



T.C.  
ÜSKÜDAR ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MÜHENDİSLİĞİ ANABİLİM DALI  
YAPAY ZEKA MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI  
YÜKSEK LİSANS TEZİ

**Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile E-Ticaret Sistemlerinde: Ürün Önerisi Amaçlı En İyi Model Seçimi ve Performans Değerlendirmesi**

**Cansu ÇERİ**

**Tez Danışmanı**  
**Dr. Öğr. Üyesi Ersin ERSOY**

**İSTANBUL-2025**

T.C.  
ÜSKÜDAR ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MÜHENDİSLİĞİ ANABİLİM DALI  
YAPAY ZEKA MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI  
YÜKSEK LİSANS TEZİ

**Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile E-Ticaret  
Sistemlerinde: Ürün Önerisi Amaçlı En İyi Model Seçimi ve  
Performans Değerlendirmesi**

**Cansu ÇERİ**

**Tez Danışmanı  
Dr. Öğr. Üyesi Ersin ERSOY**

**İSTANBUL-2025**

## ÖZET

### **Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile E-Ticaret Sistemlerinde: Ürün Önerisi Amaçlı En İyi Model Seçimi ve Performans Değerlendirmesi**

E-ticaret sektöründe kullanıcı deneyimini ve satışları artırmanın en önemli yollarından biri, kullanıcılara özel ürün önerileri sunabilen öneri sistemleridir. Bu sistemler, kullanıcıların geçmiş etkileşimleri, satın alma alışkanlıkları ve ürün özellikleri gibi verileri analiz ederek kişiselleştirilmiş öneriler oluşturur. Günümüzde, büyük e-ticaret platformları (Amazon, Alibaba, Hepsiburada, Trendyol vb.) tarafından kullanılan gelişmiş öneri algoritmaları, müşteri sadakatini artırmak ve dönüşüm oranlarını yükseltmek için kritik bir rol oynamaktadır. Bu çalışmada, özel olarak oluşturulmuş ve gerçek bir e-ticaret platformundan elde edilen özgün bir veri seti kullanılarak, farklı makine öğrenmesi ve derin öğrenme tabanlı algoritmaların ürün öneri sistemlerindeki performansı karşılaştırılmıştır. Bu çalışmada, e-ticaret platformlarında kullanıcı deneyimini geliştirmek amacıyla geniş bir algoritma yelpazesi ele alınmıştır. Algoritmalar, her bir kullanıcının tercihlerine göre önerilerde bulunmayı hedeflerken, farklı yöntemler ve yaklaşımlar kullanılmaktadır. Bu algoritmaların performansı; Ortalama Doğruluk (MAP), Kapsama Oranı (Coverage- CC), Ortalama Önerilen Ürün Sayısı (MNS), Ortalama Derinlik Skoru (MDS) ve Ortalama Kişiselleştirme Skoru (MPS) metrikler kullanılarak kapsamlı bir şekilde değerlendirilmiştir. Çalışmanın temel amacı, farklı algoritmaların öneri doğruluğu, çeşitlilik, yenilikçilik ve kişiselleştirme açısından güçlü ve zayıf yönlerini ortaya koyarak, en uygun öneri modelini belirlemektir. Ayrıca, özgün e-ticaret verisi kullanılması sayesinde, öneri sistemlerinin gerçek dünya senaryolarında nasıl çalıştığı daha gerçekçi bir şekilde değerlendirilmiştir. Bu çalışma, e-ticaret platformları için en uygun öneri sistemini belirlemek isteyen araştırmacılar ve sektör profesyonelleri için yol gösterici niteliktedir. Aynı zamanda, farklı öneri algoritmalarının avantajlarını ve sınırlamalarını ortaya koyarak, gelecekte bu sistemlerin daha etkin hale getirilmesi için potansiyel geliştirme alanlarını sunmaktadır.

**Anahtar Kelimeler:** ürün öneri sistemleri, makine öğrenmesi, derin öğrenme, performans değerlendirme

## ABSTRACT

### **Model Selection and Performance Evaluation for Product Recommendation in E-Commerce Systems Using Machine Learning and Deep Learning Methods**

One of the most important ways to enhance user experience and increase sales in the e-commerce sector is through recommendation systems that offer personalized product suggestions. These systems analyze data such as user interactions, purchasing habits, and product features to generate tailored recommendations. Advanced recommendation algorithms used by large e-commerce platforms play a critical role in boosting customer loyalty and increasing conversion rates. This study compares the performance of various machine learning and deep learning-based algorithms for product recommendation systems using an original dataset from an e-commerce platform. A wide range of algorithms aimed at improving user experience in e-commerce platforms is examined. These algorithms use different methods and approaches to provide recommendations based on individual user preferences. The performance of these algorithms is comprehensively evaluated using metrics such as Mean Average Precision (MAP), Catalog Coverage (CC), Mean Number of Suggested Products (MNS), Mean Depth Score (MDS), and Mean Personalization Score (MPS). The primary aim of the study is to identify the most suitable recommendation model by highlighting the strengths and weaknesses of each algorithm in terms of recommendation accuracy, diversity, novelty, and personalization. The use of an original e-commerce dataset allows for a more realistic evaluation of how recommendation systems perform in real-world scenarios. This study serves as a guide for researchers and industry professionals seeking to determine the most effective recommendation system for e-commerce platforms.

**Keywords:** product recommendation systems, machine learning, deep learning, performance evaluation

## TEŐEKKÜR

Bu alıőmanın gerekleőtirilmesinde saėladıkları veri setleri ve teknik destek nedeniyle Oksid Biliőim ve İncehesap Őirketlerine iten teőekkür ederim. Gerek analiz sũrecinde gerekse sistem geliőtirme aőamalarında verdikleri katkılar, araőtırmamın uygulanabilirliėini ve geerliliėini önemli ölçũde artırmıőtır. Destekleri iin her iki kuruma da Őükranlarımı sunarım.

Akademik yolculuėum boyunca, engin bilgi ve deneyimleriyle alıőmamın bilimsel temeller üzerinde Őekillenmesine rehberlik eden kıymetli hocam **Dr. Öğr. Üyesi Ersin Ersoy'a** en iten teőekkürlerimi sunarım.

Hayatım boyunca yanımda olan sevgili annem ve en büyük destekilerimden biri olan eőim **Sefer eri** bu sũrete bana güç ve motivasyon kaynaėı olmuőtur. Tez sũrecinde gösterdikleri anlayıő ve sabır iin hepsine en iten teőekkürlerimi sunarım.

## BEYAN FORMU

Bu çalışmadaki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi, görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, yararlandığım kaynaklara bilimsel normlara uygun olarak atıfta bulunduğumu, tezimin kaynak gösterilen durumlar dışında özgün olduğunu, tarafımdan üretildiğini ve Üsküdar Üniversitesi Sağlık Bilimleri Enstitüsü Tez Yazım Kılavuzuna göre yazıldığımı beyan ederim



**Tarih**  
**Öğrencinin Adı ve SOYADI**  
**İmzası**

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>TEŞEKKÜR</b> .....	<b>iii</b>
<b>BEYAN FORMU</b> .....	<b>iv</b>
<b>İÇİNDEKİLER</b> .....	<b>v</b>
<b>TABLolar DİZİNİ</b> .....	<b>viii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>ix</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ</b> .....	<b>x</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. GENEL BİLGİLER</b> .....	<b>3</b>
2.1 Kullanılan Algoritmalar ve Uygulama Süreçleri .....	3
2.1.1 İşbirlikçi Filtreleme – Öğe Tabanlı (Item-Based Collaborative Filtering) .....	3
2.1.1.1. Kullanım Senaryoları .....	4
2.1.2 Rastgele Öneri (Random-Based Recommendation) .....	4
2.1.2.1. Kullanım Senaryoları .....	5
2.1.3. Popülerlik Tabanlı Öneri (Popularity-Based Recommendation) .....	5
2.1.3.1. Kullanım Senaryoları .....	5
2.1.4. İçerik Tabanlı Filtreleme (Content-Based Filtering) .....	6
2.1.4.1. Kullanım Senaryoları .....	6
2.1.5. Derin Öğrenme Tabanlı Model – RNN (Recurrent Neural Network).....	7
2.1.5.1. Kullanım Senaryoları .....	7
2.1.6 Random Forest .....	8
2.1.6.1. Kullanım Senaryosu.....	8
2.1.7. Hibrit Öneri Modeli (Hybrid Recommendation System) .....	8
2.2. Kullanılan Veri Setleri Teknik Özellikleri (Used Datasets) .....	9

2.2.1 Ürün Bilgileri Veri Seti Özellikleri (Product Information Dataset) .....	9
2.2.2 Kullanıcı-Satın Alma Geçmişi Veri Seti Özellikleri (User-Purchase History Dataset).....	10
2.2.3 Kullanıcı Etkileşimleri Veri Seti Özellikleri (User Interactions Dataset) .....	11
2.3 Performans Değerlendirme Metrikleri (Performance Evaluation Metrics) .....	12
2.3.1 MAP – Ortalama Doğruluk Puanı (Mean Average Precision).....	12
2.3.2 CC – Katalog Kapsamı (Catalog Coverage) .....	13
2.3.3 MNS – Ortalama Yenilik Puanı (Mean Novelty Score) .....	14
2.3.4 MDS – Ortalama Çeşitlilik Puanı (Mean Diversity Score).....	14
2.3.5 MPS – Ortalama Kişiselleştirme Puanı (Mean Personalization Score).....	15
2.3. İlgili Literatür .....	16
<b>3. GEREÇ VE YÖNTEM.....</b>	<b>19</b>
3.1. Araştırmanın Tipi .....	19
3.2. Araştırmanın Modeli.....	19
3.2.1. Veri Seti Hazırlama .....	20
3.2.2. Algoritma Eğitimi.....	21
3.2.3. Performans Değerlendirme .....	22
3.3. Araştırmanın Yeri ve Zamanı.....	22
3.4. Araştırmanın Evren ve Örneklemi.....	23
3.4.1. Ürün Bilgileri Veri Seti.....	23
3.4.2. Kullanıcı Etkileşimleri Veri Seti .....	25
3.4.3. Kullanıcı Satın Alma Geçmişi Veri Seti.....	27
3.5. Veri Toplama Araçları .....	29
3.6. Verilerin Analizi.....	29
3.7. Yöntemin Uygulanması .....	30
<b>4. BULGULAR.....</b>	<b>34</b>
4.1. Genel Performans Tablosu.....	34

4.2. Doğruluk Performansı (MAP).....	34
4.3. Katalog Kapsamı (Catalog Coverage- CC).....	35
4.4. Yenilikçilik (Mean Novelty Score- MNS).....	36
4.5. Çeşitlilik (Mean Diversity Score- MDS).....	37
4.6. Kişiselleştirme (Mean Personalization Score- MPS) .....	38
<b>5.TARTIŞMA .....</b>	<b>40</b>
<b>6. SONUÇ VE ÖNERİLER.....</b>	<b>45</b>
6.1. Random-Based Model Üzerinden Değerlendirme .....	45
6.2. Popularity-Based Model Üzerinden Değerlendirme .....	46
6.3. Content-Based Filtering (İçerik Tabanlı Filtreleme) .....	46
6.4. Item-Based Collaborative Filtering (IBCF) .....	46
6.5. Hybrid Model (Hibrit Yaklaşım).....	47
6.6. RNN (Recurrent Neural Networks- Tekrarlayan Sinir Ağları).....	47
6.7. Random Forest Algoritması .....	47
6.8. Akademik ve Bilimsel Katkılar .....	48
<b>KAYNAKLAR .....</b>	<b>49</b>
<b>EKLER .....</b>	<b>51</b>
Ek 1. Etik Kurul Onayı.....	51
Ek 2. Özgeçmiş .....	52

## TABLULAR DİZİNİ

Tablo 1 : Ürün bilgileri veri seti.....	10
Tablo 2: Kullanıcı-satın alma geçmişi veri seti .....	10
Tablo 3: Kullanıcı etkileşimleri veri seti .....	11
Tablo 4: Ürün bilgilerine ait örnek veri seti .....	24
Tablo 5: Kullanıcı etkileşimlerine ait örnek veri seti .....	26
Tablo 6: Kullanıcı satın alma geçmişine ait örnek veri seti .....	28
Tablo 7: Ürün bilgileri ham veri seti.....	32
Tablo 8: Ürün bilgileri temizlenen veri seti.....	32
Tablo 9: Algoritma performans sonuçları tablosu .....	34



## ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1: İşbirlikçi filtreleme yönteminin temel çalışma mantığı.....	4
Şekil 2: İçerik tabanlı filtreleme yönteminin temel çalışma mantığı .....	6
Şekil 3 : En çok satın alınan ürünlerin toplam adet bazında dağılımı .....	11
Şekil 4 : Kullanıcı etkileşimleri görüntüleme, sepete ekleme ve satın alma oranları .....	12
Şekil 5: Model eğitimi ve performans değerlendirme için .....	20
Şekil 6: Öneri algoritmalarına göre Ortalama Doğruluk (MAP) değerleri .....	35
Şekil 7: Öneri algoritmalarına göre Katalog Kapsamı (CC) değerleri .....	36
Şekil 8: Öneri algoritmalarına göre Yenilikçilik (MNS) değerleri .....	37
Şekil 9: Öneri algoritmalarına göre Çeşitlilik (MDS) değerleri .....	38
Şekil 10: Öneri algoritmalarına göre Kişiselleştirme (MPS) değerleri .....	39

## SİMGELER VE KISALTMALAR DİZİNİ

<b>CBF</b>	: Content-Based Filtering (İçerik Tabanlı Filtreleme)
<b>CF</b>	: Collaborative Filtering (İşbirlikçi Filtreleme)
<b>IBCF</b>	: Item-Based Collaborative Filtering (Ürün Tabanlı İşbirlikçi Filtreleme)
<b>UBCF</b>	: User-Based Collaborative Filtering (Kullanıcı Tabanlı İşbirlikçi Filtreleme)
<b>RNN</b>	: Recurrent Neural Network (Yinelemeli Sinir Ağı)
<b>RF</b>	: Random Forest (Rastgele Orman)
<b>MAP</b>	: Mean Average Precision (Ortalama Doğruluk Skoru)
<b>MPS</b>	: Mean Personalization Score (Ortalama Kişiselleştirme Skoru)
<b>MDS</b>	: Mean Diversity Score (Ortalama Çeşitlilik Skoru)
<b>MNS</b>	: Mean Novelty Score (Ortalama Yenilik Skoru)
<b>CC</b>	: Catalog Coverage (Katalog Kapsamı)
<b>API</b>	: Application Programming Interface (Uygulama Programlama Arayüzü)
<b>SQL</b>	: Structured Query Language (Yapılandırılmış Sorgu Dili)
<b>ML</b>	: Machine Learning (Makine Öğrenmesi)
<b>DL</b>	: Deep Learning (Derin Öğrenme)
<b>AI</b>	: Artificial Intelligence (Yapay Zeka)
<b>RFM</b>	: Recency, Frequency, Monetary (Son Alışveriş, Sıklık, Harcama)

# 1. GİRİŞ

E-ticaret sektörü, dijital dönüşümle birlikte hızla büyümekte ve tüketicilerin çevrimiçi alışveriş deneyimini geliştirmek için çeşitli yenilikçi çözümler sunmaktadır. Artan rekabet ortamında, kullanıcıların ilgisini çekmek ve alışveriş deneyimini kişiselleştirmek, platformların sürdürülebilirliği açısından büyük önem taşımaktadır. Bu bağlamda, ürün öneri sistemleri, kullanıcıların ilgi alanlarına ve geçmiş etkileşimlerine dayalı olarak en uygun ürünleri sunarak müşteri memnuniyetini artırmada kritik bir rol oynamaktadır (He, Liu, & Jung, 2023). Kullanıcılara doğru ve kişiselleştirilmiş öneriler sunan sistemler, yalnızca müşteri deneyimini iyileştirmekle kalmaz, aynı zamanda satış oranlarını artırma, müşteri sadakatini sağlama ve kullanıcıların platformda daha fazla zaman geçirmesini teşvik etme açısından da önemli avantajlar sunar.

Ürün öneri sistemleri, makine öğrenmesi ve derin öğrenme tekniklerinden faydalanarak farklı algoritmalarla geliştirilmektedir. Geleneksel öneri sistemleri, genellikle popülerlik tabanlı ve içerik tabanlı yaklaşımlar üzerine inşa edilmiştir. Popülerlik tabanlı sistemler, en çok satan veya en çok görüntülenen ürünleri önerirken; içerik tabanlı sistemler, ürünlerin özelliklerini ve kullanıcı tercihlerine olan benzerliğini dikkate alarak öneriler üretir. Ancak, bu yaklaşımlar bazı sınırlamalara sahiptir. Popülerlik tabanlı sistemler, kullanıcılara özgü kişiselleştirme sunamazken; içerik tabanlı yöntemler, kullanıcıların yeni ürünler keşfetmesini engelleyebilir ve sadece belirli ürün gruplarına yoğunlaşma riski taşır.

Çalışmada, e-ticaret platformlarında kullanılan farklı öneri algoritmalarının performanslarını değerlendirmek amacıyla Random-based, Popularity-based, Content-based, Item-based Collaborative Filtering (IBCF), Hybrid Model, Recurrent Neural Networks (RNN) ve Random Forest yöntemleri kullanılmıştır. Çalışmamızda, öneri sistemlerinin başarısını ölçmek için performans metrikleri analiz edilmiştir.

Öneri sistemlerinin etkinliğini değerlendirmek için yalnızca doğru ürünlerin sunulması yeterli değildir; aynı zamanda bu sistemlerin kapsayıcılığı, kullanıcıya sunduğu çeşitlilik ve yenilikçilik seviyesi gibi çeşitli performans kriterleri de dikkate alınmalıdır. Bu çalışmada kullanılan algoritmaların başarımı; Ortalama Doğruluk (MAP), Kapsama Oranı (Coverage- CC), Ortalama Önerilen Ürün Sayısı (MNS), Ortalama

Derinlik Skoru (MDS) ve Ortalama Kişiselleştirme Skoru (MPS) gibi çok boyutlu metriklerle ölçülmüştür (Le, 2019). Bu metrikler sayesinde, sadece önerilerin ne kadar isabetli olduğu değil, aynı zamanda kullanıcılara ne kadar farklı ve kişiselleştirilmiş içerikler sunulduğu da analiz edilmiştir. Böylece, öneri sistemlerinin kullanıcı deneyimine olan katkısı daha bütüncül bir şekilde değerlendirilebilmiştir.

Diğer çalışmalardan farklı olarak, çok farklı algoritmaları karşılaştırarak her birinin avantajlarını ve dezavantajlarını daha geniş bir perspektiften incelemeyi amaçlanmıştır. Bildiğimiz kadarıyla çalışmamız, söz konusu metriklerin tamamı dikkate alınarak gerçek bir e-ticaret şirketi veri seti üzerinde yapılan özgün bir çalışmadır. Gerçekleştirilen karşılaştırmalı analizler, her bir algoritmanın güçlü ve zayıf yönlerini ortaya koyarak, e-ticaret platformları için en uygun öneri yöntemlerini belirleme konusunda yol gösterici olacaktır. Elde edilen bulgular, öneri sistemlerinin daha verimli hale getirilmesi ve gelecekteki geliştirme çalışmaları için değerli bir kaynak sunacaktır. Bu kapsamda, öneri sistemlerinin geliştirilmesine yönelik aşağıdaki üç temel araştırma sorusu ele alınmıştır:

- AS1: Veri setleri üzerinde uygulanan farklı öneri algoritmalarının kişiselleştirme, doğruluk, yenilik ve çeşitlilik açısından performansı nasıl farklılık göstermektedir?
- AS2: Çalışmada incelenen öneri algoritmalarının güçlü ve zayıf yönleri nelerdir?
- AS3: Derin öğrenme tabanlı öneri algoritmaları diğer algoritmalar ile karşılaştırıldığında hangi metriklerde üstünlük sağlamaktadır ve bu farklar nasıl açıklanabilir?

## 2. GENEL BİLGİLER

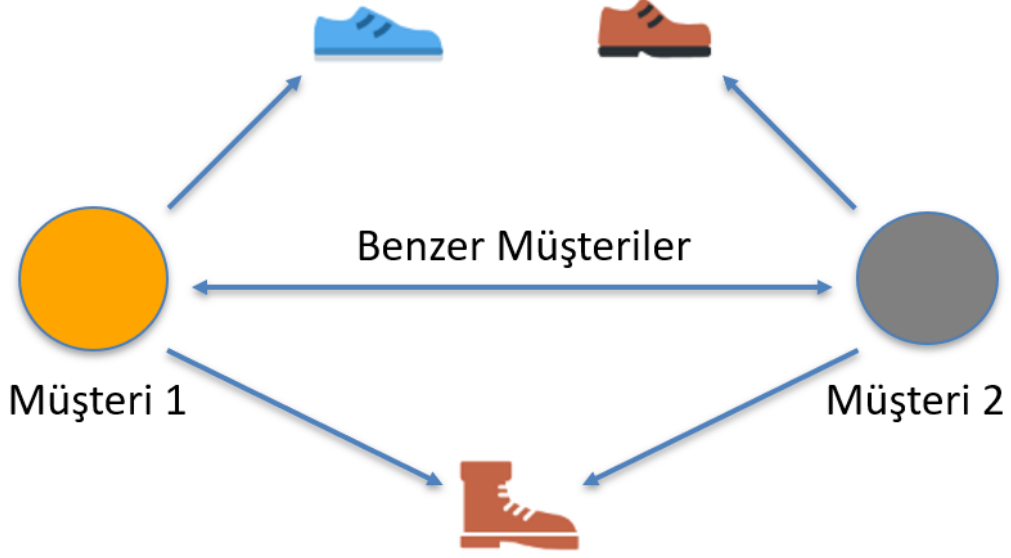
### 2.1 Kullanılan Algoritmalar ve Uygulama Süreçleri

Bu çalışmada, e-ticaret platformlarında ürün önerilerinin doğruluğunu, çeşitliliğini, yenilikçiliğini ve kişiselleştirme düzeyini artırmak amacıyla yedi farklı öneri algoritması karşılaştırmalı olarak uygulanmıştır. Bu algoritmalar, her biri farklı veri türleriyle ve kullanıcı davranışlarıyla çalışmaktadır. Aşağıda bu algoritmaların her biri, detaylı teorik açıklamaları ve uygulama süreçleri ile sunulmaktadır.

#### 2.1.1 İşbirlikçi Filtreleme – Öğe Tabanlı (Item-Based Collaborative Filtering)

Öğe tabanlı işbirlikçi filtreleme (Ricci et al., 2011; Breese ve ark., 1998), öneri sistemlerinde kullanıcıların önceki davranışları doğrultusunda benzer ürünleri keşfetmeyi hedefleyen, kullanıcıdan ziyade ürün merkezli bir yaklaşımdır. Bu modelin temel felsefesi, "benzer ürünler genellikle benzer kullanıcılar tarafından tercih edilir" varsayımına dayanır. Yani, bir kullanıcının geçmişte satın aldığı veya etkileşimde bulunduğu ürünler incelenerek, bu ürünlere benzer diğer ürünler sistem tarafından tespit edilir ve öneri olarak sunulur. Bu durum Şekil 1’de şematik olarak gösterilmiştir.

IBCF, 1990’lı yılların sonunda Amazon gibi büyük çevrimiçi perakendecilerin öneri sistemlerinde kullanılmaya başlanmış ve kullanıcı ölçeğinde yaşanan hesaplama zorluklarını aşmak amacıyla geliştirilmiştir. Kullanıcı sayısı sistemde arttıkça kullanıcı tabanlı işbirlikçi filtrelemenin karmaşıklığı ve hesaplama süresi yükselmekteydi. Öğe tabanlı yaklaşım, bu problemi ürün düzeyinde benzerlikler kurarak çözmeyi başarmıştır. Teorik olarak, öğe tabanlı filtreleme, kullanıcı-ürün etkileşim matrisindeki ürün sütunları arasında benzerlik hesaplayarak çalışır. Ürünlerin benzerliği, genellikle Cosine Similarity (Salton & McGill, 1983) gibi metriklerle hesaplanır. Bu hesaplama sonucunda her ürün için "en benzer ürünler listesi" oluşturulur ve bir kullanıcının geçmişte etkileşimde bulunduğu ürünlere benzer olanlar önerilir.



Bir müşteri tarafından satın alındı, diğer müşteriye önerildi.

Şekil 1: İşbirlikçi filtreleme yönteminin temel çalışma mantığı

#### 2.1.1.1. Kullanım Senaryoları

- Büyük ölçekli e-ticaret sitelerinde kullanıcı davranışlarının yeterince yoğun olduğu durumlarda güvenilir öneriler sunulabilir.
- İçerik bilgisi sınırlı olan, ancak kullanıcı etkileşim verisi zengin olan sistemlerde tercih edilir.
- Gerçek zamanlı öneri üretimi gereken, fakat her kullanıcı için ayrı profil çıkarmanın zor olduğu yapılarda oldukça faydalıdır.
- "Bu ürünü alanlar şunları da aldı" gibi uygulamalarda oldukça etkilidir.

#### 2.1.2 Rastgele Öneri (Random-Based Recommendation)

Rastgele öneri algoritması (Ricci et al., 2011), herhangi bir makine öğrenmesi, istatistiksel analiz ya da kullanıcı geçmişi dikkate alınmaksızın sistemdeki tüm ürünler arasından eşit olasılık ile ürün seçerek öneri yapma prensibine dayanır. Bu tür algoritmalar genellikle öneri sistemlerinde "kontrol grubu" oluşturmak amacıyla ya da diğer algoritmalarla kıyaslama yapılırken alt sınır belirlemek için kullanılır.

Bu yaklaşımın temel varsayımı, sistemin rastgelelik üzerinden dahi öneri sunabiliyor olmasının öneri motorlarının etkisini sınamak için önemli olduğudur.

Kullanıcıya önerilen içeriklerin tatmin edici olup olmadığı, rastgele sunulanlarla kıyaslanarak ölçülür. Ayrıca, çeşitliliğin doğal yollarla sağlanması ve belirli ürünlerin öne çıkması açısından da sistem davranışını test etmede işlevseldir.

### **2.1.2.1. Kullanım Senaryoları**

Bu algoritma, özellikle öneri sisteminin başarı düzeyini ölçmek amacıyla referans (benchmark) modeli olarak kullanılır. Ayrıca sistemin ilk aşamalarında, kullanıcı geçmişini bulunmayan dönemlerde, geçici olarak ürün çeşitliliği sunmak için tercih edilebilir. Örneğin, yeni bir e-ticaret sitesinin beta sürümünde öneri motorunun test edilmesi amacıyla kullanılabilir.

### **2.1.3. Popülerlik Tabanlı Öneri (Popularity-Based Recommendation)**

Popülerlik tabanlı öneri algoritması, tüm kullanıcıların kolektif tercihlerine dayanarak en çok ilgi gören ürünleri öne çıkarır. Bu yaklaşım, "en çok satın alınan ya da en çok görüntülenen ürün herkes için uygundur" varsayımı ile çalışır. Temelde bir sıralama algoritması gibi davranır; sistemdeki en popüler içerikler belirlenir ve bunlar öneri listelerinde gösterilir.

Bu modelde öneriler, kullanıcı kişisel geçmişine değil, ürünün genel kitlesel başarısına dayanır. Genellikle sistemin sıcak içeriklerini öne çıkarmada, yeni kullanıcılar için hızlı öneriler sunmada işlevseldir. Soğuk başlangıç problemini ürün tarafında büyük ölçüde ortadan kaldırır.

Bu algoritma, e-ticaret platformlarında sıklıkla kullanılan satış verilerine dayalı olarak çalışır. Ürünler; satış miktarına, alışveriş sepetine eklenme sıklığına veya sayfa görüntülenme oranına göre sıralanabilir. Bu sıralama sonucunda en popüler olanlar belirlenir ve öneri olarak gösterilir. Basit ama etkili bu yaklaşım, özellikle zaman baskısı altında çalışan sistemlerde ilk öneri seti için önemli katkı sağlar.

#### **2.1.3.1. Kullanım Senaryoları**

Popülerlik tabanlı algoritmalar, öneri sisteminin kullanıcıya özel bilgiye erişiminin kısıtlı olduğu durumlarda kullanılır. Özellikle kullanıcı girişi yapmadan gezen ziyaretçilere öneriler sunarken ya da kategori sayfalarında "en çok satanlar" listesini hazırlarken bu yöntem tercih edilir. Ayrıca hızlı çalışması sayesinde kampanya dönemlerinde en çok tercih edilen ürünleri öne çıkarmak için idealdir.

#### 2.1.4. İçerik Tabanlı Filtreleme (Content-Based Filtering)

İçerik tabanlı filtreleme (Ricci et al., 2011), öneri sistemlerinde kullanıcıların geçmişte beğendiği ya da etkileşim kurduğu ürünlerin içeriklerine dayanarak, benzer özelliklere sahip ürünleri bulmaya odaklanır. Bu yaklaşım, "kullanıcılar geçmişte neyi sevdiyse, gelecekte de ona benzer şeyleri sever" varsayımıyla hareket eder. Bu durum Şekil 2’de şematik olarak gösterilmiştir.

Bu modelde, ürünler çeşitli metinsel ya da sayısal özelliklerine göre vektörleştirilir. En yaygın kullanılan tekniklerden biri TF-IDF (Term Frequency-Inverse Document Frequency) (Salton & McGill, 1983) yöntemidir. Bu yöntem, her ürünün açıklamasını veya içerik bilgisini sayısal forma dönüştürerek karşılaştırılabilir hale getirir. Kullanıcının geçmişte beğendiği ürünlerin TF-IDF vektörlerinin ortalaması alınarak bir kullanıcı profili çıkarılır. Daha sonra tüm ürünlerle bu profil arasında cosine similarity ölçülerek benzerlik puanları hesaplanır. Bu benzerlik puanlarına göre kullanıcıya öneri yapılır.

İçerik tabanlı sistemler, her kullanıcı için ayrı bir profil oluşturduğu için yüksek seviyede kişiselleştirme imkânı sunar. Ayrıca, kullanıcıya önerilen ürünlerin neden önerildiği de açıklanabilir olduğundan, şeffaflık sağlar.



Şekil 2: İçerik tabanlı filtreleme yönteminin temel çalışma mantığı

##### 2.1.4.1. Kullanım Senaryoları

Bu algoritma, kullanıcı davranış geçmişi az olan ama ürün açıklamaları açısından zengin olan sistemlerde oldukça başarılıdır. Özellikle teknik ürün açıklamaları, film

türleri, kitap kategorileri gibi içerik açısından detaylı alanlarda öne çıkar. Ayrıca yeni eklenen ürünlerin önerilmesi açısından da etkilidir.

### 2.1.5. Derin Öğrenme Tabanlı Model – RNN (Recurrent Neural Network)

Recurrent Neural Network (RNN) (LeCun ve ark., 2016), zaman serisi veriler veya sıralı (sekansel) veriler üzerinde çalışan derin öğrenme modelleridir. Bu tür ağlar, önceki zamandaki çıktıları bir sonraki zaman adımına aktararak geçmiş bilgileri belleğinde tutabilir ve sıralı ilişkileri öğrenebilir.

Öneri sistemlerinde RNN'lerin kullanımı, özellikle bir kullanıcının geçmiş satın alma ya da tıklama davranışlarının sırasına göre bir sonraki etkileşimi tahmin etmeye yöneliktir. Örneğin, bir kullanıcı belirli ürünleri belirli bir sırayla görüntülediyse veya satın aldıysa, model bu örüntüyü öğrenip sonraki adımda neyle ilgileneceğini tahmin edebilir.

Klasik RNN'lerin uzun süreli bağımlılıkları öğrenme problemi yaşaması nedeniyle genellikle LSTM (Long Short-Term Memory) veya GRU (Gated Recurrent Unit) gibi gelişmiş RNN mimarileri kullanılır. Bu yapılar, geçmiş bilgi ile güncel bilgiyi dengeleyen kapı mekanizmaları sayesinde daha verimli öğrenme sağlar.

RNN tabanlı öneri sistemleri, klasik işbirlikçi filtreleme yöntemlerine göre zaman faktörünü daha iyi modelleyebilir ve sıralı kararları (örneğin oturum içi davranışlar) tahmin etmekte oldukça etkilidir.

#### 2.1.5.1. Kullanım Senaryoları

RNN tabanlı öneri sistemleri, aşağıdaki gibi sıralı davranışların kritik olduğu durumlarda yüksek performans gösterir:

- **Oturum içi öneriler:** Kullanıcının bir oturumda yaptığı işlemlerin sıralamasına göre öneri sunmak.
- **Zaman serisi verileri:** Belirli zaman aralıklarıyla yapılan satın alma gibi düzenli verilerde kullanmak.
- **Eğlence platformları:** Kullanıcının izlediği içeriklerin sırasına göre bir sonraki içeriği önerme (Netflix, Spotify).
- **Oyun içi öneriler:** Oyuncunun oyun sırasında izlediği yollar, kullandığı silahlar gibi sıralı davranışların takibi.

Zaman bağımlılığı yüksek, sıralı kararların ön planda olduğu sistemlerde klasik yöntemlere göre çok daha başarılı tahminler yapılmasına olanak sağlar.

### 2.1.6 Random Forest

Random Forest (Breiman, 2001) algoritması, birden fazla karar ağacının birlikte çalıştığı bir topluluk öğrenme (ensemble learning) yöntemidir. Her bir ağaç, eğitim verisinin farklı bir alt kümesi üzerinde eğitilir ve nihai tahmin, bu ağaçların oy birliği veya ortalaması ile belirlenir. Bu sayede model, aşırı öğrenmeye (overfitting) karşı daha dirençli hale gelir ve genellenebilirliği artar.

Öneri sistemlerinde Random Forest, kullanıcı ve ürün özellikleri üzerinden hangi ürünlerin birlikte tercih edildiğini modelleyerek gelecekteki eşleşmeleri tahmin etmek için kullanılabilir. Bu yaklaşım, özellikle birlikte satın alma ilişkilerini keşfetmede oldukça etkilidir. Model, belirli bir ürünün yanına hangi ürünün önerilmesi gerektiğini bir sınıflandırma problemi gibi ele alır. Random Forest, doğrusal olmayan ilişkileri yakalayabilme yeteneği ve yüksek doğruluk oranı nedeniyle, geleneksel regresyon veya işbirlikçi filtreleme yöntemlerine kıyasla daha güçlü sonuçlar verebilir.

#### 2.1.6.1. Kullanım Senaryosu

Random Forest tabanlı öneri sistemi, özellikle birlikte satın alma (co-purchase) ilişkilerinin öne çıktığı senaryolarda etkilidir. Örnek kullanım alanları şunlardır:

- **Sepet tamamlama:** Kullanıcının sepete attığı ürüne göre yanında alınabilecek tamamlayıcı ürünün önerilmesi (örneğin, telefon alan bir kullanıcıya kılıf önerilmesi).
- **Çapraz satış (cross-sell):** İlgili ama farklı kategorilerden ürünlerin önerilmesi.
- **Puanlama ya da sıralama:** Bir ürünün yanında en çok eşleşen ürünlerin sıralanarak kullanıcıya sunulması.

Random Forest'ın yüksek doğruluğu, özellikle etkileşim verisinin zengin olduğu sistemlerde, öneri kalitesini ciddi oranda artırır.

### 2.1.7. Hibrit Öneri Modeli (Hybrid Recommendation System)

Hibrit öneri sistemleri (Burke, 2002; Morales Murillo et al., 2022), birden fazla öneri algoritmasının güçlü yönlerini birleştirerek daha etkili, doğru ve dengeli öneriler sunmayı amaçlayan sistemlerdir. Bu yaklaşımlar, genellikle içerik tabanlı filtreleme

(Content-Based Filtering) ve işbirlikçi filtreleme (Collaborative Filtering) yöntemlerini bir araya getirerek hem kişiselleştirme hem de çeşitlilik sağlamaya çalışır.

Hibrit modellerin arkasındaki temel fikir, tek bir algoritmanın sınırlılıklarını diğerinin avantajlarıyla kapatmak ve daha kararlı bir öneri çıktısı üretmektir. Örneğin içerik tabanlı sistemler soğuk başlangıç problemini çözerken, işbirlikçi sistemler yüksek kişiselleştirme sağlar. Bu iki yöntemin birleşimi sayesinde hem yeni ürünler hem de kullanıcı alışkanlıkları dikkate alınarak öneriler sunulabilir.

### 2.1.7.1. Kullanım Senaryosu

Hibrit öneri sistemleri aşağıdaki gibi çok boyutlu ihtiyaçların olduğu durumlarda tercih edilir:

- **Yeni ürünlerin önerilmesi gerekirken kişiselleştirme de bekleniyorsa:** İçerik temelli model, etkileşimi olmayan ürünleri sisteme dahil edebilirken, işbirlikçi modelle kişiselleştirme yapılabilir.
- **Soğuk başlangıç problemi çift yönlü yaşıyorsa:** Yeni kullanıcı ve yeni ürünlerin olduğu sistemlerde hibrit yaklaşım denge sağlar.
- **Doğruluk, çeşitlilik ve yenilikçiliğin birlikte optimize edilmesi isteniyorsa:** Her bir metrik farklı algoritmalarla daha iyi optimize edilebildiğinden, hibrit modeller ideal çözümler sunar.
- **Gerçek zamanlı ve yüksek hacimli platformlar:** Farklı öneri kaynaklarının birleşimiyle daha doğru ve dengeli öneri sonuçları elde edilir.

Örnek uygulama alanları arasında Netflix, Amazon, YouTube gibi çok kategorili ve çok kullanıcıya sahip sistemler yer almaktadır.

## 2.2. Kullanılan Veri Setleri Teknik Özellikleri (Used Datasets)

E-ticaret platformundan elde edilen üç farklı veri seti, öneri sistemlerinin geliştirilmesi ve performanslarının karşılaştırılması amacıyla kullanılmıştır.

### 2.2.1 Ürün Bilgileri Veri Seti Özellikleri (Product Information Dataset)

Ürün bilgileri veri seti, platformda bulunan ürünlerin kimlik bilgilerini ve teknik özelliklerini içermektedir. Algoritmalar için temel veri kaynağı olarak kullanılmıştır. Tablo 1'de veri setinin içeriği ve açıklamaları bulunmaktadır.

**Tablo 1: Ürün bilgileri veri seti**

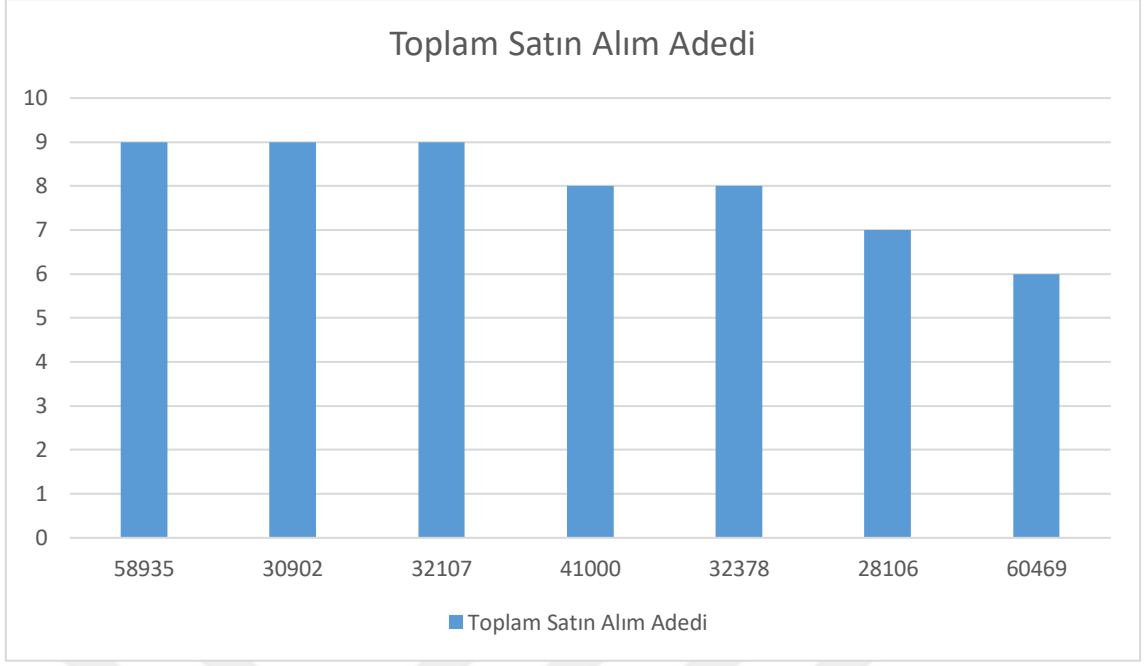
Alan Adı	Açıklama
urun_id	Her ürün için benzersiz bir kimlik numarası
adi	Ürünün Adı
marka_id	Ürünün ait olduğu marka
kategori_id	Ürünün ait olduğu kategori
ozellikler	Ürünün teknik detaylarını içeren metin bilgisi
eklenme_tarihi	Ürünün sisteme eklenme tarihi

### 2.2.2 Kullanıcı-Satın Alma Geçmiş Veri Seti Özellikleri (User-Purchase History Dataset)

Geçmiş satın alma işlemlerine ait bilgilerden oluşan veri kümesi, işbirlikçi filtreleme ve makine öğrenmesi tabanlı yöntemlerin geliştirilmesinde temel alınmıştır. Tablo 2’de veri setinin içeriği ve açıklamaları bulunmaktadır.

**Tablo 2: Kullanıcı-satın alma geçmişi veri seti**

Alan Adı	Açıklama
user_id	Kullanıcının Kimliği
product_id	Satın Alınan ürün kimliği
quantiy	Kullanıcının satın aldığı ürün miktarı
timestamp	Satın alma işleminin gerçekleştiği zaman




Şekil 3 : En çok satın alınan ürünlerin toplam adet bazında dağılımı

### 2.2.3 Kullanıcı Etkileşimleri Veri Seti Özellikleri (User Interactions Dataset)

Kullanıcıların e-ticaret platformundaki etkileşimlerini içeren veri kümesi, RNN, işbirlikçi filtreleme ve içerik tabanlı filtreleme modellerinin geliştirilmesinde kullanılır. Tablo 3'te veri setinin içeriği ve açıklamaları bulunmaktadır.

Tablo 3: Kullanıcı etkileşimleri veri seti

Alan Adı	Açıklama
<b>uye_id</b>	Kullanıcı kimliği
<b>urun_id</b>	Etkileşim yapılan ürünün kimliği
<b>eklenme_tarihi</b>	Kullanıcının ürüne etkileşimde bulunduğu tarih
<b>puan</b>	Kullanıcının ürünle ilgili verdiği puan (1-5 arasında bir değer)
<b>event_type</b>	Kullanıcının ürüne yaptığı etkileşim türü (view, ...)



Şekil 4 : Kullanıcı etkileşimleri görüntüleme, sepete ekleme ve satın alma oranları

### 2.3 Performans Değerlendirme Metrikleri (Performance Evaluation Metrics)

Algoritmaların başarılarını değerlendirmek için metrikler kullanılmıştır. Bu metrikler, her algoritmanın doğruluk, çeşitlilik, yenilik ve kişiselleştirme performanslarını analiz etmek için kullanılmıştır.

#### 2.3.1 MAP – Ortalama Doğruluk Puanı (Mean Average Precision)

Mean Average Precision (MAP), öneri sisteminin kullanıcılara ne kadar isabetli ve sıralaması etkili öneriler sunduğunu ölçmek için kullanılan en yaygın metriklerden biridir. Bu metrik, her kullanıcıya özel olarak oluşturulan öneri listesindeki doğru (ilgili) ürünlerin pozisyonuna ve sıralamasına göre doğruluk (precision) değerlerini hesaba katar. Her bir kullanıcının ortalama doğruluğu (Average Precision – AP) hesaplanır ve ardından tüm kullanıcılar için ortalaması alınarak MAP değeri elde edilir.

MAP, özellikle kişiselleştirilmiş öneri sistemlerinin değerlendirilmesinde kritiktir çünkü sadece ilgili ürünlerin listede olup olmamasını değil, bu ürünlerin listenin hangi sıralarında bulunduğunu da dikkate alır. Üst sıralarda yer alan ilgili ürünler daha yüksek katkı sağlar. Bu yönüyle, kullanıcıya zaman kazandıran ve tatmin edici öneri listeleri sunan sistemleri ön plana çıkarır.

- **|U|**: Kullanıcı sayısı
- **AP(u)**: Kullanıcı u için ortalama doğruluk
- **N**: Kullanıcıya önerilen maksimum ürün sayısı (örneğin top-10)
- **P(k)**: İlk k pozisyona kadar olan doğruluk (Precision@k)
- **rel(k)**: k'inci sıradaki ürün gerçekten ilgiliyse 1, değilse 0

$$MAP = \frac{1}{|U|} \sum_{u=1}^{|U|} AP(u)$$

Yüksek MAP değeri, sistemin öneri listelerinde gerçekten kullanıcıya hitap eden ürünleri, doğru bir sırayla sunabildiğini gösterir. Düşük MAP değeri ise önerilerin genel olarak alakasız ya da sıralamasının başarısız olduğunu işaret eder

### 2.3.2 CC – Katalog Kapsamı (Catalog Coverage)

Katalog kapsamı (Catalog Coverage – CC), öneri sisteminin ne kadar geniş bir ürün yelpazesi sunduğunu değerlendiren bir metriktir. Sistem, yalnızca sık tercih edilen birkaç ürünü tekrar tekrar öneriyorsa bu değer düşük olur. Buna karşılık, öneri sistemi geniş ürün portföyünü kapsayarak farklı ürünlerin de önerilmesini sağlıyorsa katalog kapsamı yüksek olur.

Bu metrik, özellikle çeşitliliğin, yenilikçiliğin ve ticari fırsatların artırılmasının hedeflendiği senaryolarda önemlidir. Sadece popüler ürünleri değil, sistemdeki niş ürünleri de önerilere dahil etmek, satış hacmini artırmanın yanı sıra kullanıcıların ilgisini çekecek yeni keşifler yapmasını da sağlar.

- **C**: Katalog kapsamı metriği
- **U**: Tüm kullanıcılar kümesi
- **R(u)**: Kullanıcı u'ya önerilen ürün kümesi
- **I**: Sistemdeki tüm ürünlerin kümesi
- **U R(u)**: Tüm kullanıcılara önerilen ürünlerin birleşimi

$$CC = \frac{|U_{u \in U} R(u)|}{|I|}$$

Yüksek CC değeri, sistemin öneri kapasitesinin geniş olduğunu ve ürünlerin büyük kısmını öneri sürecine entegre ettiğini gösterir. Düşük CC değeri ise sistemin dar bir ürün grubuna odaklandığını ve potansiyel satış fırsatlarını kaçırdığını gösterir.

### 2.3.3 MNS – Ortalama Yenilik Puanı (Mean Novelty Score)

Ortalama Yenilik Puanı (Mean Novelty Score – MNS), öneri sisteminin kullanıcıya ne kadar bilinmeyen, yeni veya daha önce karşılaşmadığı ürünleri sunduğunu ölçer. Özellikle “keşif” (discovery) motivasyonunun yüksek olduğu kullanıcı deneyimlerinde bu metrik büyük önem taşır.

Yenilik, öneri sisteminin kullanıcıyı sıradan ve tahmin edilebilir önerilerin ötesine geçerek sürpriz yapabilmesini sağlar. MNS hesaplanırken genellikle ürünün genel popülerlik skoru ya da kullanıcı geçmişindeki görülme sıklığı göz önüne alınır. Az bilinen ürünler daha yüksek yenilik puanı alır.

- **U:** Kullanıcı kümesi
- **R(u):** Kullanıcı u'ya önerilen ürün kümesi
- **pop(i):** Ürün i'nin popülerlik skoru (örneğin kaç kullanıcıya önerildiği ya da satın alındığı)

$$MNS = \frac{1}{|U|} \sum_{u \in U} \left( \frac{1}{|R(u)|} \sum_{i \in R(u)} \frac{1}{pop(i) + 1} \right)$$

Yüksek MNS değeri, sistemin kullanıcıya farklı ve az bilinen ürünler önerdiğini, dolayısıyla keşif duygusunu tetiklediğini gösterir. Düşük MNS değeri ise sistemin çoğunlukla zaten kullanıcıların aşına olduğu ürünleri önerdiğini ve yenilikçilikten uzaklaştığını gösterir.

### 2.3.4 MDS – Ortalama Çeşitlilik Puanı (Mean Diversity Score)

Ortalama Çeşitlilik Puanı (Mean Diversity Score – MDS), önerilen ürünlerin birbirinden ne kadar farklı olduğunu ölçer. Bir öneri listesinde yalnızca aynı türde, benzer kategori veya marka ürünlerin yer alması, çeşitlilik açısından zayıf bir tablo ortaya koyar. MDS ise bu tür tekrarları azaltmayı ve kullanıcıya daha geniş perspektifli seçenekler sunmayı hedefler.

Bu metrik, önerilen ürün çiftleri arasındaki mesafeyi (örneğin vektör uzayında benzerlik farkı, kategori farkı) hesaplayarak çalışır. Daha çeşitli ve homojen olmayan öneri listeleri yüksek MDS değerine ulaşır.

- **U**: Kullanıcı kümesi
- **R(u)**: Kullanıcı u'ya önerilen ürün kümesi
- **i, j ∈ R(u)**: Öneri listesindeki ürün çiftleri
- **d(i, j)**: Ürün i ile j arasındaki çeşitlilik mesafesi (örneğin: kosinüs uzaklığı, kategori farkı, öznitelik uzaklığı)

$$MDS = \frac{1}{|U|} \sum_{u \in U} \left( \frac{2}{|R(u)|(|R(u)| - 1)} \sum_{i, j \in R(u), i \neq j} d(i, j) \right)$$

Yüksek MDS değeri, sistemin kullanıcılara yalnızca benzer ürünler değil, farklı kategorilerden alternatifler sunduğunu gösterir. Bu, kullanıcı memnuniyetini artırmakla kalmaz, aynı zamanda çapraz satış fırsatlarını da genişletir. Düşük MDS değeri ise sistemin monoton öneriler sunduğunu ve farklılaşma sağlayamadığını gösterir.

### 2.3.5 MPS – Ortalama Kişiselleştirme Puanı (Mean Personalization Score)

Ortalama Kişiselleştirme Puanı (Mean Personalization Score – MPS), öneri sisteminin her kullanıcıya özel ne kadar farklı öneriler sunduğunu ölçer. Bu metrik, kullanıcılar arasında öneri listelerinin ne kadar örtüştüğünü analiz eder. Eğer tüm kullanıcılara benzer öneri listeleri sunuluyorsa kişiselleştirme düşük demektir. Oysa her kullanıcıya özgü ürün önerileri yapılması MPS skorunu yükseltir.

Kişiselleştirme, modern öneri sistemlerinin temel yapı taşlarından biridir. Kullanıcıların bireysel ilgi alanlarını, geçmiş davranışlarını ve tercihlerine uygun öneriler sunmak, memnuniyetin ve sadakatin artmasında kritik rol oynar. MPS genellikle öneri listeleri arasındaki jaccard farklılığı ya da ortalama benzerlik skorlarının tersine çevrilmesi gibi tekniklerle ölçülür.

- **sim (R<sub>u</sub>, R<sub>v</sub>)**: Bu iki kullanıcının öneri listeleri arasındaki benzerlik (örneğin Jaccard)
- **|U|**: Toplam kullanıcı sayısı
- **R<sub>u</sub>, R<sub>v</sub>**: Kullanıcı u ve kullanıcı v'ye ait öneri listeleri

$$MPS = 1 - \frac{1}{|U|(|U| - 1)} \sum_{u=1}^{|U|} \sum_{v=u+1}^{|U|} \text{sim}(R_u, R_v)$$

Yüksek MPS değeri, sistemin her kullanıcıya farklı ve özelleştirilmiş bir öneri listesi sunduğunu gösterir. Düşük MPS değeri, kullanıcılar arasında öneri çeşitliliğinin azaldığını, sistemin kişisel farklılıkları göz ardı ettiğini ortaya koyar.

### 2.3. İlgili Literatür

E-ticaret alanında öneri sistemlerine yönelik yapılan çalışmalar yıllar içinde büyük çeşitlilik göstermiştir. İlk dönemlerde öne çıkan işbirlikçi filtreleme yöntemleri, kullanıcıların geçmiş davranışlarına dayalı olarak önerilerde bulunmayı hedeflemiştir. Artukarslan ve Alptekin (2019), bu yaklaşımı temel alan çalışmalarında kullanıcı-öge etkileşim matrislerinden hareketle öneri doğruluğunu artırmayı amaçlamış, matris çarpanlarına ayırma tekniklerinden faydalanmışlardır. Benzer şekilde, Anbazhagan ve Arock (2016) tarafından yapılan araştırmalarda da bu tür algoritmaların güçlü ve zayıf yönleri değerlendirilmiştir. Ancak bu çalışmaların önemli bir kısmı, yalnızca doğruluk metriğine odaklanmakta ve sistemin çeşitlilik, kişiselleştirme ya da yenilikçilik gibi farklı boyutlarını göz ardı etmektedir. Zamanla kullanıcıların daha kişiselleştirilmiş deneyim beklentisi ve sistemlerin daha karmaşık kullanıcı davranışlarını anlamaya yönelik ihtiyacı, içerik tabanlı ve hibrit sistemlerin gelişmesine neden olmuştur. Saini ve Singh (2023) tarafından sunulan hibrit model çalışmasında, işbirlikçi ve içerik tabanlı yaklaşımların birleştirilmesi önerilmiş; bu sayede önerilerin daha isabetli hale gelebileceği belirtilmiştir. Ancak çalışmada kullanılan metrikler sınırlı kalmış, kullanıcı grubu çeşitliliği ya da öneri kapsamı gibi açılardan detaylı analiz yapılmamıştır. Özkılıç (2022) ise öneri sistemlerinin e-ticaret sitelerine uygulanabilirliğine odaklanmış ve önerilerin ticari etkilerini tartışmıştır. Bununla birlikte, algoritma performanslarının karşılaştırmalı analizi eksik bırakılmıştır. İçerik temelli yaklaşımlar üzerine yapılan çalışmalarda ise ürün açıklamaları ve kullanıcı tercihleri üzerinden öneri yapılması hedeflenmiştir. Padhy ve arkadaşları (2024) da içerik temelli ve işbirlikçi yöntemleri karşılaştırarak yöntemlerin avantajlarını sunmuş, ancak bu sistemlerin çoklu metriklerle bütüncül olarak analiz edilmediği görülmektedir. metin verilerinin öneri sistemlerinde kullanımı üzerine yapılan çalışmalarda da görüldüğü üzere (Srifi, Oussous, Lahcen, &

Mouline, 2020), kalitesini artırmak amacı önemli bir yaklaşımdır. Literatürdeki genel eğilim, öneri sistemlerinin daha kişiselleştirilmiş hale gelmesi ve kullanıcı davranışlarının bütüncül biçimde analiz edilmesi yönündedir (R. C. K., Srikantaiah, & V. K. R., 2018). Öneri sistemlerinde derin öğrenmenin kullanımı ise son yıllarda literatürde önemli bir yer edinmiştir. Betru ve arkadaşları (2017), sinir ağları, CNN ve RNN gibi mimarilerle öneri doğruluğunu artırmaya yönelik çeşitli modeller geliştirmiştir. Ancak bu gibi çalışmalarda genellikle sadece derin öğrenme algoritmalarının başarımı değerlendirilmiş; klasik yöntemlerle karşılaştırmalar sınırlı tutulmuştur. Buna karşılık olarak bu çalışmada hem makine öğrenmesi temelli algoritmalar hem de derin öğrenme yaklaşımları aynı veri seti üzerinde test edilerek çok yönlü bir performans analizi yapılmıştır. Öte yandan, segmentasyon tabanlı yaklaşımların öneri sistemlerine katkısı da araştırmalarda yer bulmuştur. Legito ve arkadaşları (2023), K-means algoritması ile kullanıcı gruplarını segmente ederek daha özelleştirilmiş öneriler geliştirmeyi hedeflemiştir. Ancak öneri algoritmalarının bireysel başarımı bu çalışmalarda arka planda kalmıştır. Bu çalışmada ise algoritmaların tekil olarak performansı çoklu metrikler aracılığıyla analiz edilmiştir. Son olarak, literatürde öneri algoritmalarının birbirleriyle doğrudan karşılaştırıldığı bazı çalışmalar da yer almaktadır. Phalle ve Bhushan (2024), içerik tabanlı ve işbirlikçi filtreleme yöntemlerini kullanıcı deneyimi açısından değerlendirmiş; öneri kalitesi üzerine yorumlar yapılmıştır. Ancak burada da sektörel bağlam, veri büyüklüğü ve algoritma esnekliği gibi unsurlar dışarıda bırakılmıştır. Buna ek olarak, Vozalis ve Margaritis (2003), farklı bellek-temelli ve model-temelli algoritmaları değerlendirerek; işbirlikçi filtreleme, içerik tabanlı filtreleme ve hibrit modellerin öneri doğruluğu, veri seyrekliği ve hesaplama karmaşıklığı açısından avantajlarını karşılaştırmalı biçimde analiz etmişlerdir. Ayrıca Hieu Le (2019) tarafından yürütülen çalışmada, Random-based, Popularity-based, Content-based, Itembased Collaborative Filtering (IBCF) ve Hybrid algoritmaları aynı veri seti üzerinde test edilerek performansları çok boyutlu metrikler ile değerlendirilmiştir. Her algoritmanın MAP, CC, MNS, MDS ve MPS gibi beş ayrı ölçüte göre incelendiği bizim çalışmamızda ise algoritmalar arası kapsamlı bir karşılaştırma sunarak özellikle IBCF modelinin doğruluk açısından öne çıktığını göstermiştir. Cremonesi ve arkadaşları (2010), öneri sistemlerinin gerçek kullanıcı deneyimini yansıtabilmesi için sadece hata oranı (RMSE) gibi klasik regresyon metriklerinin yeterli olmadığını, özellikle Top-N öneri performansının daha anlamlı metriklerle (örneğin doğruluk, precision) değerlendirilmesi gerektiğini belirtmiştir. Bu nedenle bizim çalışmamızda başarı oranı birçok metrik ile incelenmiştir. Genel olarak

değerlendirildiğinde, öneri sistemleri üzerine yapılan literatür çalışmalarının çoğu belirli yöntem ya da metrikler üzerine odaklanmakta; farklı algoritmaların gerçek veriler üzerinde çok boyutlu karşılaştırmaları ise oldukça sınırlı kalmaktadır. Bu bağlamda yürütülen bu çalışmada; içerik tabanlı, işbirlikçi, rastgele, popülerlik temelli, derin öğrenme ve hibrit yöntemler aynı e-ticaret veri seti üzerinde test edilmiş; performansları doğruluk (MAP), kapsam (CC), yenilikçilik (MNS), çeşitlilik (MDS) ve kişiselleştirme (MPS) gibi metriklerle sistematik olarak değerlendirilmiştir. Böylece hem literatürdeki tek boyutlu yaklaşımların ötesine geçilmiş hem de gerçek senaryoya dayalı uygulamalı bir öneri sistemi modeli ortaya konmuştur.



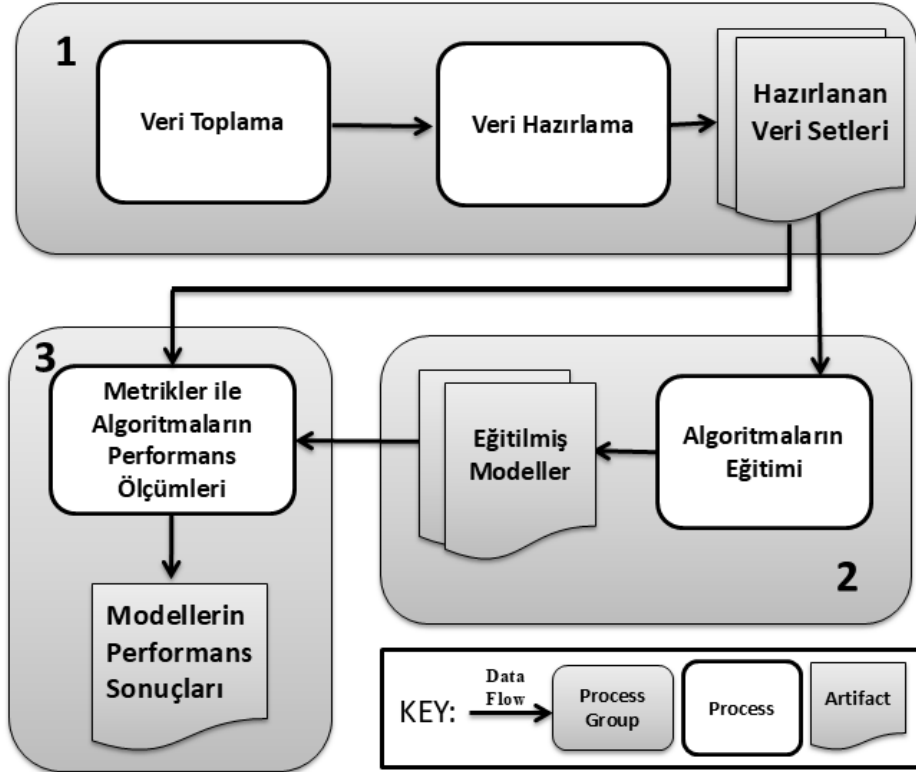
## 3. GEREÇ VE YÖNTEM

### 3.1. Araştırmanın Tipi

Bu araştırma, nicel yöntemlere dayalı olarak yürütülen uygulamalı bir çalışmadır. Çalışmada, farklı algoritmaların öneri sistemlerinde nasıl sonuçlar verdiği karşılaştırmalı olarak incelenmiştir. İçerik tabanlı filtreleme, işbirlikçi filtreleme, popülerlik ve rastgele öneri yöntemlerinin yanı sıra, derin öğrenme temelli RNN modeli, Random Forest ve bu yöntemlerin birleşimi olan hibrit öneri modeli araştırma kapsamında değerlendirilmiştir. Her algoritma belirli bir sistemle uygulanmış ve ortaya çıkan öneriler çeşitli ölçütlere göre analiz edilmiştir. Bu analizde öneri sistemlerinin başarısı sadece doğruluk açısından değil, aynı zamanda çeşitlilik, yenilikçilik, kişiselleştirme ve katalog kapsamı gibi farklı boyutlardan da değerlendirilmiştir. Kullanılan performans metrikleri arasında Ortalama Doğruluk Puanı (MAP), Katalog Kapsamı (CC), Ortalama Yenilik (MNS), Ortalama Çeşitlilik (MDS) ve Ortalama Kişiselleştirme (MPS) yer almaktadır. Bu metrikler aracılığıyla her algoritmanın güçlü ve zayıf yönleri ortaya konmuş ve e-ticaret uygulamaları için en uygun öneri yöntemlerinin belirlenmesi amaçlanmıştır.

### 3.2. Araştırmanın Modeli

Bu çalışmada kullanılan model, karşılaştırmalı analiz modeli olarak tanımlanabilir. Çalışmada amaç, farklı öneri algoritmalarının performansını belirli ölçütler doğrultusunda karşılaştırmak ve hangilerinin daha başarılı sonuçlar verdiğini ortaya koymaktır. Araştırma süreci boyunca her algoritma veri kümeleri üzerinde uygulanmış ve sonuçlar önceden belirlenmiş performans kriterlerine göre analiz edilmiştir. Bu kapsamda, algoritmaların doğruluk, çeşitlilik, kişiselleştirme, yenilik ve kapsam gibi yönlerden nasıl performans gösterdiği karşılaştırmalı olarak değerlendirilmiştir. Modelin merkezinde, farklı yöntemlerin aynı koşullarda test edilmesi ve bu sayede elde edilen sonuçların nesnel biçimde kıyaslanabilmesi yer almaktadır. Bu yönüyle araştırma modeli hem uygulamalı hem de betimleyici özellikler taşımakta, elde edilen bulgular öneri sistemlerinin etkinliğini ölçmeye yönelik somut çıktılar sağlamaktadır.



Şekil 5: Model eğitimi ve performans değerlendirme için

Önerilen yöntem üç ana adımdan ve bunlara bağlı alt adımlardan oluşan genel süreç Şekil 5’te gösterilmiştir. İlk adımda (1), sistemden veri toplanarak analiz için uygun hale getirilir ve "Veri Seti" elde edilir. İkinci adım (2), denetimli makine öğrenimi algoritmalarının eğitim sürecini içerir; bu aşamada veri seti kullanılarak algoritmalar eğitilir. Bazı algoritmalar doğrudan tahmin üretme yeteneğine sahip olduklarından herhangi bir eğitim süreci gerektirmez ve bu nedenle ikinci adımı atlayarak doğrudan üçüncü adıma geçer. Üçüncü adımda (3), hem eğitilmiş hem de eğitimsiz algoritmaların performansları, belirlenen metrikler aracılığıyla değerlendirilir ve karşılaştırmalı olarak analiz edilir.

### 3.2.1. Veri Seti Hazırlama

İlk aşama olan veri toplama ve hazırlama süreci, öneri sisteminin temellerini oluşturur. Bu adımda üç temel veri seti kullanılır: ürün bilgileri, kullanıcıların geçmiş satın alma kayıtları ve kullanıcıların platform üzerindeki etkileşimleri. Tablo 1’de yer alan ürün bilgileri veri seti; ürün ID’si, ürün adı, marka, kategori ve teknik açıklamalar (örneğin işlemci tipi, ekran kartı, depolama kapasitesi) gibi alanları içerir ve özellikle içerik tabanlı öneri algoritmalarının yapılandırılmasında temel veri kaynağı olarak görev

yapar. Tablo 2’de yer alan kullanıcı-satın alma geçmiş veri seti; kullanıcı ID’si, satın alınan ürün ID’si, satın alma miktarı ve zaman damgası gibi bilgileri barındırır ve işbirlikçi filtreleme ile makine öğrenmesi algoritmalarında kullanılır. Tablo 3’te üçüncü veri seti olan kullanıcı etkileşimleri ise kullanıcıların ürünlerle olan davranışlarını (örneğin görüntüleme, sepete ekleme, satın alma gibi) zamansal bağlamda sunar ve özellikle zaman dizisi modellemelerinde (örneğin RNN) etkin rol oynar. Bu veri setleri, model eğitimi öncesinde kapsamlı bir veri temizleme ve ön işleme sürecine tabi tutulur. Eksik ve tutarsız veriler ayıklanır, tekrar eden kayıtlar temizlenir, aykırı değerler tespit edilerek uygun yöntemlerle işlenir. Metin verilerinin sayısallaştırılmasında TF-IDF yöntemi kullanılarak ürün açıklamaları vektörlere dönüştürülür ve içerik tabanlı modeller için anlamlı giriş verileri oluşturulur. Ayrıca kullanıcı ve ürün kimlikleri üzerinde sayısal etiketleme (label encoding), indeksleme, normalizasyon ve kategori dönüşümleri gerçekleştirilerek algoritmalarla uyumlu veri yapıları elde edilir. Tüm bu ön işleme adımları sonucunda, veri setleri makine öğrenmesi modelleri için doğrudan kullanılabilir bir hale getirilir.

### **3.2.2. Algoritma Eğitimi**

Bu çalışmada öneri sisteminin ikinci aşaması, yalnızca model eğitimi gerektiren algoritmaların öğrenme süreçlerini kapsar. Her ne kadar bazı algoritmalar önceden tanımlı kurallar veya istatistiksel benzerlik ölçümleriyle çalışsa da (örneğin içerik tabanlı filtreleme, popülerlik tabanlı öneri ya da rastgele seçim modelleri), diğer algoritmalar (örneğin Random Forest veya RNN gibi) doğrudan makine öğrenmesi eğitim süreçlerine dayanır ve veri üzerinden öğrenme gerektirir. Hazırlanan veri setleri, makine öğrenmesi ve derin öğrenme tabanlı algoritmalar tarafından kullanılır. Bu kapsamda, Recurrent Neural Networks (RNN) algoritması, kullanıcıların zaman sıralı etkileşimlerini analiz ederek davranışsal kalıpları öğrenmeye çalışır. Etkileşim geçmişi; tıklama, görüntüleme, sepete ekleme gibi işlemlerden oluşur ve bu diziler üzerinden model eğitilir. Öte yandan, Random Forest algoritması ise kullanıcı-ürün ilişkilerini sınıflandırmaya yönelik olarak eğitilir ve geçmiş satın alma örüntüleri ile ürün özelliklerine dayalı karar ağaçları modeli oluşturulur. Bu aşamada yalnızca eğitim gerektiren algoritmalar ele alınır; eğitim süreci gerektirmeyen popülerlik tabanlı ve rastgele seçim gibi algoritmalar ise bu adıma dahil edilmeden, doğrudan üçüncü aşama olan performans değerlendirme sürecine aktarılır. Böylece her algoritmanın yapısal gereksinimlerine uygun bir iş akışı izlenir ve

değerlendirme süreci öncesinde sadece öğrenme tabanlı algoritmaların modelleme işlemleri gerçekleştirilir.

### **3.2.3. Performans Değerlendirme**

Son aşama olan performans değerlendirme sürecinde, makine öğrenmesi ile eğitilen öneri sistemlerinin etkinliği çeşitli metrikler aracılığıyla analiz edilir. Bu süreç sadece doğrulukla sınırlı kalmaz; aynı zamanda öneri kalitesi, kullanıcı deneyimine katkı ve sistemin erişim kapasitesi gibi farklı açılardan da değerlendirme yapılır. Bu kapsamda kullanılan beş temel metrik şunlardır: Ortalama Doğruluk (MAP), Kapsama Oranı (CC), Ortalama Önerilen Ürün Sayısı (MNS), Ortalama Derinlik Skoru (MDS) ve Kişiselleştirme Skoru (MPS). Bu aşamada, tüm metrikler birlikte ele alınarak algoritmaların güçlü ve zayıf yönleri belirlenir. Böylece hangi modelin öneri sistemine daha fazla katkı sunduğu, kullanıcı deneyimini ne ölçüde iyileştirdiği ve sistemin genel başarımlar düzeyi nesnel olarak ortaya konur. Elde edilen sonuçlar, öneri sisteminin optimize edilmesine, doğru algoritma seçiminin yapılmasına ve farklı kullanıcı gruplarına özel stratejiler geliştirilmesine olanak tanır.

### **3.3. Araştırmanın Yeri ve Zamanı**

Bu araştırma, 2024 yılının Eylül ayı ile 2025 yılının haziran ayı arasında dijital ortamda yürütülmüştür. Çalışma sürecinde kullanılan algoritmalar, Python programlama dili ve scikit-learn, pandas, TensorFlow gibi açık kaynaklı kütüphaneler kullanılarak yerel geliştirici bilgisayarlarında çalıştırılmış, öneri sistemleri üzerine yapılan test ve değerlendirme işlemleri ise Jupyter Notebook ve Google Colab gibi araçlar aracılığıyla gerçekleştirilmiştir.

Veri işlemleri ve öneri algoritmalarının çıktılarının değerlendirilmesi aşamasında, öneri sistemleri literatürüne uygun olarak geliştirilen performans metrikleri (MAP, MDS, MPS, CC, MNS) doğrultusunda analiz yapılmıştır.

Araştırma boyunca kullanılan veriler, ticari bir e-ticaret platformundan sağlanmış olup, veri setleri araştırmacının bilgisayarında saklanmış ve analizler lokal ortamda yapılmıştır. Çalışma boyunca herhangi bir fiziksel ortamda görüşme, uygulama ya da saha çalışması yapılmamış, tüm süreç çevrimiçi ve veri odaklı olarak yürütülmüştür.

### 3.4. Araştırmanın Evren ve Örneklemi

#### 3.4.1. Ürün Bilgileri Veri Seti

Bu araştırmada kullanılan ürün bilgileri veri seti, öneri sisteminin özellikle içerik tabanlı filtreleme algoritmalarını desteklemek ve hibrit model yaklaşımlarında ürün karakteristiklerinin hesaba katılmasını sağlamak amacıyla yapılandırılmıştır. Veri seti, e-ticaret platformunda sunulan ürünlerin hem temel kimlik bilgilerini hem de metinsel ve teknik özelliklerini barındırmaktadır. Öneri sistemlerinin gelişmiş biçimde çalışabilmesi için yalnızca kullanıcı-ürün ilişkisi değil, aynı zamanda ürünlerin kendi aralarındaki benzerlik düzeyleri de dikkate alınmalıdır. Bu noktada ürünlere ait açıklayıcı alanlar modelin bilgi zenginliğini artırmakta ve kullanıcı profiline uygun ürünlerin daha isabetli önerilmesini mümkün kılmaktadır.

Tablo 1 üzerinde sunulan bu veri seti; `urun_id`, `adi`, `marka_id`, `kategori_id` ve `ozellikler` gibi alanları içermektedir. `urun_id` alanı, her bir ürün için benzersiz bir kimlik numarası olarak tanımlanmış ve tüm işlemlerde ürünlerin doğru eşlenmesini sağlamıştır. `adi` alanı, ürünlerin kısa tanımını içermekle birlikte veri analizi sürecinde sınıflama ve görselleştirme amaçlı kullanılmıştır. `marka_id` ve `kategori_id` değişkenleri ise, özellikle marka temelli eğilimlerin ve kategori içi önerilerin belirlenmesi açısından modelin segmentasyon gücünü artıran yapılar arasında yer almaktadır. Tabloda yer alan en kritik alanlardan biri olan `ozellikler`, ürünlerin metinsel olarak tanımlandığı, teknik detayları ve açıklamalarının yer aldığı bölümdür. Bu alandaki veriler; ürünlerin ekran boyutu, işlemci tipi, bellek kapasitesi, bağlantı seçenekleri, fiziksel boyutları, garanti süresi ve fonksiyonel nitelikleri gibi birçok özneliği barındırmaktadır.

Araştırmada kullanılan bu veri setinde yaklaşık 20.000 satırlık ürün bilgileri yer almaktadır. Bu ürünler, gerçek bir e-ticaret platformundan alınan veriler üzerinden temsili biçimde seçilmiş olup, örneklem yapısı oluşturulurken çeşitlilik, içerik zenginliği ve sektör temsiliyeti dikkate alınmıştır. Ürünlerin büyük çoğunluğunu teknolojik cihazlar oluşturmaktadır. Bunlar arasında bilgisayar bileşenleri (örneğin: ekran kartı, işlemci, bellek), ev teknolojileri (örneğin: robot süpürgeler, kettle cihazları), kişisel bakım ürünleri (örneğin: saç kurutma makinesi), oyuncu ekipmanları (mousepad, kulaklık, klavye) gibi farklı segmentlerden elektronik ürünler yer almaktadır. Bu çeşitlilik, öneri sistemlerinin içerik tabanlı yapısının hem farklı kategorilerde hem de farklı teknik düzeylerdeki ürünler için test edilebilmesine olanak tanımıştır.

Bu veri seti, öneri algoritmaları açısından özellikle TF-IDF (Term Frequency – Inverse Document Frequency), cosine similarity ve vektörleştirme temelli metin madenciliği yaklaşımlarının uygulanabildiği zengin bir yapı sunmuştur. özellikler alanındaki metinler ve kullanıcıların geçmişte tercih ettiği ürünlerle en yüksek benzerlik oranına sahip ürünler hesaplanarak öneriler oluşturulmuştur. Ayrıca içerik tabanlı filtreleme yöntemi ile hibrit öneri sisteminde bu veriler, kullanıcıların geçmiş davranışlarıyla birlikte birleştirilerek daha kapsamlı ve kullanıcıya özel öneriler sunulmuştur.

Sonuç olarak, içerik derinliği ve kategori çeşitliliği açısından zengin olan bu veri kümesi, öneri sistemlerinin başarısını artırmada doğrudan etkili olmuştur.

**Tablo 4: Ürün bilgilerine ait örnek veri seti**

urun_id	adi	marka_id	kategori_id	ozellikler
15489	Lenovo Neo 30a i7-13620H 16GB 512GB SSD	208	826	Intel i7, 16GB RAM, 512GB SSD, 23.8", FreeDOS, HDMI, USB, BT5.2, Wi- Fi 6
14785	Konsol Oyun v2	707	1675	Core i5-14400F, 16GB, 512GB, RTX 4070, FreeDOS
25647	Konsol Oyun v1	707	1675	Core i3-14100F, 16GB, 512GB, RTX 4060
84596	Stratos Edge	621	1675	Core i5- 12600KF, 16GB, 512GB, ARC B580
74589	MSI GeForce RTX 4070	75	798	HDMI, DisplayPort, 12GB GDDR6X, 3x Fan
21496	Xiaomi Robot Vacuum S20	540	1651	400 ml, 20 mm, Sert Zemin, Navigasyon, 24 Ay Garanti
76915	Xiaomi Robot Vacuum X20 Pro	540	1651	0-250 L, 5 Saat, Sert Zemin, Navigasyon, 24 Ay
78515	Xiaomi Robot Vacuum X20 Max	540	1651	0-250 L, Navigasyon, 160 Dk, 24 Ay

21418	Xiaomi Electric Glass Kettle	540	1500	1.7 lt, 2200W, Cam, 24 Ay Garanti
32819	Xiaomi S400 Dijital Baskül	540	926	150 kg, Dijital, Bluetooth
76965	Xiaomi H101 Saç Kurutma Makinesi	540	1671	1600W, Pembe, 2 Kademeli, 24 Ay Garanti
76978	Xiaomi Buharlı Kırıksık Giderici	540	1470	1300W, 1600 mL

### 3.4.2. Kullanıcı Etkileşimleri Veri Seti

Bu çalışmada, kullanıcıların ürünlerle olan etkileşimlerini yalnızca sonuç odaklı değil, sürece yayılan çok katmanlı bir yapı içerisinde analiz edebilmek adına özel bir veri seti oluşturulmuştur. Sıklıkla yapılan hata, yalnızca satın alma verilerine odaklanarak kullanıcı davranışlarını değerlendirmeye çalışmaktır. Oysaki, bir ürünün satın alınması öncesinde gerçekleşen diğer etkileşimler —örneğin ürünün incelenmesi ya da sepete eklenmesi— en az nihai karar kadar önemli sinyaller taşımaktadır. Bu sebeple, çalışmada kullanılan veri seti, yalnızca satın alma işlemlerini değil; aynı zamanda görüntüleme (view) ve sepete ekleme (add\_to\_cart) gibi öncül kullanıcı eylemlerini de kapsamaktadır.

Tablo 5’te yer alan bu veri seti, beş temel değişkenden oluşmaktadır: uye\_id, urun\_id, eklenme\_tarihi, puan ve event\_type. Bunlardan uye\_id, her kullanıcıya özel atanan benzersiz bir kimlik numarası olup, farklı veri kaynakları ile entegre edilebilir yapıdadır. urun\_id değişkeni, kullanıcının etkileşimde bulunduğu ürünü tanımlar. eklenme\_tarihi, olayın gerçekleştiği zamanı göstererek zaman temelli analizlerin yapılmasına olanak tanır. Özellikle dönemsel eğilimlerin ya da kampanya etkilerinin incelenmesinde bu alan büyük önem taşımaktadır. puan değişkeni, kullanıcının ürüne dair memnuniyetini veya değerlendirmesini sayısal olarak ifade eder. 1 ile 5 arasında değişen bu değer, özellikle kullanıcı ilgisini modelleyen veya benzer kullanıcı davranışlarını tespit eden algoritmalarda oldukça faydalı bir parametre olarak kullanılmaktadır. event\_type ise kullanıcı tarafından gerçekleştirilen etkileşim türünü belirtir ve genellikle üç kategoride ele alınır: “view” (görüntüleme), “add\_to\_cart” (sepete ekleme) ve “purchase” (satın alma).

Bu veri setinin en güçlü yönlerinden biri, kullanıcı davranışını yalnızca nihai bir aksiyonla değil, bu aksiyona giden yol boyunca oluşan adımlarla birlikte değerlendirme

imkânı sunmasıdır. Böylece kullanıcıların bir ürüne gösterdiği ilgi düzeyi, ürünle kurduğu temasın sıklığı ve süresi gibi detaylar da analiz kapsamına dâhil edilebilmektedir. Bu yaklaşım, özellikle sıralı veri yapılarında başarılı sonuçlar veren RNN (Recurrent Neural Networks) veya LSTM (Long Short-Term Memory) gibi modellerle çalışıldığında büyük avantaj sağlamaktadır. Zira bu tür modeller, zaman içindeki davranış değişimlerini ve ardışık etkileşim kalıplarını öğrenebildikleri için, kullanıcının karar alma sürecine dair daha isabetli çıkarımlar yapılmasını mümkün kılar.

Sonuç olarak, Tablo 5’te detaylandırılan kullanıcı etkileşimleri veri seti; zaman, davranış türü ve değerlendirme gibi çok boyutlu bilgileri içeren yapısıyla, sadece ürün öneri sistemlerinde değil; aynı zamanda kullanıcı segmentasyonu, ilgi modelleme, kişiselleştirme ve davranışsal pazarlama stratejilerinin geliştirilmesinde de önemli bir araç olarak değerlendirilmektedir. Bu yapısı sayesinde, klasik işlem verilerinin ötesine geçerek kullanıcıyı daha derinlikli ve davranış temelli bir bakış açısıyla analiz etmek mümkün hâle gelmiştir.

**Tablo 5: Kullanıcı etkileşimlerine ait örnek veri seti**

uye_id	urun_id	eklenme_tarihi	puan	event_type
17541	68166	2024-08-05 12:58:14.000	4	add_to_cart
70012	94449	2024-08-05 12:48:24.000	4	add_to_cart
24731	92336	2024-08-05 12:54:56.000	1	view
71710	63917	2024-08-05 12:56:36.000	3	add_to_cart
61321	85904	2024-08-05 12:40:59.000	4	add_to_cart
97307	60117	2024-08-05 12:55:50.000	3	purchase
18168	75629	2024-08-05 12:59:21.000	2	purchase
22515	93205	2024-08-05 12:42:17.000	1	view
24555	68604	2024-08-05 12:59:45.000	1	view
83594	75289	2024-08-05 12:56:56.000	2	view
10140	86459	2024-08-05 12:55:49.000	2	view
92315	75254	2024-08-05 12:54:48.000	4	purchase
43508	68945	2024-08-05 12:54:26.000	3	view

67662	74313	2024-08-05 12:53:34.000	5	view
13568	85609	2024-08-05 12:55:54.000	2	add_to_cart
30914	80498	2024-08-05 12:48:53.000	5	purchase
30417	60237	2024-08-05 12:41:43.000	1	view
36192	80940	2024-08-05 12:58:25.000	4	view
11766	60158	2024-08-05 12:57:15.000	3	add_to_cart
99180	75763	2024-08-05 12:49:59.000	1	purchase
94888	86857	2024-08-05 12:49:54.000	5	add_to_cart

### 3.4.3. Kullanıcı Satın Alma Geçmiş Veri Seti

Araştırmada kullanılan bir diğer temel veri kaynağı olan kullanıcı satın alma geçmişi veri seti, kullanıcıların zaman içinde gerçekleştirdikleri alışveriş davranışlarının sistematik olarak kaydedildiği ve öneri algoritmalarına doğrudan giriş sağlayan bir yapı sunmaktadır. Özellikle işbirlikçi filtreleme algoritmalarında ve makine öğrenmesi temelli modellendirme süreçlerinde bu veri seti, kullanıcı tercihlerini ve ürün talep eğilimlerini ortaya çıkarmak için kritik bir rol oynamaktadır.

Tablo 6'da yer alan kullanıcı satın alma geçmişi veri seti, user\_id, product\_id, quantity ve timestamp olmak üzere dört temel değişkenden oluşmaktadır. user\_id, her kullanıcıyı sistem içinde tanımlayan benzersiz kimliktir. product\_id, satın alınan ürünün sistemdeki tanımını içerir ve ürün bilgileri veri setiyle eşleştirilerek detaylara ulaşmak mümkündür. quantity değişkeni, kullanıcının aynı ürünün kaç adedini satın aldığını ifade eder. Bu sayı bazı algoritmalarda ürün ilgisi için ağırlıklandırma katsayısı olarak kullanılabilir. timestamp alanı ise her satın alma işleminin tarih ve saatini içerir; bu bilgi zamansal analizler ve eğilim modellemeleri açısından oldukça önemlidir.

Bu veri seti, öneri sisteminde işbirlikçi filtreleme (Collaborative Filtering) yöntemlerinin uygulanabilmesi için vazgeçilmezdir. Özellikle user-based ve item-based filtreleme yöntemleri, kullanıcılar arasında benzerlik kurarken veya ürünler arasında ortak tercih ilişkisi kurarken bu veri setinden faydalanmaktadır. Kullanıcıların aynı ürünleri alma sıklıkları, zaman aralıkları ve ürün bazlı talepleri üzerinden benzer profiller çıkarılabilmekte ve buna dayalı öneriler üretilebilmektedir.

Ek olarak, bu veri seti popülerlik tabanlı algoritmaların temelini de oluşturur. Sistem genelinde en çok satın alınan ürünlerin belirlenmesi, yeni veya giriş yapmamış kullanıcılar için hızlı ve genel geçer öneriler sunulmasına olanak tanır. Ayrıca timestamp alanı kullanılarak belirli dönemlerde (örneğin kampanya dönemlerinde veya tatil zamanlarında) öne çıkan ürünler tespit edilip dinamik öneri modelleri oluşturulabilir. Bu sayede öneri sistemi, yalnızca kişiye özel değil, aynı zamanda zamana duyarlı öneriler sunabilme yetisine sahip olur.

Sonuç olarak, kullanıcı satın alma geçmişi veri seti; kullanıcı tercihlerinin tarihsel gelişimini yansıtan, zaman temelli eğilimlerin belirlenmesine imkân tanıyan ve algoritmik modelleme sürecinde veri güvenilirliğini artıran önemli bir yapı sunmaktadır. Gerek bireysel analizlerde gerekse sistem düzeyinde davranışsal örüntülerin çıkarılmasında bu veri seti etkin bir biçimde kullanılmıştır.

**Tablo 6: Kullanıcı satın alma geçmişine ait örnek veri seti**

user_id	product_id	quantity	timestamp
7924	75318	1	2024-04-18 00:05:00
5196	64359	4	2024-06-29 09:40:00
7316	72317	5	2024-06-11 05:12:00
2457	83746	4	2024-01-02 16:01:00
2241	63670	1	2024-02-05 05:35:00
2535	69690	4	2024-04-06 11:59:00
6885	77720	1	2024-03-11 14:26:00
4145	69852	4	2024-05-16 23:14:00
4124	91566	3	2024-03-08 15:18:00
5594	97752	1	2024-06-14 06:03:00
7353	63096	3	2024-01-05 03:40:00
9807	91926	3	2024-01-03 19:54:00
3460	81595	1	2024-02-24 06:25:00
6864	69798	2	2024-04-14 04:33:00
8255	84303	2	2024-05-22 07:54:00
5424	76220	1	2024-03-22 10:45:00
1360	93859	4	2024-02-04 00:44:00
8850	84847	3	2024-06-28 03:29:00
9655	84552	2	2024-06-26 06:30:00
7442	74596	5	2024-04-22 22:12:00
2794	64456	1	2024-01-31 05:49:00
9973	93482	4	2024-04-09 00:35:00
8067	81545	4	2024-06-18 12:03:00
3259	84945	5	2024-02-25 20:27:00
6383	99834	5	2024-06-13 10:34:00

### **3.5. Veri Toplama Araçları**

Bu araştırmada kullanılan veriler, Türkiye merkezli ve büyük ölçüde teknolojik ürünlerin satışına odaklanan bir e-ticaret firmasının dijital satış ve kullanıcı etkileşim sistemlerinden temin edilmiştir. Veri toplama işlemleri doğrudan şirketin ürün katalogları, kullanıcı davranış kayıtları ve sipariş geçmişi gibi sistematik olarak tutulan dijital altyapılarından elde edilmiştir. Veriler, manuel giriş yapılmadan, sistemden doğrudan veri tabanı sorguları (SQL) ile çekilmiş ve anonimleştirilerek araştırmada kullanılmak üzere analiz ortamına aktarılmıştır.

Elde edilen veri setleri üç ana başlık altında sınıflandırılmıştır: Ürün bilgileri veri seti, her bir ürünün teknik ve yapısal tanımlarını içeren içerik odaklı verilerden oluşmaktadır. Kullanıcı etkileşimleri veri seti, kullanıcıların ürünleri görüntüleme, sepete ekleme ve puanlama gibi davranışlarını içeren eylem verilerini barındırmaktadır. Kullanıcı satın alma geçmişi veri seti ise her bir kullanıcının geçmiş sipariş hareketlerini tarihsel ve niceliksel biçimde içermektedir.

Araştırmada kullanılan bu üç veri seti, söz konusu firmanın farklı zamanlarda topladığı ve güncel ürün/hareket kayıtlarını içeren verilerdir. Firma genel itibarıyla bilgisayar bileşenleri, oyuncu ekipmanları, robot süpürgeler, akıllı ev cihazları ve çevre birimleri gibi yüksek teknoloji tüketim ürünleri üzerine uzmanlaşmış bir yapıya sahiptir. Bu bağlamda, öneri sisteminde test edilen modellerin çıktıları teknoloji alışverişlerine yönelik kullanıcı davranışlarını temsil etme potansiyeline sahiptir. Ayrıca, farklı algoritmalarla karşılaştırmalı analiz yapılmasına olanak sağlayacak şekilde verilerin yeterli çeşitlilikte ve hacimde olması, veri toplama sürecinin araştırma açısından uygunluğunu desteklemektedir.

### **3.6. Verilerin Analizi**

Çalışmada öneri sistemi geliştirme süreci sistematik bir yapı izlenerek yürütülmüştür. İlk olarak, çalışma kapsamında kullanılacak veri setleri toplanmış ve veri hazırlama sürecine tabi tutulmuştur. Bu süreçte eksik, tutarsız ve tekrarlayan veriler tespit edilerek veri temizleme işlemleri gerçekleştirilmiş, uç değerler (outlier) analiz edilerek uygun tekniklerle işlenmiştir. Verinin bütünlüğünü ve güvenilirliğini sağlamak amacıyla standart ön işleme teknikleri uygulanmış ve model eğitimine uygun nitelikte optimize edilmiş bir veri seti oluşturulmuştur.

Çalışmada üç temel veri seti kullanılmıştır. İlk veri seti, yaklaşık 20.000 satırdan oluşan ürün bilgileri veri setidir. Tablo 1’de yer alan veri seti, ürün adı, markası, kategorisi ve açıklamaları gibi içerik tabanlı bilgileri içermektedir ve özellikle içerik temelli yaklaşımların hazırlanmasında önemli bir rol oynamıştır. İkinci veri seti olan Tablo 2 de yer alan kullanıcı etkileşimleri veri seti, yaklaşık 100.000 satırdan oluşmakta ve kullanıcıların ürünlerle olan tıklama, görüntüleme, favorileme gibi etkileşimlerini zaman damgasıyla birlikte içermektedir. Bu veri seti, zaman sıralı analiz gerektiren derin öğrenme modelleri için kullanıma uygun hale getirilmiştir. Üçüncü veri seti olan Tablo 3 te yer alan kullanıcı-satın alma geçmişi veri seti ise yaklaşık 1.000 satırlık daha küçük bir yapıya sahip olup, kullanıcıların geçmiş satın alma davranışlarını içermektedir ve özellikle kullanıcı-temelli öneri modellerinde temel kaynak olarak kullanılmıştır.

### **3.7. Yöntemin Uygulanması**

Çalışmada öneri sistemi geliştirme süreci sistematik bir yapı izlenerek yürütülmüştür. İlk olarak, çalışma kapsamında kullanılacak veri setleri toplanmış ve veri hazırlama sürecine tabi tutulmuştur. Bu süreçte eksik, tutarsız ve tekrarlayan veriler tespit edilerek veri temizleme işlemleri gerçekleştirilmiş, uç değerler (outlier) analiz edilerek uygun tekniklerle işlenmiştir. Verinin bütünlüğünü ve güvenilirliğini sağlamak amacıyla çeşitli ön işleme teknikleri uygulanmış ve model eğitime uygun nitelikte optimize edilmiş bir veri seti oluşturulmuştur.

Çalışmada üç temel veri seti kullanılmıştır. İlk veri seti, 23.388 satırdan oluşan ürün bilgileri veri setidir. Tablo1’de yer alan veri seti, ürün adı, markası, kategorisi ve açıklamaları gibi içerik tabanlı bilgileri içermektedir ve özellikle içerik temelli yaklaşımların hazırlanmasında önemli bir rol oynamıştır. İkinci veri seti olan Tablo 2’de yer alan kullanıcı etkileşimleri veri seti, 100.000 satırdan oluşmakta ve kullanıcıların ürünlerle olan tıklama, görüntüleme, favorileme gibi etkileşimlerini zaman damgasıyla birlikte içermektedir. Bu veri seti, zaman sıralı analiz gerektiren derin öğrenme modelleri için kullanıma uygun hale getirilmiştir. Üçüncü veri seti olan Tablo 3’te yer alan kullanıcı-satın alma geçmişi veri seti ise 1.000 satırlık daha küçük bir yapıya sahip olup, kullanıcıların geçmiş satın alma davranışlarını içermektedir ve özellikle kullanıcı-temelli öneri modellerinde temel kaynak olarak kullanılmıştır.

Tablo 7’de sunulan ham veri seti, sistemden doğrudan alınmış olup; çeşitli karakter bozulmaları, eksik bilgiler, tutarsız metin yapıları ve kodlama sorunları içermektedir. Özellikle “özellikler” sütununda yer alan “BelirtilmemiAY”, “DAXAYAK”, “6aE” gibi ifadeler, karakter kodlama hataları ve manuel veri girişi kaynaklı bozulmalardan oluşmakta ve bu tür metinsel bozukluklar öneri sistemlerinde anlamlı özellik çıkarımı yapılmasını zorlaştırmaktadır. Bu nedenle, veri ön işleme süreci kapsamında detaylı bir temizlik ve dönüştürme işlemi uygulanmıştır (Kotsiantis, Kanellopoulos, & Pintelas, 2006). İlk olarak, karakter kodlaması problemi yaşayan alanlarda UTF-8 standardizasyonu sağlanmış ve özel karakterler ya da bozuk semboller düzeltilmiştir. Ardından, eksik ya da anlamsız veriler tespit edilerek; örneğin "BelirtilmemiAY" gibi metinler "Belirtilmemiş" olarak normalize edilmiş hem yazım hataları hem de dil bilgisi hataları düzeltilmiştir. Metin içerisindeki büyük/küçük harf tutarsızlıkları, metin normalleştirme adımlarıyla düzenlenmiş, böylece aynı anlama gelen ancak farklı biçimlerde yazılmış ifadeler birleştirilmiştir. Ayrıca, metin içerisindeki fazladan boşluklar, eksik noktalama işaretleri ve uygunsuz virgül kullanımları string manipülasyon yöntemleri (örneğin trim, str\_replace, preg\_replace) (Atkinson, 2009) ile temizlenmiş; kelimeler arası gereksiz boşluklar kaldırılmış, tüm metinler tutarlı hale getirilmiştir. “Ek olarak, kategori ve marka ID’leri gibi sayısal alanlarda sistemde tanımlı olmayan, eksik ya da hatalı eşleşen kayıtlar belirlenmiş ve ilgili ürünlerin doğru ID’lerle eşleştirilmesi sağlanmıştır. Bütün bu işlemler sonucunda oluşturulan temizlenmiş veri seti Tablo 8’de sunulmakta olup, bu tablo sistematik olarak uygulanan veri temizleme stratejilerinin sonuçlarını temsil etmektedir. Bu adımlar yalnızca örnek veri için değil, çalışmada kullanılan diğer veri setlerine uygulanmış ve modelin daha doğru, tutarlı ve güvenilir çıktılar üretmesi amaçlanmıştır.

**Tablo 7: Ürün bilgileri ham veri seti**

urun_id	adi	marka_id	kategori_id	ozellikleri
71829	MSI PRO B650M-B	72	799	AM5, AMD B650, 2 x USB 2.0, 4 x USB 3.2 Gen1
59475	Xiaomi Mi Air Purif	540	881	BelirtilmemiAY, Uzaktan Kumanda, Kokuyu Giderir
20991	Xiaomi Mi Air Purif 3	540	881	BelirtilmemiAY, DAĞAYAYak Ses Seviyesi, Temiz Hava
65983	MSI Modern 15	72	834	Intel Core i7-1355U, 15.6a€, FreeDOS

**Tablo 8: Ürün bilgileri temizlenen veri seti**

urun_id	adi	marka_id	kategori_id	ozellikleri
71829	MSI PRO B650M-B	72	799	AM5, AMD B650, 2 x USB 2.0, 4 x USB 3.2 Gen1
59475	Xiaomi Mi Air Purif	590	681	Belirtilmemiş, Uzaktan Kumanda, Kokuyu Giderir
20991	Xiaomi Mi Air Purif 3	590	681	Belirtilmemiş, Düşük Ses Seviyesi, Temiz Hava
65983	MSI Modern 15	72	874	Intel Core i7-1355U, 15.6", FreeDOS

Çalışmanın ikinci aşaması, yalnızca model eğitimi gerektiren algoritmaların öğrenme süreçlerini kapsamaktadır. Bu doğrultuda, içerik tabanlı filtreleme, popülerlik tabanlı öneri veya rastgele seçim gibi önceden tanımlı kurallar ya da istatistiksel dağılımlar üzerinden çalışan, herhangi bir öğrenme mekanizması içermeyen algoritmalar bu aşamaya dahil edilmemiş ve doğrudan performans değerlendirme sürecine yönlendirilmiştir (Adomavicius & Tuzhilin, 2005).

Bu çalışma kapsamında, veri üzerinden öğrenme yeteneğine sahip olan bazı algoritmaların önden eğitilmeleri gerekmektedir. Bu nedenle, Random Forest ve Recurrent Neural Networks (RNN) gibi makine öğrenmesi ve derin öğrenme tabanlı algoritmalar için bir eğitim süreci uygulanmıştır. Temizlenmiş etkileşim verisi, bu algoritmalara uygun formatta sunulmuş ve kullanıcı davranış örüntülerinin öğrenilmesi sağlanmıştır. Özellikle RNN modeli, Embedding, LSTM ve Dense katmanlarıyla yapılandırılmış ve sparse\_categorical\_crossentropy kayıp fonksiyonu (Chollet, 2021) ile adam optimizasyon algoritması kullanılarak eğitilmiştir. Bu süreçte model doğrudan eğitim-veri seti üzerinde çalıştırılarak doğruluk (accuracy) metriği ile değerlendirilmiştir. Random Forest modeli ise, kullanıcı-ürün etkileşim verisi üzerinde uygulanmıştır. Bu algoritma, etkileşim verisindeki ürün kimliklerine (ürün\_id) göre kullanıcıların bir sonraki etkileşimde bulunacağı ürünleri tahmin etmeyi amaçlamıştır. Model 100 karar ağacından (n\_estimators) oluşan bir yapı ile yapılandırılmıştır. Eğitim sürecinde, veri seti eğitim ve test olmak üzere ikiye ayrılmış; test oranı %20 olarak belirlenmiştir. Model, gini kriteri ile ayırım yapacak şekilde oluşturulmuştur. Random Forest modeli için, klasik derin öğrenme algoritmalarında olduğu gibi epoch, batch size veya learning rate gibi hiperparametrelere ihtiyaç duyulmamıştır.

Son aşamada, geliştirilen modellerin performansları belirlenen metrikler çerçevesinde değerlendirilmiştir. Modellerin doğruluk (MAP - Mean Average Precision), kişiselleştirme (MPS - Mean Personalization Score), çeşitlilik (MDS - Mean Diversity Score) ve yenilikçilik (MNS - Mean Novelty Score) ölçütleri üzerinden performansları analiz edilmiştir. Elde edilen sonuçlar kendi içlerinde karşılaştırmalı olarak yorumlanmış, her bir algoritmanın güçlü ve zayıf yönleri sistematik bir şekilde ortaya konulmuştur. Bu değerlendirme süreci, uygulanan yöntemlerin gerçek veri üzerinde gösterdiği performansı ayrıntılı bir şekilde ortaya koymuştur.

## 4. BULGULAR

Bu bölümde, çalışmada değerlendirilen yedi farklı öneri algoritmasının e-ticaret verisi üzerindeki performansları, çok boyutlu metrikler doğrultusunda analiz edilmiştir. Analizler doğrultusunda her algoritma için beş temel metrik (MAP, CC, MNS, MDS, MPS) kullanılarak doğruluk, katalog kapsamı, yenilikçilik, çeşitlilik ve kişiselleştirme yönlerinden karşılaştırmalar yapılmıştır. Elde edilen sonuçlar tablo ve grafiklerle desteklenerek sunulmuştur.

### 4.1. Genel Performans Tablosu

Aşağıdaki Tablo 9’da öneri sistemine entegre edilen yedi farklı algoritmanın performans metriklerine göre elde ettikleri değerler sunulmuştur. Bu tabloda, her bir algoritma için MAP (Ortalama Doğruluk), CC (Katalog Kapsamı), MNS (Ortalama Yenilik), MDS (Ortalama Çeşitlilik) ve MPS (Kişiselleştirme) skorları yer almaktadır.


Tablo 9: Algoritma performans sonuçları tablosu

Algoritma	MAP	CC	MNS	MDS	MPS
Random based	0.03	0.40	6.89	0.23	0.99
Popularity-based	0.00	0.01	8.78	0.53	0.65
Content-based	0.00	0.00	0.49	0.33	0.99
Item-based CF	0.42	0.23	5.00	0.75	0.23
Hybrid Model	0.01	0.01	0.50	0.80	0.63
RNN	0.00	0.08	1.00	1.00	0.03
Random Forest	0.33	0.23	3.89	0.00	0.33

### 4.2. Doğruluk Performansı (MAP)

Mean Average Precision (MAP), öneri sistemlerinin doğruluk performansını değerlendirmede kullanılan temel metriklerden biridir. Bu metrik, sistemin kullanıcılara

sunduğu öneri listelerinde, gerçekten ilgili olan ürünlerin ne kadar üst sıralarda yer aldığını ölçer. MAP hesaplamasında önce her kullanıcı için Average Precision (AP) değeri hesaplanır; bu değer, önerilen ürünler arasında kullanıcı için gerçekten ilgili olanların sıralamasına göre belirlenir. Daha sonra tüm kullanıcıların AP değerlerinin ortalaması alınarak sistemin genel doğruluk düzeyi belirlenir. MAP değeri 0 ile 1 arasında bir değerdir ve değer 1'e yaklaşması, sistemin önerilerinde daha yüksek isabet sağladığı anlamına gelir. Bu çalışmada öneri sistemine entegre edilen yedi farklı algoritmanın MAP skorları hesaplanmıştır. Şekil 6 da görüldüğü üzere elde edilen sonuçlara göre, Item-Based Collaborative Filtering algoritması 0.42 MAP değeriyle en yüksek doğruluk düzeyine ulaşmıştır. Random Forest algoritması 0.33 değeri ile ikinci sırada yer alırken, Random-based 0.03 skoruyla doğruluk sergilemiştir. Hybrid modelin 0.01 MAP değeriyle daha düşük bir doğruluk düzeyi sunarken, Popularity-based, Content-Based Filtering ve RNN modeli MAP değeri 0.00 olarak hesaplanmıştır. Bu skorlar, her algoritmanın kullanıcıya sunduğu önerilerin sıralama başarımına göre ölçülen nicel doğruluk düzeylerini ifade etmektedir.




Şekil 6: Öneri algoritmalarına göre Ortalama Doğruluk (MAP) değerleri

### 4.3. Katalog Kapsamı (Catalog Coverage- CC)

Catalog Coverage (CC), bir öneri sisteminin tüm ürün kataloğu içerisinde ne kadar geniş bir ürün yelpazesi önerdiğini belirlemek için kullanılan bir metriktir. Bu metrik, sistemin sadece popüler ürünleri mi yoksa daha az bilinen ürünleri de içeren daha


geniş kapsamlı öneriler mi sunduğunu analiz eder. CC oranı arttıkça, sistemin daha fazla farklı ürünü önerdiği kabul edilir. Şekil 5’te görüldüğü üzere bu çalışmada Random-based model 0.40, RNN 0.08, Hybrid model 0.01 ve Item-based CF ile Random Forest algoritmaları 0.23 oranında katalog kapsamı sağlamıştır. Popularity-based algoritma ise yalnızca popüler ürünleri önerdiği için 0.01 gibi çok düşük bir CC değeri üretmiştir.



Şekil 7: Öneri algoritmalarına göre Katalog Kapsamı (CC) değerleri

#### 4.4. Yenilikçilik (Mean Novelty Score- MNS)

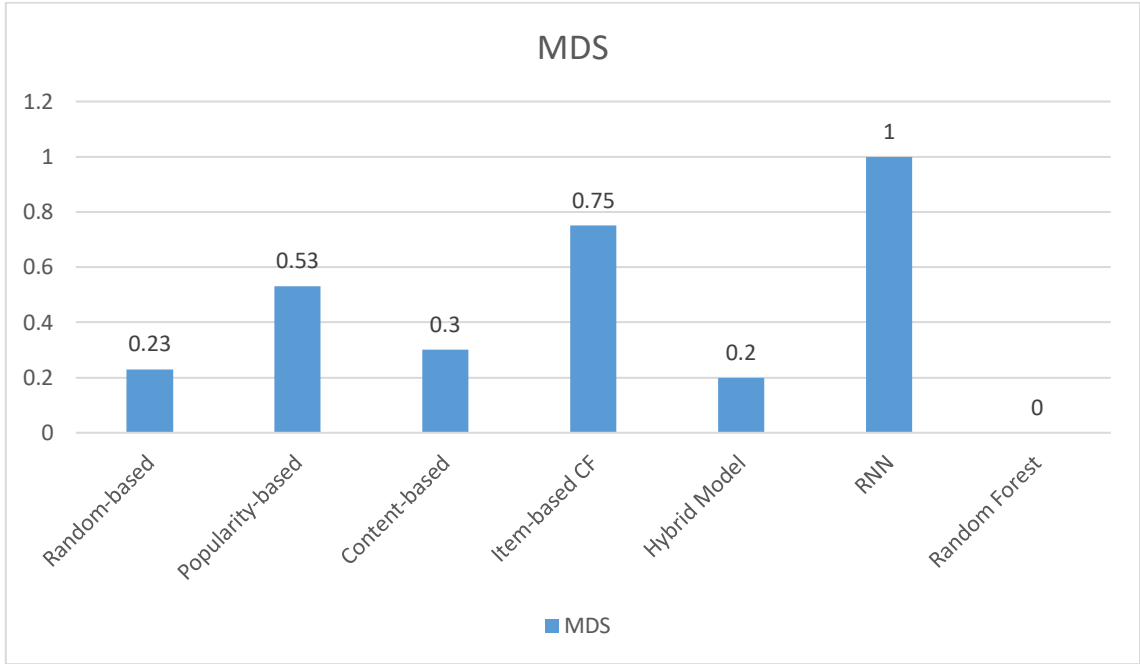
Mean Novelty Score (MNS), öneri sistemlerinin kullanıcılara ne ölçüde yeni, daha önce karşılaşmadıkları ya da popüler olmayan ürünleri sunduğunu ölçmek amacıyla kullanılan bir metriktir. Kullanıcıların daha önce görmedikleri veya etkileşime girmedikleri ürünlerin önerilmesiyle yüksek MNS değerlerine ulaşılır. Bu metrik özellikle kullanıcıların sistemde yeni ürünler keşfetme olasılıklarını artırmak açısından önemlidir. Şekil 8’de görüldüğü üzere bu çalışmada Popularity-based model 8.78 ile en yüksek yenilik skoru üretirken, Random-based algoritma 6.89 değeri ile ikinci sırada yer almıştır. Item-based CF 5.00, Random Forest 3.89, RNN 1.00, Content-based model 0.49 ve Hybrid model 0.33 MNS değerlerine sahiptir.



Şekil 8: Öneri algoritmalarına göre Yenilikçilik (MNS) değerleri

#### 4.5. Çeşitlilik (Mean Diversity Score- MDS)

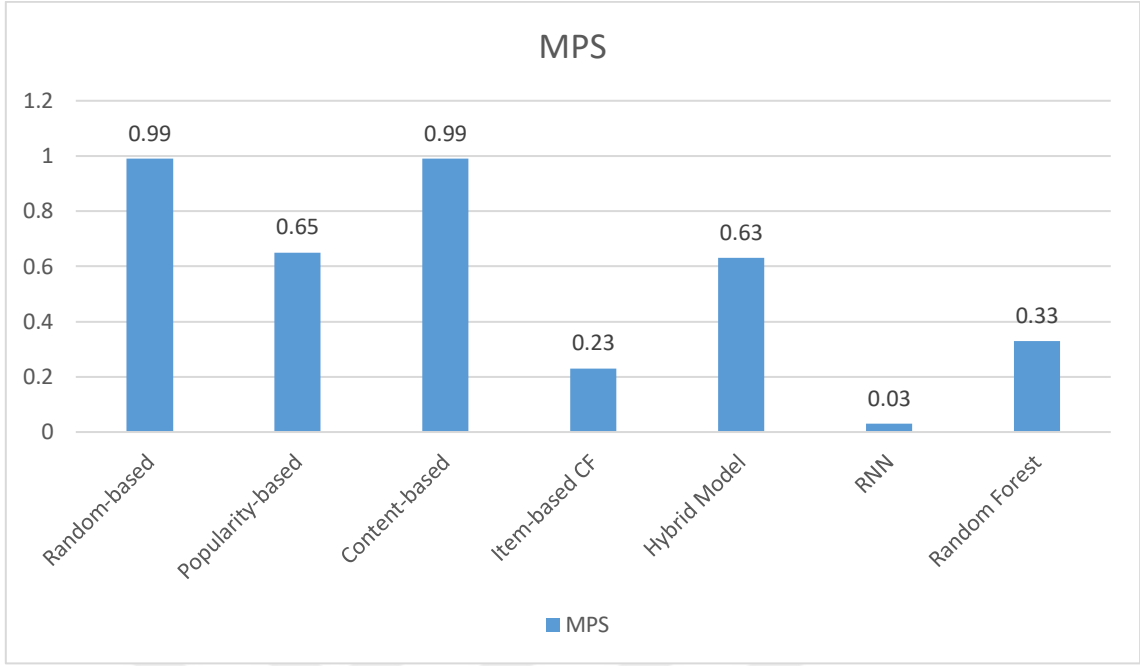
Mean Diversity Score (MDS), sistemin aynı kullanıcıya önerdiği ürünlerin birbirinden ne kadar farklı olduğunu ifade eden bir metriktir. Öneri listesindeki ürünler birbirine ne kadar az benziyorsa çeşitlilik skoru o kadar yüksek olur. Yüksek MDS değeri, sistemin aynı türde ürünler yerine farklı kategorilerden ve niteliklerden ürünler sunduğunu gösterir. Şekil 9’da görüldüğü üzere bu çalışmada kullanılan algoritmalar arasında en yüksek çeşitlilik RNN modeli ile sağlanmıştır (MDS = 1.00). Item-based CF 0.75, Popularity-based 0.53, Content-based 0.30, Random-based 0.23, Hybrid model 0.20 ve Random Forest ise 0.00 çeşitlilik skoru elde etmiştir.



Şekil 9: Öneri algoritmalarına göre Çeşitlilik (MDS) değerleri

#### 4.6. Kişiselleştirme (Mean Personalization Score- MPS)

Mean Personalization Score (MPS), sistemin farklı kullanıcılara sunduğu öneri listelerinin ne kadar benzersiz olduğunu gösteren bir ölçüttür. Yüksek MPS değeri, sistemin her kullanıcıya özel olarak öneri listeleri sunduğunu ve öneri listeleri arasında yüksek farklılık bulunduğunu ifade eder. MPS değeri kullanıcılar arası öneri listesi benzerliği azaldıkça artar. Şekil 10'da görüldüğü üzere bu çalışmada Content-Based ve Random-based algoritmalar 0.99 değeriyle en yüksek kişiselleştirme skoruna ulaşmıştır. Popularity-based model 0.65, Hybrid model 0.63, Random Forest 0.33, Item-Based CF 0.23 ve RNN modeli ise yalnızca 0.03 MPS skoruna sahiptir.



**Şekil 10: Öneri algoritmalarına göre Kişiselleştirme (MPS) değerleri**

## 5.TARTIŞMA

Her algoritma, öneri sistemleri açısından önemli kabul edilen doğruluk, çeşitlilik, yenilikçilik, kişiselleştirme ve katalog kapsamı gibi çeşitli ölçütler temel alınarak değerlendirilmiştir. Analizler, her yöntemin farklı kullanıcı ihtiyaçlarına ve senaryolara nasıl yanıt verdiğini daha iyi anlamayı amaçlamaktadır. Algoritmaların her birine ait performans değerleri, yalnızca genel başarı düzeylerini değil, aynı zamanda güçlü ve zayıf yönlerini de ortaya koymaktadır. Aşağıda sunulan değerlendirme, bu algoritmaların farklı bağlamlarda nasıl sonuçlar verdiğini karşılaştırmalı biçimde göstermektedir. Tablo 9'da, her bir algoritmanın öneri performansına yönelik metrikler özetlenmiştir: Bu bölümde, algoritmaların güçlü ve zayıf yönleri detaylı olarak ele alınmıştır. Bölümün devamında öncelikle çalışmada kullanılan algoritmalar ile ilgili değerlendirme yapılmıştır. Ardından çalışma kapsamında yer alan beş değerlendirme metriği üzerinden sonuçlar değerlendirilmiş ve karşılaştırılmıştır. Son olarak araştırma soruları yanıtlanmıştır.

Rastgele öneriler sunan Random-Based Model, herhangi bir kullanıcının geçmiş davranışlarını dikkate almadığı için öneri doğruluğu açısından ( $MAP = 0.02$ ) oldukça zayıf kalmıştır. Ancak, yenilikçilik ( $MNS = 6.90$ ) ve kişiselleştirme ( $MPS = 0.99$ ) açısından yüksek değerler sunmaktadır. Rastgele seçim yapıldığından, her kullanıcıya farklı ürünler önerilmekte ve bu durum kişiselleştirme skorunun yüksek olmasına yol açmaktadır. Ancak, rastgele önerilerin belirli bir yapıya sahip olmaması, kullanıcının gerçekten ilgisini çekebilecek ürünleri keşfetmesini zorlaştırmaktadır. Katalog kapsamı ( $CC = 0.40$ ) açısından orta seviyede bir performans göstermiş, fakat çeşitlilik ( $MDS = 0.23$ ) açısından zayıf kalmıştır.

Popularity-Based Model, en çok satan veya en çok görüntülenen ürünleri önererek çalıştığı için yenilikçilik ( $MNS = 8.78$ ) açısından en yüksek puanı elde etmiştir. Kullanıcıların en popüler ürünlerle karşılaşmasını sağladığından, farklı ve yeni ürünler keşfetme şansını artırmaktadır. Çeşitlilik ( $MDS = 0.53$ ) açısından da orta seviyede bir performans göstermiştir, çünkü popüler ürünler genellikle farklı kategorilere yayılmış olabilir. Ancak, katalog kapsamı ( $CC = 0.01$ ) son derece düşüktür, çünkü model yalnızca en popüler ürünleri önerdiğinden, geniş bir ürün yelpazesini kapsayamaz. Öneri doğruluğu ( $MAP = 0.00$ ) da oldukça düşük olup, kullanıcının bireysel geçmişine

odaklanmayan genel öneriler sunduğundan, kişiye özel öneri yapma konusunda başarısız olmuştur.

İçerik Tabanlı Model (Content-Based Filtering), kullanıcının geçmiş satın alma veya etkileşimlerine dayalı olarak benzer içeriklere sahip ürünleri önerme prensibiyle çalıştığı için kişiselleştirme (MPS = 0.99) açısından en başarılı model olmuştur. Bu durum, içerik tabanlı öneri sistemlerinin kişiselleştirme alanındaki başarısını önceki çalışmalarda da destekler niteliktedir. Örneğin, Bitirim, içerik tabanlı yöntemin kullanıcıların ilgi alanlarına dayalı olarak yüksek oranda beğenilen ürünleri önerdiğini ve uygulanan testte kullanıcıların yaklaşık %78.65'inin önerileri beğendiğini raporlamıştır. Model her bir ürünün özelliklerini analiz ederek geniş bir yelpazede öneriler sunabilmektedir. Ancak, yenilik oranı (MNS = 0.50) düşüktür, çünkü kullanıcıları genellikle geçmişte tercih ettikleri ürünlere yönlendirmekte ve yeni ürünler keşfetme şansını sınırlamaktadır. Aynı zamanda, öneri doğruluğu (MAP = 0.00) açısından başarısızdır, çünkü kullanıcıların gerçekten ilgileneceği ürünleri tam olarak tahmin edemeyebilir.

Kullanıcıların geçmiş alışveriş alışkanlıklarına dayalı olarak benzer ürünleri öneren Item-Based Collaborative Filtering (IBCF) modeli, doğruluk açısından en iyi sonuçları vermiştir (MAP = 0.42). Bu model, kullanıcının satın aldığı ürünlere benzeyen ürünleri önererek, kullanıcının gerçekten ilgisini çekecek ürünleri seçebilme konusunda en başarılı sistemlerden biri olmuştur. Bununla birlikte, çeşitlilik (MDS = 0.75) açısından da güçlü bir performans sergilemiştir, çünkü kullanıcıya sunduğu öneriler sadece belirli bir ürün grubuna odaklanmak yerine, farklı ürünlere yönlendirmektedir. Ancak, katalog kapsamı (CC = 0.23) düşük seviyededir, çünkü model genellikle kullanıcıların geçmişte etkileşimde bulunduğu ürün gruplarına odaklanarak daha dar bir öneri listesi sunmaktadır. Kişiselleştirme (MPS = 0.23) açısından ise zayıf bir performans göstermiştir, çünkü öneriler bireysel kullanıcı tercihlerinden çok, ürünler arasındaki benzerliklere dayanarak oluşturulmaktadır.

Hybrid Model, içerik tabanlı filtreleme ile işbirlikçi filtrelemeyi birleştirerek öneri doğruluğunu ve kişiselleştirme seviyesini artırmayı amaçlamaktadır. Ancak, test edilen hibrit modelin öneri doğruluğu (MAP = 0.01) ve yenilikçilik (MNS = 0.50) açısından düşük bir performans sergilediği görülmüştür. Kişiselleştirme (MPS = 0.63) açısından

orta seviyede bir başarı elde etmiştir, ancak çeşitlilik (MDS = 0.80) ve katalog kapsamı (CC = 0.01) açısından düşük sonuçlar göstermektedir.

RNN (Recurrent Neural Networks- Tekrarlayan Sinir Ağları) modeli, kullanıcının zaman içindeki değişen tercihlerine odaklanarak çalışan bir sistemdir. MDS (1.00) ile en yüksek çeşitlilik değerine sahiptir, çünkü dinamik yapısı sayesinde farklı türde ürünleri önerme kapasitesi yüksektir. Ancak, öneri doğruluğu (MAP = 0.00) ve kişiselleştirme (MPS = 0.03) açısından oldukça zayıf performans göstermiştir. Kullanıcıların geçmiş etkileşimlerine göre tahminler yapabilese de gerçek zamanlı olarak güncellenmediğinde öneriler eskimiş veya ilgisiz hale gelebilmektedir.

Son olarak, Random Forest modeli, makine öğrenmesi tabanlı bir yaklaşım kullanarak öneri sistemlerine farklı bir perspektif getirmektedir. MNS (3.89) ile orta seviyede yenilik sağlayan bir modeldir, çünkü model geçmiş verilerden öğrendiği paternlere göre öneriler sunduğunda, zaman içinde değişen ürün tercihlerini de analiz edebilmektedir. Ancak, MAP (0.33) ile doğruluk açısından zayıf kalmıştır. Modelin önerdiği ürünler bazen rastgele veya ilgisiz olabilmekte, bu da sistemin etkinliğini düşürebilmektedir.

Genel olarak bakıldığında, Item-Based Collaborative Filtering, öneri doğruluğu açısından en iyi model olurken, içerik tabanlı model kişiselleştirme açısından en başarılı model olmuştur. Çeşitlilik sağlamak için RNN en iyi seçenek olarak öne çıkarken, yeni ürünleri keşfetme açısından Popularity Based Model en yüksek performansı göstermiştir. Öneri sistemlerinin performansını değerlendirmek amacıyla gerçekleştirilen analizde, farklı algoritmaların çeşitli metriklere göre karşılaştırılması yapılmıştır. Tablo 9'da görüldüğü üzere, Content-Based ve Item-Based yaklaşımlarının genel olarak en yüksek performansı gösterdiği tespit edilmiştir. MPS metriği açısından, özellikle Content-Based yaklaşımı belirgin bir üstünlük sağlarken, MDS metriği açısından Item-Based algoritması dikkat çekici bir performans sergilemiştir. Buna karşın, Popularity-Based ve Random-Based algoritmalarının, tüm metrikler göz önüne alındığında, daha düşük başarıya sahip olduğu görülmektedir. Özellikle, RNN algoritması bazı metriklerde güçlü performans gösterirken, CC metriğinde dalgalanmalar yaşandığı gözlemlenmiştir. Random Forest yöntemi ise tüm metrikler açısından dengeli ancak orta seviyede bir performans sergilemiştir. Bu analiz, öneri sistemleri için içerik-temelli ve öge-temelli yaklaşımların geleneksel yöntemlere kıyasla daha yüksek doğruluk ve başarı sunduğunu

göstermektedir. Ancak, derin öğrenme ve hibrit modellerin belirli metriklerde avantaj sağlayabileceği ve daha detaylı incelemeye tabi tutulması gerektiği sonucu ortaya çıkmaktadır.

Elde edilen bulgular, literatürde Le'nin öneri sistemleri üzerine gerçekleştirdiği çalışma ile karşılaştırıldığında dikkat çekici benzerlikler ve farklılıklar göstermektedir. Her iki çalışmada da Item-Based Collaborative Filtering algoritması özellikle çeşitlilik açısından en başarılı model olarak öne çıkmaktadır. Bizim çalışmamızda bu algoritma 0.75 çeşitlilik skoru ve 0.23 kişiselleştirme skoru üretmiştir. Le'nin çalışmasında ise aynı algoritma, 1.04 çeşitlilik ve 9.58 kişiselleştirme skorlarını ortaya koymuştur. Bu fark, veri setlerindeki kullanıcı yoğunluğu ve ürün etiketleme yapısının öneri kalitesine olan etkisini yansıtmaktadır. Content-Based algoritma, her iki çalışmada da yüksek kişiselleştirme başarısı göstermektedir. Bizim çalışmamızda 0.99 kişiselleştirme ve 0.50 yenilikçilik skorları elde edilmiştir. Le'nin çalışmasında ise kişiselleştirme skoru 9.88, yenilikçilik skoru ise 3.08 olarak kaydedilmiştir. Random-Based algoritma, doğruluk açısından her iki çalışmada da zayıf kalmasına rağmen, bizde 0.99 kişiselleştirme ve 6.90 yenilikçilik skoru ile oldukça güçlü bir çeşitlilik sağlamıştır. Le'nin çalışmasında da benzer şekilde kişiselleştirme skoru 9.88, yenilikçilik skoru ise 7.62 olarak rapor edilmiştir. Bu durum, algoritmanın öneri çeşitliliğini artırmada etkin olduğunu doğrulamaktadır. Popularity-Based model, her iki çalışmada da düşük kişiselleştirme ile öne çıkmaktadır. Bizim çalışmamızda bu modelin kişiselleştirme skoru oldukça düşüktür ve buna rağmen 8.78 gibi yüksek bir yenilikçilik skoru elde edilmiştir. Le'nin çalışmasında ise kişiselleştirme 0.02, yenilikçilik 6.58 olarak rapor edilmiştir. Aradaki farklar, ürünlerin popülerliğinin veri setine göre değişebildiğini göstermektedir. Bizim çalışmamızda ayrıca Le'nin çalışmasında yer almayan RNN ve Random Forest algoritmaları da değerlendirmeye alınmıştır.

Genel olarak değerlendirildiğinde, her iki çalışma farklı veri setleri ve uygulama koşulları altında gerçekleştirilmiş olsa da algoritmaların güçlü ve zayıf yönlerinin benzer eğilimler gösterdiği gözlemlenmiştir. Bu sonuçlara dayanarak araştırma sorularımızı şu şekilde cevaplayabiliriz.

**AS1** sorusuna yanıt olarak, e-ticaret verileri üzerinde farklı algoritmaların kişiselleştirme, doğruluk, yenilik ve çeşitlilik metriklerinde ciddi farklılıklar gösterdiği görülmüştür. Örneğin, Item-Based CF doğruluk açısından en yüksek performansı

sağlarken, RNN modeli çeşitlilik açısından zirveye çıkmıştır. İçerik tabanlı model kişiselleştirme açısından öne çıkmış, Popularity-Based model ise yenilikçilik konusunda lider olmuştur. Bu farklılıklar, algoritmaların temel yapılarına bağlı olarak değişiklik göstermekte ve her algoritmanın farklı hedefler için optimize edilmesi gerektiğini ortaya koymaktadır.

**AS2** kapsamında çalışmada değerlendirilen tüm öneri algoritmalarının güçlü ve zayıf yönleri incelendiğinde, her birinin belirli metriklerde öne çıktığı görülmektedir. ItemBased Collaborative Filtering algoritması, yüksek doğruluk (MAP = 0.42) ve çeşitlilik (MDS = 0.75) oranlarıyla dikkat çekerken, kişiselleştirme (MPS = 0.23) ve katalog kapsamı (CC = 0.23) açısından zayıf kalmıştır. Content-Based model, yüksek kişiselleştirme (MPS = 0.99) ve katalog kapsamı (CC = 0.0) değerleriyle öne çıkarken, doğruluk (MAP = 0.00) ve yenilikçilik (MNS = 0.50) açısından yetersiz performans sergilemiştir. Random-Based algoritma kişiselleştirme (MPS = 0.99) ve yenilikçilik (MNS = 6.90) bakımından başarılı olmasına rağmen, doğruluk (MAP = 0.03) ve çeşitlilik (MDS = 0.23) açısından sınırlı kalmıştır. Popularity-Based model en yüksek yenilikçilik skorunu (MNS = 8.78) elde ederken, diğer tüm metriklerde özellikle katalog kapsamı (CC = 0.01) ve doğruluk (MAP = 0.0) bakımından düşük sonuçlar göstermiştir. Hybrid model dengeli bir yapı sunsa da tüm metriklerde düşük değerler üretmiştir (örneğin MAP = 0.01, MNS = 0.50). RNN algoritması ise düşük doğruluk (MAP = 0.01), çeşitlilik (MDS = 1.00) ve kişiselleştirme (MPS = 0.03) gibi sonuçlarla özellikle bu veri setinde etkili olamamıştır. Benzer şekilde, Random Forest algoritması da tüm metriklerde düşük düzeyde kalmış (örneğin MAP = 0.33, CC = 0.23), sadece yenilikçilik açısından kısmen kabul edilebilir bir performans sergilemiştir (MNS = 3.89). Bu bulgular, her algoritmanın belirli hedeflere yönelik avantajlar sunduğunu, ancak tüm metriklerde dengeli bir başarı için model seçiminin kullanım senaryosuna göre yapılması gerektiğini ortaya koymaktadır.

**AS3** ile ilgili olarak, derin öğrenme tabanlı öneri algoritmalarının (bu çalışmada RNN) özellikle çeşitlilik (MDS) metriğinde açık bir üstünlük sağladığı görülmüştür. Ancak doğruluk ve kişiselleştirme gibi temel kriterlerde geleneksel yöntemlerin (özellikle Item-Based CF ve Content-Based) gerisinde kaldığı gözlemlenmiştir. RNN'in zaman serileri üzerinde çalışabilmesi çeşitlilik açısından avantaj sağlasa da bireysel kullanıcı ilgisine tam uyum sağlayamadığı için doğruluk ve kişiselleştirme sonuçları daha düşük olmuştur.

## 6. SONUÇ VE ÖNERİLER

Bu çalışma, e-ticaret ortamlarında öneri sistemlerinin başarımını değerlendirmeyi amaçlayarak farklı algoritmaların performanslarını çok boyutlu şekilde analiz etmiştir. Öneri sistemlerinin temel amacı, kullanıcıların ilgisini çekecek ürünleri yüksek doğruluk, çeşitlilik ve kişiselleştirme ile sunmaktır. Bununla birlikte, kullanıcıların yeni ürünler keşfetmesini sağlamak ve sistemin ürün kataloğundaki genişliği kullanabilmesi de öneri sistemlerinin başarısını etkileyen önemli kriterler arasında yer almaktadır. Bu çalışmada, öneri sistemlerinin performansını değerlendirmek amacıyla Random-based, Popularity-based, Content-based Filtering, Item-based Collaborative Filtering, Hybrid Model, Recurrent Neural Networks ve Random Forest algoritmaları kullanılmıştır. Söz konusu algoritmalar, öneri sistemlerinin doğruluk, katalog kapsamı, yenilikçilik, çeşitlilik ve kişiselleştirme düzeylerini ölçmeye yönelik beş temel metrik üzerinden karşılaştırılmıştır. Bu bölümde, her bir algoritmanın bu metrikler üzerinden sunduğu performans detaylı olarak tartışılmış, ardından genel bir karşılaştırma sunulmuştur. Son olarak, bu analizlerden çıkarılabilecek stratejik sonuçlara yer verilmiştir.

### 6.1. Random-Based Model Üzerinden Değerlendirme

Rastgele öneriler sunan Random-based model, kullanıcı geçmişi, ürün ilişkileri veya davranışsal veri olmaksızın sistemin rastgele seçimle ürün önerdiği bir yaklaşımdır. Bu nedenle önerilerin doğruluğu oldukça düşüktür ( $MAP = 0.03$ ). Kullanıcılar genellikle ilgilenmeyecekleri ürünlerle karşılaştıklarından, öneri sisteminin faydası sınırlı kalmaktadır. Buna karşın, sistem her kullanıcıya farklı ürünler sunduğu için kişiselleştirme ( $MPS = 0.99$ ) oldukça yüksek gözükmemektedir. Ancak bu metrik yanıltıcı olabilir; çünkü burada kişiselleştirme, kullanıcının profilinden değil, önerilerin çeşitliliğinden kaynaklanmaktadır. Yenilikçilik ( $MNS = 6.89$ ) bakımından oldukça iyi performans gösteren Random-based model, daha önce sunulmayan ürünleri önerme eğilimindedir. Fakat bu önerilerin kullanıcı için faydalı ya da ilgili olması garanti edilemez. Çeşitlilik ( $MDS = 0.23$ ) açısından düşük performans, sistemin geniş ürün yelpazesi içinden seçim yapsa bile birbirine benzer ürünleri önermesiyle açıklanabilir. Katalog kapsamı ( $CC = 0.40$ ) ise orta seviyededir; sistem geniş bir katalogtan seçse de önerilerin anlamlılığı düşüktür.

## 6.2. Popularity-Based Model Üzerinden Değerlendirme

Bu model, tüm kullanıcılara en popüler ürünleri önerir. Bu yaklaşım, önerilerin doğrudan kullanıcıya özel olmaması nedeniyle doğruluk ( $MAP = 0.00$ ) açısından düşük bir performans sergiler. Ancak, en popüler ürünler geniş kitleler tarafından beğenildiği için genel kullanıcı memnuniyeti orta düzeyde olabilir. Yenilikçilik ( $MNS = 8.78$ ) açısından bu model en yüksek skoru elde etmiştir. Çünkü kullanıcılar çoğunlukla popüler ürünleri daha önce görmemiş olabilirler ve bu sayede yeni ürünler keşfedebilirler. Fakat bu durum, sistemin katalog kapsamını ( $CC = 0.01$ ) kısıtlar; çünkü sistem yalnızca sınırlı sayıda en popüler ürünü önerdiğinden diğer ürünler sistem dışında kalır. Çeşitlilik ( $MDS = 0.53$ ) orta düzeydedir. Kişiselleştirme ( $MPS = 0.65$ ) ise bu model için tatmin edici değildir çünkü tüm kullanıcılara aynı ürünler önerilir.

## 6.3. Content-Based Filtering (İçerik Tabanlı Filtreleme)

İçerik tabanlı filtreleme, kullanıcıların geçmiş tercihlerine benzer özelliklere sahip ürünleri önerir. Bu model, kullanıcının daha önceki etkileşimlerine bağlı olarak önerilerde bulunduğu için kişiselleştirme ( $MPS = 0.99$ ) açısından en yüksek başarıyı göstermektedir. Ancak,  $MAP$  değerinin  $0.00$  çıkması, önerilerin kullanıcının anlık ihtiyaçlarını karşılamadığına veya yeterince ilgili ürün öneremediğine işaret eder. Yenilikçilik ( $MNS = 0.49$ ) ve çeşitlilik ( $MDS = 0.33$ ) orta düzeydedir; sistem kullanıcıya benzer içerikleri önerdiği için kullanıcı yeni ürünlerle karşılaşmakta zorlanabilir.

## 6.4. Item-Based Collaborative Filtering (IBCF)

Item-based yaklaşım, ürünler arasındaki benzerlikleri dikkate alarak kullanıcıya önerilerde bulunur. Bu model doğruluk ( $MAP = 0.42$ ) açısından en başarılı modeldir. Kullanıcının beğendiği ürünlere benzeyen ürünlerin önerilmesi, ilgi çekici ve anlamlı sonuçlar üretmektedir. Modelin çeşitlilik ( $MDS = 0.75$ ) skoru da yüksektir, çünkü öneriler farklı kategorilerden ürünleri içerebilmektedir. Buna rağmen, katalog kapsamı ( $CC = 0.23$ ) ve kişiselleştirme ( $MPS = 0.23$ ) nispeten düşüktür. Bu modelin temel eksikliği, kullanıcıların kişisel tercihlerinden ziyade ürün benzerliğine odaklanmasıdır. Dolayısıyla, sistem bazı kullanıcıları tatmin etse de geniş ölçekte yeterince kişiselleştirilememiş öneriler sunar.

## 6.5. Hybrid Model (Hibrit Yaklaşım)

Hibrit model, içerik tabanlı ve işbirlikçi filtreleme yöntemlerini birleştirerek daha dengeli sonuçlar elde etmeyi hedefler. Ancak bu çalışmada kullanılan hibrit model, MAP (0.00) ve CC (0.01) gibi metriklerde düşük değerler göstermiştir. Sadece kişiselleştirme metriği (MPS = 0.63) açısından orta seviyede bir performans elde edilmiştir. Bu durum, kullanılan hibrit modelin yapılandırılmasında optimizasyon eksikliklerinin ve zayıf öğrenme mekanizmalarının etkili olduğunu göstermektedir.

## 6.6. RNN (Recurrent Neural Networks- Tekrarlayan Sinir Ağları)

RNN, kullanıcının zaman serisine bağlı olarak etkileşim verilerini analiz eder ve dinamik öneriler üretir. Çeşitlilik (MDS = 1.00) açısından en yüksek değeri sunan modeldir. Bu sonuç, sistemin çok çeşitli ürünleri etkili bir şekilde önerdiğini göstermektedir. Ancak, MAP (0.00) ve MPS (0.03) değerlerinin düşüklüğü, sistemin doğru ve kişiselleştirilmiş öneriler üretme konusunda başarısız olduğunu göstermektedir. Bu model, zaman içinde kullanıcı tercihlerinin değişimini takip edebilse de eğitim verisinin güncelliği, modelin hiper parametrelerinin ayarlanması gibi konularda yetersiz kalınmış olabilir. Bu da modelin potansiyelini tam anlamıyla yansıtamamasına neden olmuştur.

## 6.7. Random Forest Algoritması

Makine öğrenmesine dayalı Random Forest algoritması, geçmiş verilerden öğrenerek önerilerde bulunur. MNS (3.89) ile orta seviyede yenilikçilik sunarken, doğruluk (MAP = 0.33) ve kişiselleştirme (MPS = 0.33) metriklerinde düşük performans göstermektedir. Bu model, bazı durumlarda başarılı tahminler sunsa da genellikle ilgi çekici olmayan, genel geçer öneriler üretebilmektedir. Özellikle karar ağacı tabanlı modellerin öneri sistemlerinde kullanılabilirliği yüksek olmasına rağmen, çok sayıda karar ağacının birleşiminden oluşan Random Forest modeli öneri bağlamında yeterli hassasiyeti gösterememektedir.

## 6.8. Akademik ve Bilimsel Katkılar

Bu çalışma, e-ticaret tabanlı öneri sistemlerinin çok boyutlu değerlendirilmesine yönelik kapsamlı bir yaklaşım sunarak literatüre önemli katkılar sağlamaktadır. Bu çalışmada öneri algoritmaları beş temel performans metriği ile değerlendirilmiştir: doğruluk (MAP), kişiselleştirme (MPS), yenilik (MNS), çeşitlilik (MDS) ve katalog kapsamı (CC). Bu yönüyle çalışma, öneri sistemlerini çok boyutlu performans çerçevesinde ele alan az sayıdaki araştırmadan biri olma özelliği taşımaktadır. Böylece öneri sistemlerinin yalnızca “doğru” değil, aynı zamanda “kişisel”, “yenilikçi” ve “çeşitli” olup olmadıkları da sistematik olarak incelenmiş ve somut verilerle ortaya konulmuştur.

Bir diğer akademik katkı, klasik yöntemler (Item-Based, Content-Based, Popularity, Random) ile makine öğrenmesi temelli algoritmalar (Random Forest) ve derin öğrenme modelleri (RNN) arasında karşılaştırmalı bir değerlendirme yapılmış olmasıdır. Bu karşılaştırma, algoritmaların yalnızca başarı düzeylerini değil, aynı zamanda hangi metriklerde hangi yöntemlerin öne çıktığını da ortaya koyarak farklı yöntemlerin avantaj-dezavantaj profilini ayrıntılı biçimde tanımlamıştır. Özellikle her bir algoritmanın güçlü ve zayıf yönlerinin metriklerle eşleştirilmiş biçimde raporlanması, ileride yapılacak hibrit öneri sistemi tasarımları için somut bir temel oluşturacaktır.

## KAYNAKLAR

- Adomavicius G, Tuzhilin A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*. 2005; 17(6):734–749.
- Anbazhagan M, Arock M. A study and analysis of collaborative filtering algorithms for recommender systems. *Int J Comput Technol Appl (IJCTA)*. 2016; 9(27):127–136.
- Artukarslan M, Alptekin SE. Collaborative filtering based recommender system design for e-commerce: A case study. *The Fourteenth Int Conf on Internet and Web Applications and Services (ICIW)*. 2019.
- Atkinson L. *Beginning PHP and MySQL: From novice to professional*. 4th ed. Berkeley, CA: Apress; 2009.
- Betru BT, Onana CA, Batchakui B. Deep learning methods on recommender system: A survey of state-of-the-art. *Int J Comput Appl*. 2017; 162(10):17–25.
- Bitirim Y. A content-based product recommendation approach. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*. 2022; 37(1):119–128.
- Breese JS, Heckerman D, Kadie C. Empirical analysis of predictive algorithms for collaborative filtering. *Proc of the 14th Conf on Uncertainty in Artificial Intelligence (UAI)*. 1998; 14:43–52.
- Breiman L. Random forests. *Machine Learning*. 2001; 45(1):5–32.
- Burke R. Hybrid recommender systems: Survey and experiments. *User Model User-Adap Interact*. 2002; 12(4):331–370.
- Chollet F. *Deep learning with Python*. 2nd ed. Shelter Island, NY: Manning Publications; 2021.
- Cremonesi P, Koren Y, Turrin R. Performance of recommender algorithms on top-N recommendation tasks. *Proc of the 4th ACM Conf on Recommender Systems (RecSys'10)*. 2010:39–46.
- He X, Liu Q, Jung S. The impact of recommendation system on user satisfaction: A moderated mediation approach. *ResearchGate*. 2023.
- Kotsiantis SB, Kanellopoulos D, Pintelas PE. Data preprocessing for supervised learning. *Int J Comput Sci*. 2006; 1(2):111–117.
- Le H. *Building and evaluating recommender systems [Bachelor's thesis]*. Helsinki: Metropolia University of Applied Sciences; 2019.
- LeCun Y, Goodfellow I, Courville A. *Deep learning*. Cambridge, MA: MIT Press; 2016.

- Legito L, Wattimena FY, Rofi'i YU, Munawir M. E-commerce product recommendation system using case-based reasoning (CBR) and K-means clustering. *Int J Softw Eng Comput Sci (IJSECS)*. 2023; 3(2):162–173.
- Morales Murillo VG, Pinto Avendaño DE, Rojas López F, Gonzales Calleros JM. (2022) A systematic literature review on the hybrid approaches for recommender systems. 2022.
- Özkılıç A. E-Ticaret sitelerine öneri sisteminin uygulanması [Yüksek Lisans Tezi]. Bursa: Bursa Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü; 2022.
- Padhy N, Suman S, Priyadarshini TS, Mallick S. A recommendation system for e-commerce products using collaborative filtering approaches. *Engineering Proceedings*. 2024; 67:50.
- Phalle TS, Bhushan S. Content-based filtering and collaborative filtering: A comparative study. *J Adv Zool*. 2024; 45(S-4):96–100.
- R. CK, Srikantaiah KC, VKR. Personalized recommendation systems (PRES): A comprehensive study and research issues. *Int J Mod Educ Comput Sci*. 2018; 10(10).
- Ricci F, Rokach L, Shapira B, Kantor PB, eds. *Recommender systems handbook*. New York: Springer; 2011.
- Salton G, McGill MJ. *Introduction to modern information retrieval*. New York: McGraw-Hill; 1983.
- Saini K, Singh A. Hybrid recommender system for e-commerce: A comprehensive review and future directions. *J Harbin Eng Univ*. 2023.
- Srifi M, Oussous A, Lahcen AA, Mouline S. Recommender systems based on collaborative filtering using review texts—A survey. *Information*. 2020; 11(6):1–21.
- Vozalis E, Margaritis KG. *Analysis of recommender systems' algorithms*. Thessaloniki: University of Macedonia; 2003.

## **EKLER**

### **Ek 1. Etik Kurul Onayı**

