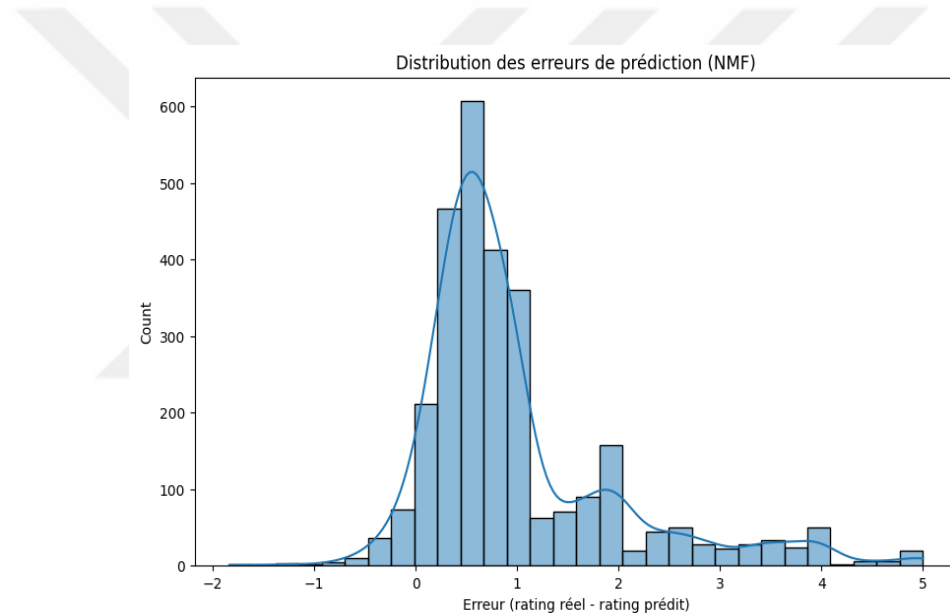
Her iki grafikte de, X ekseninde 0 civarında puanların dağılımında bir tepe gözlemlenmiştir. Bu durum, modelin çoğu zaman nispeten doğru tahminler yaptığını ve birçok hatanın sifira yakın olduğunu gösterir. Bu tepe 0 civarında ne kadar yüksek ve darsa, tahminler o kadar iyidir. Ve Y ekseninde, hataların sıklığını gözlemlenmesi ile Pearson korelasyonu ile, hataların sıklığının daha yüksek olduğu açıktır.

#### 4.1.4 Surprise kütüphanesinden nmf yöntemi ile kullanıcı tabanlı işbirlikçi filtreleme

Tablo 4.4. NMF yöntemini kullanan kullanıcı tabanlı işbirlikçi filtrelemenin performans sonuçları.

Algoritma	Test_RMSE	Test_MAE
NMF	1.404	1.020

Tablo 4.4, Surprise kütüphanesinden alınan NMF yöntemi ile uygulanan kullanıcı tabanlı işbirlikçi filtrelemenin, 4'e eşit bir alaka eşiği ile performans sonuçlarını göstermektedir.



Şekil 4.3. NMF ile tahmin hatalarının dağılımı.

Şekil 4.3'da 0 ile 1 arasında önemli tepe noktalarının olması, sistemin tahminlemesinin en az 1 puan düşük ettiğini göstermektedir.

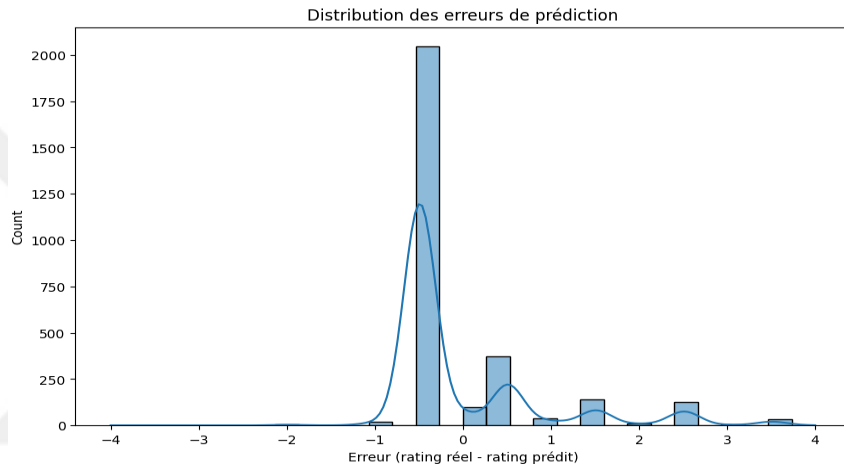
#### 4.1.5 Öğe tabanlı işbirlikçi filtreleme sistemi

Çıkarımsal veriler kullanılarak oluşturulan hibrit modelimizle karşılaştırıldığında, öğe tabanlı işbirlikçi filtrelememizin tasarımı ve değerlendirilmesi için 500 kullanıcının 150 ürününe ait işlem verisi kullanılmış ve 1518 puan üretilmiştir.

Tablo 4.5. Sistem performans ölçümleri (öğe tabanlı CF).

Metrik	Değer
RMSE	0.897
MAE	0.675

Tablo 4.5'da görüldüğü gibi, etkileşim verisi olarak derecelendirme verilerini kullanan madde tabanlı işbirlikçi filtreleme, verilerimiz üzerinde oldukça iyi bir performans gösterdi. RMSE değeri 0,897 ve MAE değeri 0,675' olarak hesaplanmıştır.



Şekil 4.4. Tahmin hatalarının dağılımı.

Resim 4.4'de x eksenini tahmin hatasını (Gerçek Derecelendirme - Tahmin Edilen Derecelendirme) temsil eder. Pozitif bir değer modelin derecelendirmeyi düşük tahmin ettiğini, negatif bir değer ise yüksek tahmin ettiğini gösterir. 0 hatası mükemmel bir tahmin anlamına gelir. Y eksenini bu belirli hataya sahip tahminlerin sıklığını veya sayısını temsil eder. Grafik -1 ile 0 arasında bir tepe noktası gösterir, bu da sistemimizin tahminleri yaklaşık 1 puan yüksek tahmin ettiği anlamına gelir.

#### 4.2. Çıkarılan Verilerle Öğe Tabanlı Öneri Filtreleme

Tüm test verilerinde ilgili derecelendirme eşliğini farklı değerlere eşit olarak ele aldığımızda hibrit sistemi aşağıdaki tabloda sunulan RMSE ve MAE değerlerini vermiştir.

Tablo 4.6. Sistem performans ölçümleri (hybrit).

Metrik	Değer
RMSE	1.050
MAE	0.695

### 4.3. Basit İçerik Tabanlı Öneri Sistemi

Tablo 4.7. Kosinüs benzerliği ile içerik tabanlı öneri sisteminin performansı.

Metrikler	Değerler
F1-puanı	0.9000
kesinlik	1.0000
hatırlamak	0.8182

Tablo 4.7, içerik tabanlı öneri sisteminin performans değerlendirme sonuçlarını 1 hassasiyet ve 0,8182 hatırlama oranıyla sunmakta olup, önerilen maddelerin iyi bir alaka düzeyine sahip olduğunu göstermektedir.

## 5. TARTIŞMA VE SONUÇ

E-ticaretin hızlı büyümesi ve çevrimiçi verilerin büyüyen hacmi, kişiselleştirme ve verimlilik için akıllı sistemleri gerekli kılıyor. Makine öğrenimi (ML), veri odaklı karar alma ve otomasyonu mümkün kılarak e-ticaretin dönüşümünde önemli bir teknoloji olarak ortaya çıktı. Öneri sistemleri (RS) ve dijital pazarlama otomasyonu, makine öğreniminin e-ticarete önemli bir etki gösterdiği iki temel alandır.

Öneri sistemleri, ortaya çıktıkları günden bu yana bilgi teknolojisi dünyasında temel araçlar olarak kendilerini kanıtlamışlardır. İşletmeler için gerçek büyüme itici güçleri ve kullanıcılar için seçim kolaylaştırıcıları olarak, bu sistemler özellikle makine öğrenimi algoritmalarının kapsamlı entegrasyonu sayesinde hızlı bir büyüme yaşadılar. Bu nedenle işletmelerin stratejilerini geliştirme biçimlerini ve kullanıcıların dijital içerikle etkileşim kurma biçimlerini temelden yeniden tanımlıyorlar.

Bu tezde, birkaç öneri sistemi tasarlandı ve test edildi. Bunlar; model tabanlı işbirlikçi filtreleme sistemi, kullanıcı tabanlı işbirlikçi filtreleme öneri sistemi, içerik tabanlı bir öneri sistemi, ve hibrit öneri sistemleridir.

Model tabanlı işbirlikçi filtreleme için, kosinüs benzerliği ölçümü kullanılarak yapılan deneyde, SVD algoritması 1.0419, SVDpp algoritması 1.0616, KNNBaseline algoritması 1.0455, SlopeOne algoritması 1.2540, NMF algoritması 1.2370, KNN Basic algoritması 1.1606 ve Normal Predictor algoritması 1.472653 RMSE değeri vermiştir.

Yine kosinüs benzerliği ölçümü kullanılarak yapılan deneyde, SVD algoritması 0.8786, SVDpp algoritması 0.8576, KNNBaseline algoritması 0.8586, SlopeOne algoritması 1.0189, NMF algoritması 1.0339, KNN Basic algoritması 0.9272 ve Normal Predictor algoritması 1.1944 MAE değeri vermiştir.

Kosinüs benzerliği ile elde edilen sonuçlar incelendiğinde KNNBaseline ve SVD algoritmalarının daha düşük RMSE ve MAE puanlarıyla verilerimiz üzerinde en iyi performansı gösterdiğini görebiliriz.

Model tabanlı işbirlikçi filtreleme için diğer bir çalışmada, Pearson benzerliği ölçümü kullanılarak yapılan deneyde, SVD algoritması 1.0819, SVDpp algoritması 1.0595, KNNBaseline algoritması 1.0054, SlopeOne algoritması 1.1134, NMF algoritması

1.2782, KNN Basic algoritması 1.1964 ve Normal Predictor algoritması 1.3586 RMSE değeri vermiştir.

Yine Pearson benzerliği ölçümü kullanılarak yapılan deneyde, SVD algoritması 0.8563, SVDpp algoritması 0.8749, KNNBaseline algoritması 0.7948, SlopeOne algoritması 1.9223, NMF algoritması 1.0872, KNN Basic algoritması 0.9368 ve Normal Predictor algoritması 1.1944 MAE değeri vermiştir.

Pearson benzerliği ile elde edilen sonuçlar incelendiğinde daha düşük RMSE ve MAE puanlarıyla KNNBaseline'ın en iyi performansa sahip olduğu açıkça görülmektedir.

Kullanıcı tabanlı işbirlikçi filtreleme öneri sistemi için Surprise kütüphanesinin NMF yöntemi ile elde edilen deneyde RMSE değeri 1.404, MAE değeri ise 1.020 olarak elde edilmiştir.

İçerik tabanlı işbirlikçi filtreleme için, kosinüs benzerlik ölçümünü kullanarak sistem 0,897 RMSE ve 0,675 MAE performans ölçümü elde etti.

Hibrit sistem için, kosinüs benzerlik ölçümünü kullanarak yapılan deneyde algoritma ile 1,050 RMSE ve 0,695 MAE performans ölçümü elde etti.

Matematiksel metrikler RMSE ve MAE'ye göre, işbirlikçi filtreleme tek başına kullanılan hibrit yöntemini küçük bir farkla geride bırakıyor. Ancak hibrit sistem test sırasında daha fazla öneri kapsamına ve daha fazla öneri çeşitliliğine sahip olduğu gözlenmiştir.

E-ticaret sektörünün tartışmasız mihenk taşı olan Amazon, müşterilerine ürün tavsiye ederken iş birlikçi filtrelemeyi kullanıyor. İşbirlikçi filtreleme öneri yöntemleri hızla gelişti. Öğe tabanlı CF ve kullanıcı tabanlı CF, farklı öğeler ve kullanıcılar arasındaki ilişkilerin belirlenmesine olanak tanır. Yaklaşımına göre kullanıcı-ürün, kullanıcı-kullanıcı, ürün-ürün matrisleri analiz edilir ve daha sonra bu ilişkilerden müşterilere yönelik öneriler hesaplanır. CF'nin ilk sürümlerinde soğuk başlatma, veri seyrekliği ve zayıf ölçeklenebilirlik gibi birçok sorun vardı. Soğuk başlatma problemini çözmek için çeşitli teknikler kullanılmaktadır. Örneğin, henüz herhangi bir etkileşim geçmişi olmayan ve dolayısıyla CF'nin diğer kullanıcılar veya öğelerle benzerliği hesaplamak için temel alabileceği verileri olmayan yeni bir müşteri için bazıları en popüler öğeleri öneri olarak sunar.

Çıkarımsal verileri ilişkilendirme kuralları kullanarak ekleme yöntemi, işbirlikçi filtrelemede karşılaşılan veri kıtlığı sorununa güvenilir bir çözüm olarak düşünülebilir ve

aynı zamanda onun gelişmesine de olanak sağlar. Kullanıcı tabanlı işbirlikçi filtreleme neredeyse yalnızca kullanıcı öge derecelendirme verilerini kullanır. Çıkarımsal veriler belirli ağırlıklarla eklendiğinde etkileşim verileri daha yoğun hale gelir ve veri ne kadar fazlaysa işbirlikçi filtrelemenin önerileri de o kadar alakalı hale gelmiş olur.

Dijital pazarlama stratejilerine etkili ve ölçülenebilir bir öneri sistemi uygulamak büyük fark oluşturabilir. Özenle hazırlanmış müşteri segmentasyonu sonrasında sistem, farklı segmentlere nokta atışı ilgili önerilerde bulunabilmektedir. Böylece müşteri deneyiminin daha iyi kişiselleştirilmesine olanak sağlanmış olmaktadır.



## KAYNAKLAR

- (Anonim), 2023. Segmentation de la clientèle : le marketing ciblé simplifié.  
<https://business.adobe.com/fr/blog/basics/define-customer-segmentation> (19.02.2025).
- (Anonim), 2021. Historique Du E-Commerce: Évolution & Dates Clés [1960 - 2020].  
<https://www.wizishop.fr/blog/historique-ecommerce> (06.01.2025)
- (Anonim), 2025. L'essor Du Commerce Électronique ; Introduction, Développement Et Catégories. <https://www.xtransfer.com/fr/wiki/trade-terms/the-rise-of-e-commerce-introduction-development-and-categories> (05.01.2025)
- (Anonim), 2024. Segmentation client & intelligence artificielle : Comment créer des segments avec l'IA. <https://www.cartelis.com/blog/segmentation-client-intelligence-artificielle-ia/> (19.02.2025)
- (Anonim), 2018. Power of Me. Dallas, <https://www.epsilon.com/us/about-us/pressroom/new-epsilon-research-indicates-80-of-consumers-are-more-likely-to-make-a-purchase-when-brands-offer-personalized-experiences>
- (Anonim), 2025. Le Machine Learning amène une révolution au monde du marketing ciblé.  
<https://www.etic-insa.com/datascience-ia/machine-learning-marketing> (19.02.2025)
- (Anonim), 2025. turkiyedeki-sosyal-medya-kullanilari-2023-rakamlari-aciklandi.  
<https://fr.rayhaber.com/2025/05/turkiyedeki-sosyal-medya-kullanilari-2023-rakamlari-aciklandi/> (10.02.2025)
- (Anonim), 2025. Future of AI-Powered Digital Marketing.  
<https://www.reachfirst.com/future-of-ai-powered-digital-marketing/> (03.03.2025)
- (Anonim), 2025. Tendances actuelles du e-commerce et bonnes pratiques d'intégration pour votre entreprise. <https://inventiv-it.fr/tendances-ecommerce/> (15.01.2025)
- (Anonim), 2025. Ecommerce-Statistics.  
<https://www.salesforce.com/commerce/ecommerce-statistics/> (25.01.2025)
- Aggarwal, C. C., 2016. Recommender Systems: The Textbook. pp.1–3, 30–35, Springer.

- Airey D., 2020. A Guide to Creating Iconic Brand Identities. Berkeley: New Riders.
- Allen, R.B., 1990. User models: theory, method, and practice. *International Journal of Man-Machine Studies*, 32(5), 511-543.
- Amandine D., 2024. Histoire Et Évolution Du Commerce Électronique Dans Le Monde. <https://fr.textmaster.com/blog/histoire-evolution-e-commerce/>; (03.01.2025)
- Anshari, M., Almunawar, N., Lim, and A. Al-Mudimigh S. A., 2018. Customer relationship management and big data enabled: Personalization & customization of services. *Applied Computing and Informatics*, doi:10.1016/j.aci.2018.05.004.
- Aras, M.E., 2010. Birliktelik Kuralları ile Web Siteleri İçin Tavsiye Motoru Uygulaması. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Bhatnagar, Bijendra, T., 2021. Hyper-Personalized Recommendation Systems: A Systematic Literature Mapping. In *Disruptive Technologies for Society 5.0*. Taylor & Francis. <https://doi.org/10.1201/9781003154686-4>
- Cenk E., 2015. Elektronik Ticarete Tüketicilerin Satın Alma Davranış Ve Tercihlerini Etkileyen Unsurlar: E-Ticaret Siteleri Üzerine Bir Çalışma.
- Chaffey, D., Ellis-Chadwick, F., 2019. *Digital Marketing: Strategy and Implementation*. Pearson Education.
- Deshpande, M. and Karypis G., 2001. Selective Markov Models for Predicting Web-Page Accesses. *Proceedings of the First SIAM International Conference on Data Mining (SDM'2001)*.
- Donald J. Kridel, Daniel R. Dolk, David Castillo, 2013. *Recommender Systems as a Mobile Marketing Service*.
- Erdoğan U., 2025. Birliktelik Kuralları. [https://erdincuzun.com/makine\\_ogrenmesi/association-rules-birliktelik-kurallari/](https://erdincuzun.com/makine_ogrenmesi/association-rules-birliktelik-kurallari/)
- Ferreira, D., Silva, S., Abelha, A., and Machado, J., 2020. Recommendation System Using Autoencoders, *Applied Sciences*, 10, 5510.

Michael, 2025. Les principaux avantages du marketing génératif de l'IA pour les entreprises. <https://www.on24.com/fr/blog/top-benefits-of-generative-ai-marketing-for-businesses/>

Molly H., Amanda D., 2023. L'IA générative dans le marketing. <https://www.ibm.com/fr-fr/think/topics/generative-ai-marketing>

Jacuński, M., 2018. Measuring and Analysis of Digital Marketing. University of Wrocław, pp. 10–24.

Jacek Piotrowski, 2021. Machine Learning and Marketing Automation — Will ML transform your business. <https://encharge.io/machine-learning-marketing-automation/>

Jannach, D., Zanker, M., Felfernig, A., Friedrich, G., 2011. Recommender systems: An introduction. Cambridge University Press.

Kotler, P. & Keller, K., 2012. Marketing Management. Upper Saddle River, N.J. Prentice Hall.

LITMUX, 2014. The New Rules Of Digital Marketing. Digital Marketing Made Simple Learn Latest Skills, Techniques And Strategies. White avenue East Legon

Magdalena D., 2025. What Is Digital Marketing? Definition, Types & Examples. <https://landingi.com/digital-marketing/>

Marko Balabanovi'c, Yoav Shoham, 1997. Content-Based, Collaborative Recommendation.

Minculete, G. & Olar, P., 2018. Approaches to the Modern Concept of Digital Marketing. International Conference Knowledge-Based Organization.

Pearl Pu, Li Chen, Rong Hu., 2011. A user-centric evaluation framework for recommender systems

Saaty, T.L., 2008. Decision Making with the Analytic Hierarchy Process. International Journal of Services Science, *1(1)*, 83–98.

Sachi Nandan Mohanty et al., 2020. Recommender System with Machine Learning and Artificial Intelligence

Sahakian, B.J., LaBuzetta, J.N., 2013. Bad Moves: How Decision Making Goes Wrong, and the Ethics of Smart Drugs. Oxford University Press.

Sedanur YEŞİLKAYA KOÇ, 2023. Derin Öğrenme Tabanlı Öneri Sistemleri Analizi ve Bir Uygulama.

Subaşı, H.H., 2012. Elektronik Ticaret ve Güven: Bir Araştırma. Gazi Üniversitesi, Sosyal Bilimler Enstitüsü.

SMAIL Mehdi, M., 2023. L'apport du Marketing Digital dans la fidélisation client. Université 8 Mai 1945 Guelma, Algérie.

Stephan S., 2014. Ecommerce Personalization Blog. <https://www.barilliance.com/what-is-personalization-in-ecommerce/>

Thamar Leonard (2024). La compréhension et la prédiction des préférences des clients dans le commerce en détail grâce à l'IA. International Journal of Economic Studies and Management (IJESM).

Wierenga, B., Van der Lans, R., 2017. Handbook of Marketing Decision Models. Springer. <https://doi.org/10.1007/978-3-319-56941-3>

## ÖZGEÇMİŞ

