



T.C.

Ardahan Üniversitesi

Lisansüstü Eğitim Enstitüsü

İleri Teknolojiler Ana Bilim Dalı

İleri Teknolojiler Bilim Dalı

ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİNDE POPÜLARİTE YANLILIĞINI YÖNETME

Nilüfer BALLI

Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA

Yüksek Lisans Tezi

Ardahan, 2025

ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİNDE POPÜLARİTE
YANLILIĞINI YÖNETME

Nilüfer BALLI

Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA

Ardahan Üniversitesi Lisansüstü Eğitim Enstitüsü
İleri Teknolojiler Ana Bilim Dalı
İleri Teknolojiler Bilim Dalı

Yüksek Lisans Tezi

Ardahan, 2025

KABUL VE ONAY

Nilüfer Ballı tarafından hazırlanan “Çok Ölçütlü Öneri Sistemlerinde Popülarite Yanlılığını Yönetme” başlıklı bu çalışma, 29.08.2025 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Dr. Öğr. Üyesi Mehmet KURUCAN (Başkan)

Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA (Danışman)

Dr. Öğr. Üyesi Erhan TURAN

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından kabul edilmiştir.

Prof. Dr. Mustafa ŞENEL
Enstitü Müdürü

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Ardahan Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinleri yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / Ardahan Üniversitesi Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. ⁽¹⁾
- Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ay ertelenmiştir. ⁽²⁾
- Tezimle ilgili gizlilik kararı verilmiştir. ⁽³⁾

29/08/2025

Nilüfer BALLI

“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”

- (1) Madde 6. 1. Lisansüstü tezle ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.
- (2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulunun** gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.
- (3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, **tezin yapıldığı kurum** tarafından verilir *. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, **ilgili kurum ve kuruluşun önerisi** ile **enstitü** veya **fakültenin** uygun görüşü üzerine **üniversite yönetim kurulu** tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.

Madde 7.2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

* **Tez danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** tarafından karar verilir.

ETİK BEYAN

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, Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA danışmanlığında tarafımdan üretildiğini ve Ardahan Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Yönergesine göre yazıldığını beyan ederim.

Tuğba TÜRKOĞLU KAYA

ÖN SÖZ

Bu yolculuk boyunca yanımda olan, sabırları ve sevgileriyle her zaman bana güç veren aileme en derin minnetimi sunarım. Onların inancı ve desteği, en zor anlarda bile bana yol gösteren bir ışık olmuştur.

Özellikle de bilgeliği, anlayışı ve engin sabrıyla bu çalışmaya yön veren kıymetli danışman hocam Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA' ya gönülden teşekkür ederim. Sadece akademik anlamda değil, aynı zamanda insani yaklaşımıyla da bana örnek olmuş; her aşamada cesaret verici bir rehberlik sağlamıştır. Bu tez, onun değerli katkılarıyla şekillenmiş ve tamamlanabilmiştir.

Tüm kalbimle teşekkür ederim.

Ardahan - 2025

Nilüfer BALLI

ÖZET

BALLI Nilüfer. *Çok Ölçütlü Öneri Sistemlerinde Popülerite Yanlılığını Yönetme*, Yüksek Lisans, Ardahan, 2025.

Çok ölçütlü öneri sistemleri, kullanıcıların ürün veya hizmetleri birden fazla kriter üzerinden değerlendirmesine imkân tanıyarak daha kişiselleştirilmiş ve kapsamlı öneriler sunmayı hedeflemektedir. Ancak bu sistemlerde karşılaşılan temel sorunlardan biri popülerite yanlılığıdır. Popülerite yanlılığı, kolektif eğilimlerin bireysel tercihler üzerinde baskın hale gelmesiyle ortaya çıkar; bu durum, öneri listelerinde popüler içeriklerin aşırı temsil edilmesine ve daha az bilinen ancak uygun alternatiflerin göz ardı edilmesine neden olur. Bu bağlamda, bu tez kapsamında mevcut yöntemleri incelemenin yanı sıra popülerite yanlılığını azaltmayı hedefleyen iki yenilikçi yaklaşım önermektedir: RelPref ve PriRelPref. Bu yöntemler, kullanıcı-öge etkileşimlerini daha hassas ve dengeli şekilde modelleyerek, kullanıcıların kriter önceliklerini dikkate alır. RelPref, her kriter için kullanıcı puanlarını dinamik olarak değerlendirirken; PriRelPref, kullanıcıya özgü kriter önceliklendirmesini dahil ederek yanlılığı daha etkin biçimde azaltır. Böylece, kullanıcıların en çok önem verdiği kriterlerle öğelerin en iyi performans gösterdiği kriterler arasında uyum sağlanır ve daha dengeli, çeşitli ve kişiselleştirilmiş öneriler sunulur. Önerilen yöntemler, farklı kullanıcı puanlama davranışlarını temsil eden üç farklı veri setinde (YM10, YM20 ve TA) kapsamlı şekilde test edilmiştir. Çok boyutlu ölçütler (örneğin, uzun kuyrukta öge görünürlüğü ve çeşitlilik için Gini indeksi) RelPref ve PriRelPref'in hem kullanıcı memnuniyetini hem de sistem düzeyinde keşfedilebilirlik ve adil içerik dağılımı gibi nitelikleri anlamlı ölçüde geliştirdiğini göstermiştir. Özellikle, PriRelPref'in kriter önceliklendirme özelliği, popülerite yanlılığının yönetiminde daha etkin bir çözüm sunmaktadır. Sonuç olarak, bu çalışma çok ölçütlü öneri sistemlerinde popülerite yanlılığını sistematik biçimde ele alan ilk çalışmalardan biri olup, literatürdeki önemli bir boşluğu doldurmakta ve gelecekteki araştırmalar için sağlam bir teorik ve metodolojik temel oluşturmaktadır.

Anahtar Sözcükler:

Çok ölçütlü öneri sistemleri, Popülerite yanlılığı, Kullanıcı önceliği, Tercih modeli, Eğilim

ABSTRACT

BALLI Nilüfer. *Managing Popularity Bias in Multi-Criteria Recommender Systems*, Master's Thesis, Ardahan, 2025

Multi-criteria recommendation systems aim to provide more personalized and comprehensive recommendations by allowing users to evaluate products or services based on multiple criteria. However, one of the fundamental problems encountered in these systems is popularity bias. Popularity bias occurs when collective tendencies become dominant over individual preferences; this situation leads to over-representation of popular content in recommendation lists and the neglect of less-known but suitable alternatives. In this context, this thesis proposes two innovative approaches, RelPref and PriRelPref, aimed at reducing popularity bias, in addition to examining existing methods. These methods model user-item interactions more sensitively and balancedly, taking into account users' criterion priorities. While RelPref dynamically evaluates user scores for each criterion, PriRelPref more effectively reduces bias by incorporating user-specific criterion prioritization. Thus, harmony is achieved between the criteria that users value most and the criteria where items perform best, providing more balanced, diverse, and personalized recommendations. The proposed methods have been comprehensively tested on three different datasets (YM10, YM20, and TA) representing different user rating behaviors. Multi-dimensional metrics (such as Gini index for long-tail item visibility and diversity) have shown that RelPref and PriRelPref significantly improve both user satisfaction and system-level qualities such as discoverability and fair content distribution. Particularly, PriRelPref's criterion prioritization feature provides a more effective solution in managing popularity bias.

In conclusion, this study is one of the first studies to systematically address popularity bias in multi-criteria recommendation systems, filling an important gap in the literature and establishing a solid theoretical and methodological foundation for future research.

Keywords:

Multi-criteria recommender systems, Popularity bias, User priority, Preference score, Tendency

İÇİNDEKİLER

KABUL VE ONAY	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI	ii
ETİK BEYAN	iv
ÖN SÖZ	v
ÖZET	vi
ABSTRACT	vii
İÇİNDEKİLER	viii
SİMGELER VE KISALTMALAR DİZİNİ	xi
TABLolar DİZİNİ	xiii
ŞEKİLLER DİZİNİ	xiv
GİRİŞ	1
1. BÖLÜM	4
ÖNERİ SİSTEMLERİ	4
1.1. ÖNERİ SİSTEMLERİ TÜRLERİ	5
1.1.1. İçerik Tabanlı Filtreleme	5
1.1.2. İşbirlikçi Filtreleme	6
1.1.3. Hibrit Sistemler	6
1.2. ÖNERİ SİSTEMLERİNİN ÖZELLİKLERİ	6
1.2.1. Kişiselleştirme	7
1.2.2. Kullanıcı Etkileşimi ve Geri Bildirim	7
1.2.3. Çeşitlilik ve Yenilik	8
1.3. ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİ	9
1.4. ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİNDE	
KARŞILAŞILAN PROBLEMLER	11
1.4.1. Veri Seyrekliği	11
1.4.2. Soğuk Başlangıç Problemi	11
1.5. Popülarite Yanlılığı	12
1.5.1.1. Çok Ölçütlü Öneri Sistemlerinde Popülarite Yanlılığı	12
1.6. TEZİN AMACI VE KATKILARI	14
1.7. TEZ ORGANİZASYONU	16

2. BÖLÜM	19
LİTERATÜR TARAMASI	19
3. BÖLÜM	23
GENEL BİLGİLER.....	23
3.1. KULLANICI POPÜLERLİK EĞİLİMİ BELİRLEME	
YÖNTEMLERİ	23
3.1.1. Popüler Ürünlerin Oranı Yaklaşımı	24
3.1.2. Derecelendirilen Ürünlerin Ortalama Popülerliği.....	24
3.1.3. Ortalamadan Daha İyi Yaklaşımı.....	25
3.2. POPÜLARİTE YANLILIĞINI AZALTAN ALGORİTMALAR	27
3.2.1. Dinamik Kullanıcı Odaklı Yeniden Sıralama Algoritması	27
3.2.2. Arttırılmış Fayda Üretimi Algoritması.....	28
3.2.3. Çarpımsal Fayda Öğrenme Algoritması.....	29
3.2.4. Popülerlik Farkındalıklı Ürün Ağırlıklandırma Algoritması.....	29
4. BÖLÜM	31
ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİNDE POPÜLARİTE	
YANLILIĞINI AZALTMA	31
4.1. GİRİŞ	31
4.2. GÖRECELİ TERCİH MODELİ	31
4.3. KRİTER- DUYARLI GÖRECELİ TERCİH MODELİ	35
5. BÖLÜM	37
DENEYLER.....	37
5.1. TEST METODOLOJİSİ	37
5.2. VERİ SETİ.....	38
5.3. DEĞERLENDİRME METRİKLERİ.....	40
5.3.1. Doğruluk Metrikleri	40
5.3.1.1. Kesinlik	40
5.3.1.2. Geri Çağırma	41
5.3.1.3. F1- Ölçütü	42
5.3.2. Doğruluk Ötesi Metrikler	42
5.3.2.1. Yenilik	42
5.3.2.2. Ortalama Uzun Kuyruk Popülerliği.....	43

5.3.2.3. Uzun Kuyruk Kapsamı	44
5.3.2.4. Gini Katsayısı	44
6. BÖLÜM	45
DENEYSEL SONUÇLAR.....	45
SONUÇ.....	65
KAYNAKÇA.....	70
EKLER.....	76
EK 1. ORJİNALLİK RAPORU FORMU	76
EK 2. ETİK KURUL izni YA DA ETİK KURUL MUAFİYET FORMU.....	77
ÖZ GEÇMİŞ	78



SİMGELER VE KISALTMALAR DİZİNİ

ÖS	Öneri Sistemleri
İF	İşbirlikçi Filtreleme
ÇÖÖS	Çok Ölçütlü Öneri Sistemleri
RelPref	Göreceli Tercih Modeli
PriRelPref	Kriter Duyarlı Göreceli Tercih Modeli
RPI	Popüler Ürünlerin Oranı yöntemi
APRI	Derecelendirilen Ürünlerin Ortalama Popülerliği
BTA	Ortalamada Daha İyi Yaklaşımı
DUoR	Dinamik Kullanıcı Odaklı Yeniden Sıralama Algoritması
Aug	Arttırılmış Fayda Üretimi Algoritması
Mul	Çarpımsal Fayda Öğrenme Algoritması
Pa_w	Popülerlik Duyarlı Öğe Ağırlıklandırma Algoritması
λ	lambda
U	Kullanıcı
i	Değerlendirilmiş Ürün
P_{1×n}	Tahmini Puan Matrisi
C_{1×m}	Aday Ürün Kümesi
PopRatio_u	Popülerlik Oranı
RecList	Öneri Listesi
Pref_{RecList}	Öneri Listesinin Popülerlik Derecesi
Pref(r_{u,i})	Kullanıcıya Özel Tercih Skoru
α	Alfa
β	Beta
TopN	Öneri Listesinin Boyutu
MLR	Çoklu Doğrusal Regresyon
U_{Test}	Test Kullanıcısı
M	Üst Öğe
C	Aday Öğe Seti
N	Nihai Öneri Listesinin Boyutu
YM	Yahoo! Movie

TA	TripAdvisor
APLT	Ortalama Uzun Kuyruk Popülerliği
LTC	Uzun Kuyruk Kapsamı



TABLÖLAR DİZİNİ

Tablo 1. RelPref algoritmasının adımları ve kullanılan yöntemler	33
Tablo 2. YM ve TA veri setine ait bilgiler	39



ŞEKİLLER DİZİNİ

Şekil 1. Tek ölçütlü film öneri sistemi.....	9
Şekil 2. RelPref'in temel yapısı	34
Şekil 3. PriRelPref'in temel yapısı.....	36
Şekil 4. TA veri seti üzerinde BTA_{RPI} analiz sonuçları.....	46
Şekil 5. TA veri seti üzerinde BTA_{APRI} analiz sonuçları	48
Şekil 6. TA veri seti üzerinde $APRI$ analiz sonuçları	49
Şekil 7. TA veri seti üzerinde RPI analiz sonuçları	50
Şekil 8. YM20 veri seti üzerinde BTA_{RPI} analiz sonuçları	51
Şekil 9. YM20 veri seti üzerinde BTA_{APRI} analiz sonuçları	53
Şekil 10. YM20 veri seti üzerinde $APRI$ analiz sonuçları.....	55
Şekil 11. YM20 veri seti üzerinde RPI analiz sonuçları	56
Şekil 12. YM10 veri seti Üzerinde BTA_{RPI} analiz sonuçları	58
Şekil 13. YM10 veri seti Üzerinde BTA_{APRI} analiz sonuçları.....	60
Şekil 15. YM10 veri seti üzerinde $ARPI$ analiz sonuçları.....	61
Şekil 14. YM10 veri seti üzerinde RPI analiz sonuçları	63

GİRİŞ

Günümüzde dijital teknolojilerdeki hızlı gelişim ve çevrimiçi platformların günlük yaşamın ayrılmaz bir parçası hâline gelmesi, kullanıcıların karşısına her zamankinden daha fazla ürün ve hizmet seçeneği çıkmasına neden olmuştur (Goldberg, Nichols, Oki ve Terry, 1992). Bu artan seçenek çeşitliliği, bireylerin farklı alanlarda veya önem verdikleri alanlarda karar verme süreçlerini daha karmaşık ve zaman açısından zorlayıcı bir hâle getirmiştir (Sarwar, Karypis, Konstan ve Riedl, 2001). Örneğin, bir dijital platformda binlerce film arasından kişisel tercihlere uygun içerik seçmek ya da seyahat planı yaparken yüzlerce otel arasından ideal olanı belirlemek, kullanıcılar için günlük hayatta karşılaştıkları sorunların yanında ciddi bir bilişsel yük oluşturabilmektedir (Pazzani ve Billsus, 2007). Bu bağlamda, öneri sistemleri (ÖS) hem bilgi fazlalığını yönetmek hem de kullanıcıların karar verme süreçlerini kolaylaştırarak günlük hayatlarında zamandan tasarruf sağlamalarına olanak tanımak ve tercihlerinden memnun kalmaları amacıyla dijital platformlarda kritik bir rol oynamaktadır (Burke, 2002).

ÖS'nin temel işlevi, kullanıcıların önceki davranışlarını ve açık tercihlerini analiz ederek, ilgi duyabilecekleri içerikleri tahmin etmektir. Geleneksel öneri sistemleri, genellikle kullanıcıların ürünlere verdikleri tek boyutlu puanlara dayanarak benzer kullanıcı ve ürün grupları oluşturur ve bu benzerlikler üzerinden tavsiyelerde bulunur (Adomavicius ve Kwon, 2012) ancak bu yöntem hem içeriklerin çok boyutlu niteliklerini hem de kullanıcıların farklılaşan tercih kalıplarını yeterince temsil edememektedir (Lakiotaki, Matsatsinis ve Tsoukiàs, 2011). Örneğin, bir kullanıcı bir filmin hikâyesine ve oyunculuk kalitesine önem verirken, bir başkası görsel efektleri ya da yönetmenin tarzını daha öncelikli görebilir. Benzer şekilde, otel seçimlerinde bazı kullanıcılar konum kriterini esas alırken, diğerleri temizlik, müşteri hizmetleri veya kahvaltı kalitesine daha fazla önem verebilmektedir.

Bu çeşitliliği daha iyi yansıtabilmek amacıyla çok ölçütlü öneri sistemleri (ÇÖÖS) geliştirilmiştir. Bu sistemler, kullanıcıların ürün ve hizmetleri yalnızca genel bir puan üzerinden değil, birden fazla kritere dayalı olarak değerlendirmesine olanak tanımaktadır (Hdioud, Frikh ve Ouhbi, 2013). Her bir kriter üzerinden alınan geri bildirimler ayrı ayrı analiz edilerek, sistemin hem genel memnuniyeti hem de bireysel öncelikleri daha hassas

bir şekilde yansıtması sağlanır. Böylece yalnızca yüksek genel puana sahip içerikler değil, kullanıcıların önem verdiği kriterlerde öne çıkan ancak daha düşük toplam puana sahip olan alternatifler de öneri listelerinde görünür hâle gelir (Lee, Sun ve Lebanon, 2012).

Her ne kadar çok ölçütlü öneri sistemleri kişiselleştirilmiş öneriler sunma konusunda başarılı sonuçlar üretse de, bu sistemler de popülerite yanlılığı problemiyle başa çıkma konusunda önemli zorluklarla karşı karşıyadır. Bu sistemlerde, popüler öğelerin aşırı önerilme eğilimi, daha az bilinen ancak potansiyel olarak kullanıcıya uygun alternatiflerin gölgede kalmasına neden olabilir; bu da çeşitliliği sınırlar ve önerilerin genel kalitesini düşürürken kullanıcı memnuniyetini azaltmaktadır. Popülerite yanlılığı, yalnızca uzun kuyruktaki öğelerin görünürlüğü azaltmakla kalmaz, aynı zamanda kullanıcıların puanlama alışkanlıkları ve öncelikleri önemli ölçüde farklılık gösterdiğinde, sistemin bireysel tercihlere hitap etme kapasitesini de zayıflatır.

Bu tez çalışmasında, çok ölçütlü öneri sistemlerinde popülerite yanlılığının etkileri kapsamlı biçimde incelenmiş ve bu sorunu azaltmaya yönelik iki yeni yöntem geliştirilmiştir. Geliştirilen RelPref ve PriRelPref yaklaşımları, öneri sistemlerinde kullanıcıların yalnızca verdikleri puanları değil, aynı zamanda puanlama alışkanlıklarını ve hangi kriterlere daha fazla önem verdiklerini de dikkate alarak öneri sürecini daha hassas ve kişiselleştirilmiş hale getirmeyi amaçlamaktadır. RelPref yöntemi, kullanıcıların farklı kriterlerdeki değerlendirmelerini dinamik olarak analiz ederek, öneri listelerinde popüler içeriklerin aşırı temsil edilmesini önlemeye ve daha adil bir dağılım sağlamaya odaklanır. PriRelPref ise, her kullanıcının hangi kriterleri daha öncelikli gördüğünü belirleyerek, önerileri bu bireysel önceliklere göre şekillendirir ve böylece öneri listesinin kullanıcının gerçek beklentileriyle daha uyumlu olmasını sağlar. Her iki yöntem de, kullanıcıların çeşitli puanlama davranışlarını yansıtan farklı veri setlerinde kapsamlı şekilde test edilmiş; elde edilen sonuçlar, öneri listelerinde çeşitliliğin ve az bilinen içeriklerin görünürlüğü'nün arttığını, kullanıcı memnuniyetinin yükseldiğini ve sistemin daha adil ve dengeli öneriler sunabildiğini göstermiştir. Ayrıca, mevcut yöntemlerle yapılan karşılaştırmalar, geliştirilen yaklaşımların popülerite yanlılığını azaltmada ve kişiselleştirilmiş ve çeşitli öneriler sunmada önemli avantajlar sağladığını ortaya koymuştur.

Tez yedi bölümden oluşmaktadır. Birinci bölümde öneri sistemleri açıklanmakta; ikinci bölümde ilgili literatür ele alınmakta; üçüncü bölümde literatürde kullanılan ön çalışmalar sunulmaktadır. Dördüncü bölüm önerilen yöntemlerin ayrıntılarını içermekte;

beşinci bölümde deneysel çalışmalar aktarılmakta; altıncı bölümde bu deneylerin sonuçları analiz edilmekte; yedinci ve son bölümde ise genel çıkarımlar ve tartışmalar yer almaktadır.



1. BÖLÜM

ÖNERİ SİSTEMLERİ

Günümüzde dijital platformlar, kullanıcıların ilgi alanlarına ve ihtiyaçlarına uygun ürün veya hizmetleri kısa sürede keşfetmelerini sağlamak amacıyla ÖS yoğun biçimde yararlanmaktadır. ÖS, temel olarak büyük veri havuzları içerisinde her bir kullanıcıya en uygun içerik, ürün veya hizmeti sunmayı hedefleyen algoritmalarlardır. Bu sistemler, kullanıcıların sistemdeki geçmiş hareketlerini, beğenilerini, yorumlarını, ziyaret ettikleri ürünleri ve benzeri davranışsal verileri analiz ederek, kullanıcıya özgü öneriler üretmektedirler. Örneğin, Netflix izleyicilerinin daha önce izledikleri dizi ve filmleri dikkate alarak yeni içerikler önerirken; Amazon, kullanıcıların alışveriş geçmişi ve arama tercihlerini analiz ederek ilgi duyabilecekleri ürünleri ön plana çıkarmaktadır. Benzer şekilde, Spotify kullanıcılarının dinleme alışkanlıklarını inceleyerek yeni ve kişiselleştirilmiş müzik önerileri sunmaktadır (Gomez-Urbe ve Hunt, 2015).

ÖS, dijital platformlarda kullanıcıların karşılaştığı ürün ve içerik fazlalığını yöneterek kullanıcının çok fazla çeşit içerisinde kaybolmasını önleyerek, tercih süreçlerini kolaylaştırmak ve kullanıcıların platformda geçirdiği zamanı daha verimli hale getirmek için önemli bir rol üstlenmektedir. Bu sistemler, yalnızca eğlence ve alışveriş sitelerinde değil, sosyal medya uygulamalarında yeni arkadaş veya ilgilendiği tarzda içerik önerileri sunmak, profesyonel ağlarda iş ve bağlantı tavsiyeleri oluşturmak gibi çok çeşitli alanlarda yaygın olarak kullanılmaktadır. Kullanıcıların ilgi alanlarını ve geçmişteki davranışlarını analiz eden öneri sistemleri, kişiye has içerik sunarak kullanıcıların aradıklarına daha hızlı ve zahmetsizce ulaşmalarını sağlamaktadır.

Kullanıcılar dışında platformlar açısından bakıldığında ise ÖS, kullanıcı memnuniyetini ve sadakatini artırmanın ötesinde, ticari başarıya da önemli katkılar sunmaktadır. Kullanıcılar, önerilen ürün veya hizmetlerden memnun kaldıklarında, bu deneyimlerini çevreleriyle paylaşarak platformun yeni kullanıcılar kazanmasına yardımcı olmaktadır ayrıca, kişiselleştirilmiş öneriler sayesinde kullanıcıların sistemi sık sık ziyaret etmesi kullanıcıların platformla fazla etkileşimde bulunması sağlanır. Bu durum, öncelikle elde edilen doğru ve tutarlı verilerin yeni öneriler üretmek için kullanılmasında daha sonra da platformun gelirlerinin artmasına, marka değerinin güçlenmesine ve rekabet avantajı elde

etmesine olanak tanımaktadır. Sonuç olarak, öneri sistemleri hem kullanıcılar hem de platformlar için karşılıklı fayda yaratan, dijital ekosistemin vazgeçilmez bir parçası haline gelmiştir (Ricci, Shapira ve Rokach, 2015).

Birinci bölümde, öncelikle ÖS içerik tabanlı, işbirlikçi ve hibrit tabanlı filtreleme olmak üzere başlıca ÖS türleri detaylandırılmaktadır. Bölümün devamında, çok kriterli öneri sistemlerinin yapısı ve işleyişi açıklanmakta; kişiselleştirme, kullanıcı etkileşimi, çeşitlilik ve yenilik gibi öneri sistemlerinin temel özellikleri üzerinde durulmaktadır. Ayrıca, veri seyrekliği, soğuk başlangıç problemi ve popülerite yanlılığı gibi öneri sistemlerinde karşılaşılan başlıca zorluklar tartışılmakta ÇÖÖS’de popülerite yanlılığına özel olarak değinilmektedir. Son olarak, bu tez çalışmasının amacı, katkıları ve genel organizasyonu özetlenmektedir.

1.1. ÖNERİ SİSTEMLERİ TÜRLERİ

Öneri sistemleri, kullanıcıların ilgi alanlarına hitap etmek için geçmişteki tercihlerini kullanarak kişiselleştirilmiş öneriler sunmak amacıyla çeşitli yöntemler kullanmaktadır. Bu yöntemler genel olarak üç ana başlık altında toplanmaktadır: (i) İçerik Tabanlı Filtreleme (ii) İşbirlikçi Filtreleme ve (iii) Hibrit Sistemler (Adomavicius ve Tuzhilin, 2005). Bu temel öneri sistemi türlerinin detayları, sonraki alt başlıklarda ele alınacaktır.

1.1.1. İçerik Tabanlı Filtreleme

İçerik tabanlı öneri sistemleri, kullanıcının geçmişte ilgi gösterdiği ürünlerin temel özelliklerini analiz ederek kişiselleştirilmiş öneriler sunmayı amaçlar. Bu yaklaşımda, sistem öncelikle kullanıcının beğendiği kitapların türü, yazarları veya ana temaları gibi öne çıkan nitelikleri belirler ve ardından bu özelliklere benzer yeni kitapları öneri listesine dahil eder. Böylece, örneğin polisiye romanları sıkça okuyan bir kullanıcıya, yine polisiye türünde farklı yazarların eserleri önerilebilir. İçerik tabanlı sistemler, özellikle kullanıcıların belirgin ve tutarlı tercihlere sahip olduğu durumlarda etkili sonuçlar vermektedir (Lops, de Gemmis ve Semeraro, 2011).

1.1.2. İşbirlikçi Filtreleme

İşbirlikçi filtreleme(İF), öneri sistemlerinde en yaygın kullanılan yöntemlerden biridir ve temelinde, benzer tercihlere sahip kullanıcıların gelecekte de benzer ürünleri beğeneceği varsayımı yatar. Bu yaklaşımda sistem, kullanıcıların geçmişteki değerlendirmelerini ve etkileşimlerini analiz ederek ortak zevklere sahip kullanıcı gruplarını belirlemektedir. Örneğin, bir e-ticaret sitesinde hem A hem de B kullanıcısı daha önce aynı kitapları satın aldıysa, A'nın beğendiği fakat B'nin henüz görmediği bir kitap, B'ye öneri olarak sunulabilir. Benzer şekilde, bir film platformunda aksiyon filmlerini sıklıkla izleyen iki kullanıcıdan biri yeni bir aksiyon filmi izlediğinde, bu film diğer kullanıcıya da önerilebilmektedir.

İF iki ana yaklaşıma ayrılmaktadır: Kullanıcı tabanlı ve öge tabanlı. Kullanıcı tabanlı yöntemde, sistem önce hedef kullanıcıya en çok benzeyen diğer kullanıcıları bulur ve onların beğendiği fakat hedef kullanıcının henüz keşfetmediği ve beğenebileceği ürünleri önermektedir. Örneğin, Netflix'te benzer dizi ve filmleri izleyen kullanıcılar arasında, birinin izlediği yeni bir dizi diğerine önerilebilir. Öge tabanlı yöntemde ise, kullanıcının daha önce olumlu değerlendirdiği ürünlerle benzer özellikler taşıyan yeni ürünler önerilmektedir. Örneğin, bir kullanıcı birden fazla bilim kurgu filmi izlediyse, sistem bu filmlerle benzer temalara sahip yeni bilim kurgu filmlerini önermeye odaklanmaktadır (Schafer, Frankowski, Herlocker ve Sen, 2007).

1.1.3. Hibrit Sistemler

Hibrit öneri sistemleri, içerik tabanlı ve işbirlikçi filtreleme yaklaşımlarının güçlü yanlarını birleştirerek daha etkili öneriler sunmayı amaçlayan gelişmiş sistemlerdir. İçerik tabanlı filtreleme ürün özelliklerine odaklanırken, işbirlikçi filtreleme kullanıcı derecelendirmelerini temel alır. Her iki yaklaşımın da kendine özgü sınırlamaları bulunmaktadır. Bu sınırlamaları aşmak ve öneri sistemlerinin performansını arttırmak amacıyla hibrit öneri sistemleri geliştirilmiştir (Basilico ve Hofmann, 2004).

1.2. ÖNERİ SİSTEMLERİNİN ÖZELLİKLERİ

Öneri sistemleri, kullanıcıların geçmişteki tercihlerini ve davranışlarını inceleyerek, gelecekte ilgi gösterebilecekleri içerikleri öngörmeyi amaçlar. Ancak, bu sistemler farklı

kullanıcı ihtiyaçlarına yanıt verebilmek için çeşitli özelliklerle donatılmıştır. Tasarım sürecinde, belirli bir özelliğin ön plana çıkarılması, kimi zaman diğer performans ölçütlerinde istenmeyen sonuçlara yol açabilir. Örneğin, öneri listesinin çeşitliliğini artırmak doğruluk oranında bir miktar azalmaya neden olabilir. Bu nedenle, öneri sistemlerinde farklı performans kriterleri arasında denge kurmak ve bu kriterlerin sistem üzerindeki etkilerini dikkatlice değerlendirmek gerekmektedir (Adomavicius ve Kwon, 2012). Genel olarak, öneri sistemlerinin öne çıkan başlıca özellikleri alt başlıklarda detaylandırılmaktadır.

1.2.1. Kişiselleştirme

Öneri sistemleri, kullanıcıların geçmişteki etkileşimlerini gözlemleyerek ve tercihlerini inceleyerek, kişiye özgü ve beğenebilecekleri içerikler sunar. Bu bağlamda kişiselleştirme, öneri sistemlerinin kullanıcıya özgü ve anlamlı öneriler sunabilmesi için temel bir işlemdir. Kişiselleştirme, bireylerin ilgi alanlarını, ihtiyaçlarını ve önceki davranışlarını dikkate alarak, her kullanıcıya uygun içeriklerin öne çıkarılmasını sağlamaktadır (Adomavicius ve Tuzhilin, 2005). Kişiselleştirme süreci, kullanıcıların platform üzerindeki davranışlarının analiz edilmesi ve bu verilerden anlamlı kalıpların çıkarılmasıyla gerçekleşir. Bu amaçla, işbirlikçi filtreleme ve içerik tabanlı filtreleme gibi yöntemler yaygın olarak kullanılmaktadır. İşbirlikçi filtreleme, benzer tercihlere sahip kullanıcıların beğenilerini temel alırken; içerik tabanlı filtreleme, kullanıcının daha önce etkileşimde bulunduğu içeriklerin özelliklerini dikkate alır (Ricci, Rokach ve Shapira, 2011). Ancak, kişiselleştirme sürecinde bazı zorluklar da ortaya çıkabilmektedir. Özellikle popüler içeriklerin daha fazla önerilmesi, kullanıcıların bireysel tercihlerini gölgede bırakabilir ve öneri listesinin çeşitliliğini azaltabilir. Bu nedenle, popülerite yanlılığının etkilerini azaltmak ve daha dengeli, kullanıcı odaklı öneriler sunmak, kişiselleştirme sürecinin başarısı için kritik öneme sahiptir.

1.2.2. Kullanıcı Etkileşimi ve Geri Bildirim

Öneri sistemlerinin kişiye özgü öneriler üretebilmesi kullanıcıların sistemle kurduğu ilişkiye dayanır. Bu ilişki iki temel şekilde gerçekleşir: doğrudan etkileşimler ve geri bildirimler. Kullanıcılar sistemde çeşitli işlemler gerçekleştirir; bir ürünün üzerinde imleci bekletmek veya tıklamak, bir film izlemek veya bir kitabı satın almak gibi. Bu

işlemler, kullanıcının ilgi alanlarını ve tercihlerini yansıtan değerli kişisel verileri oluşturur. Ayrıca, kullanıcılar önerilen içeriklerle ilgili farklı şekillerde geri dönüş verebilirler: bir ürünü beğenebilir, yorum yapabilir veya paylaşabilir bunlar açık geri bildirimlerdir. Bu açık geri bildirimlerin yanı sıra, bir ürünü ne kadar süre ve sıklıkta inceledikleri veya tekrar ziyaret ettikleri gibi örtük geri bildirimler de sistemin öğrenme ve kişiye özgü önerilerin üretilme sürecine katkıda bulunmaktadır (Konstan ve Riedl, 2012).

1.2.3. Çeşitlilik ve Yenilik

Öneri sisteminin başarısı, kişiye özgü ürün veya içerikler sunarken , aynı zamanda onları yeni beğenebilecekleri daha önce keşfetmedikleri ürün veya içeriklere de yönlendirebilmesi ile ölçülmektedir. Bu uyumun sağlanması için iki önemli başlık bulunmaktadır: çeşitlilik ve yenilik. Çeşitlilik, kullanıcının farklı ürün veya içeriklere yönlendirerek sıradanlıktan çıkmasıdır. Örneğin, bir müzik öneri sistemi, kullanıcının sevdiği türdeki şarkıların yanı sıra, farklı türde kullanıcının beğenebileceği müzik türlerinden de örnekler sunabilir. Yenilik ise, kullanıcının henüz keşfetmediği ama ilgisini çekebilecek içerikleri önermesi ile sağlanmaktadır. Bu, kullanıcıların yeni ve farklı ürün veya içerikleri keşfederek memnun kalmasına ve sistemle olan iletişiminin ve geri bildirimlerinin artmasına olanak tanır (Ziegler, McNee, Konstan ve Lausen, 2005).

Öneri sistemlerindeki çeşitlilik, kullanıcı deneyimini geliştirmek ve platform etkileşimini sürdürmek için elzem bir niteliktir. Sistemlerin popüler içeriklere yönelme eğilimi, kullanıcıların sürekli aynı tür seçeneklerle karşılaşmasına ve keşif tecrübesinin kısıtlanmasına yol açabilir. Bu durum, kullanıcıların taze içerikler bulmasını engelleyebilir ve uzun dönemde sistemin verimliliğini düşürebilir (Jannach, Kamehkhosh ve Lerche, 2017). Bu sorunu aşmak için, sistemler kaliteli fakat daha az tanınan içerikleri de öneri listelerine ekleyecek biçimde tasarlanmalıdır. Örneğin, bir film öneri sistemi, kullanıcının beğendiği türdeki popüler filmlerin yanı sıra, aynı kategorideki daha az bilinen ama değer taşıyan yapımları da önermek, kullanıcının sinema tecrübesini zenginleştirebilir. Yenilik kavramı, kullanıcıları şaşırtacak ve ilgilerini çekebilecek sürpriz içeriklerin keşfedilmesini sağlar. Bu tarz öneriler, kullanıcıların platformla olan bağlantısını güçlendirir ve sistemin değerini artırır (McNee, Riedl ve Konstan, 2006). Ancak burada dikkat edilmesi gereken husus, önerilen içeriklerin tamamen rastgele olmamalıdır. Kullanıcının mevcut ilgi alanları ve tercihleri göz önünde bulundurularak, onu yeni keşiflere yönlendirecek

içerikler seçilmelidir. Hibrit öneri sistemleri, çeşitlilik ve yenilik kavramlarını dengeli bir şekilde harmanlayarak daha etkili öneriler sunmayı hedeflemektedir (Burke, 2002). Bu sistemler, kullanıcının alışık olduğu içerik türlerini korurken, aynı zamanda yeni deneyimler sunarak kullanıcı memnuniyetini artırır. Örneğin, bir müzik öneri sistemi, kullanıcının sevdiği sanatçıların benzerlerini önerirken, farklı müzik türlerinden de seçenekler sunabilir.

1.3. ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİ

Klasik öneri sistemlerinde, kullanıcıların ürün veya içeriklere verdikleri tek bir genel puan dikkate alınarak öneri süreci başlatılmaktadır. Bu durum bir örnekle ele alındığında, Şekil 1'de kullanıcıların (Alice, John ve Mason) çeşitli filmlere verdikleri puanlar gösterilmektedir. Her bir hücre, ilgili kullanıcının o filme verdiği genel değerlendirme puanını temsil eder. Bu tür sistemlerde amaç, eksik olan puanları tahmin ederek kullanıcılara en çok beğenebilecekleri içerikleri önermektir. Örneğin, Alice'in "Fargo" filmi için bir puanı bulunmamaktadır. Tek ölçütlü öneri sistemleri, Alice'in diğer kullanıcılarla benzerliğine bakılarak, benzer puanlama eğilimlerinden dolayı John ile arasındaki benzerlik tespit edilerek, Alice'in "Fargo" filmini beğenebileceği ve vereceği puan sistemce tahmin edilebilmektedir.

Bu yaklaşımda, her kullanıcı ve her ürün için yalnızca tek bir genel değerlendirme puanı kullanılır. Kullanıcıların farklı kriterlere (örneğin hikaye, oyunculuk, görsellik gibi) göre ayrı ayrı puan vermesi söz konusu değildir. Bu nedenle, tek ölçütlü öneri sistemleri, kullanıcıların genel beğenilerini temel alarak önerilerde bulunur.

	Wanted	WALL-E	Star Wars	Seven	Fargo
Alice	5	7	5	7	?
John	5	7	5	7	9
Mason	6	6	6	6	5
:	:	:	:	:	:

Şekil 1. Tek ölçütlü film öneri sistemi

ÇÖÖS ise, kullanıcıların ürün veya hizmetleri birden fazla kriterde değerlendirmesine olanak tanıyan gelişmiş öneri mekanizmalarıdır. Bu sistemler, klasik tek boyutlu

öneri sistemlerinden farklı olarak kullanıcı tercihlerini yalnızca bir genel puan üzerinden değil; çeşitli kriterler, özellikler veya boyutlar kullanarak işleme almasıdır. Örneğin bir film için sadece genel bir değerlendirme puanı yerine, hikaye, oyunculuk, görsellik gibi farklı kriterler üzerinden de değerlendirme yapabilmektedir. Böylece, kullanıcının bir filmi tercih etme nedeni daha detaylı öğrenilebilir gerçekten memnun kalacağı hem daha kişiselleştirilmiş hem de kullanıcının önceliklerine daha uygun hale getirilmiş öneriler sunulabilmektedir (Adomavicius ve Tuzhilin, 2005).

ÇÖÖS'nin temel özellikleri arasında, önerilecek ürün veya hizmetlerin hangi kriterler üzerinden değerlendirileceğini belirleyen kriter seti, kullanıcıların her bir kritere verdiği puanları ve bu kriterlere atfettikleri önemi modelleyen kullanıcı tercih profili, kriterlerin göreceli ağırlıklarını belirleyen ağırlıklandırma mekanizması ve öneri algoritmaları yer alır. Kriter seti, sistemin uygulama alanına göre değişiklik gösterebilir. Bu tez kapsamında kullanılan YM20 ve YM10 veri setlerinde, filmler hikaye, oyunculuk, yönetmenlik ve görsellik gibi farklı kriterler üzerinden değerlendirilmiştir. TA veri setinde ise, oteller temizlik, konum, hizmet kalitesi ve fiyat gibi çeşitli boyutlarda puanlanmıştır. Bu sayede, sistemler yalnızca genel memnuniyeti değil, kullanıcıların hangi özelliklere daha fazla önem verdiğini de dikkate alarak öneriler sunabilmektedir.

ÇÖÖS en önemli avantajı, kullanıcıların tercihlerini daha detaylı analiz edebilmesi ve bunun sonucunda ise önerilerin bu çok boyutlu yapıya göre şekillenmesidir. Bu sayede, kullanıcılar yalnızca popüler veya yüksek puanlı ürünlerle karşı karşıya kalmamaktadır; kendi önceliklerine uygun, daha niş veya az bilinen beğenebilecekleri tarzda ürün veya hizmetleri de keşfedebilirler. Ayrıca, ÇÖÖS kullanıcılar arasındaki benzerlikleri hesaplamak kullanıcıları daha kişisel öneriler sunmayı sağlamaktadır. Kullanıcılar arasındaki benzerlikleri hesaplamak için literatürde kullanılan Toplama tabanlı benzerlik hesaplaması kullanılarak kullanıcıların değerlendirme yaptıkları genel puanlar ve kriterlere verdikleri puanlar arasındaki ilişkinin kullanıcıları daha kişiselleştirilmiş öneriler sunmada etkili olduğu vurgulanmaktadır (Tang , Gordon 2009). Kullanıcının genel puanları ve kriter puanları arasında regresyon analizi yapılarak ağırlıkların hesaplanması, öneri sistemleri literatüründe kişiselleştirilmiş performans değerlendirmesi için yenilikçi bir yaklaşım sunmaktadır. Bu tez kapsamında kullanıcıların genel puanlamaları, kriterler için verdikleri puanlar ve toplama tabanlı benzerlik hesaplaması sonucunda elde edilen puanlamalar kullanılarak analizler gerçekleştirilmektedir.

Kullanıcıların her kriterin zaman içinde değişen tercihleri ve kriterlere verdikleri önem de öneri sistemi tarafından dinamik olarak izlenebilir ve öneriler buna duruma göre güncellenebilir. Bununla birlikte, ÇÖÖS bazı zorluklarla da karşılaşmaktadır. Kriter sayısının artması, sistemin karmaşıklığını ve hesaplama maliyetini yükseltebilir. Ayrıca, kullanıcıların her bir kriter için tutarlı ve anlamlı değerlendirmeler yapması her zaman kolay olmayabilir. Bu nedenle, etkili bir kullanıcı önerisi için kullanıcı geri bildirimlerinin sürekli olarak değerlendirilmesi, sistemin başarısı için kritik öneme sahiptir (Lakiotaki ve diğerleri, 2011).

1.4. ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİNDE KARŞILAŞILAN PROBLEMLER

Öneri sistemlerinin (ÇÖÖS dahil) geliştirilmesi ve uygulanması sürecinde çeşitli zorluklarla karşılaşmaktadır. Bu zorluklar, sistemlerin performansını ve kullanıcı deneyimini önemli ölçüde etkilemektedir. Özellikle popülerite yanlılığı, sistemlerin kişileştirilmiş ve etkili öneriler sunmasını engelleyen temel sorunlardan biridir. Bu bölümde, ÖS'nin karşılaştığı başlıca zorluklar ve sistemler üzerindeki etkileri detaylı olarak incelenmektedir.

1.4.1. Veri Seyrekliği

Öneri sistemlerinin karşı karşıya kaldığı en kritik problemlerden biri veri seyrekliliği olgusudur. Bu durum, kullanıcıların platform içerisindeki mevcut ürün veya hizmetlerin çok az bir bölümü ile etkileşim kurmasından doğar. Sistemler, kullanıcı davranışlarını analiz etmek için gerekli veri miktarına ulaşamadığında, kaliteli öneriler üretmekte başarısız olur. Örnek olarak, bir online alışveriş platformunda binlerce ürün bulunmasına karşın, ortalama bir kullanıcı bu ürünlerin yalnızca minimal bir yüzdesi ile etkileşime geçmesidir (Adomavicius ve Tuzhilin, 2005).

1.4.2. Soğuk Başlangıç Problemi

Öneri sistemlerinin performansını sınırlayan bir başka temel engel, soğuk başlangıç sorunudur. Bu sorun, sistemin iki farklı senaryoda karşılaştığı veri yetersizliği durumunu kapsar: yeni üye olan kullanıcılar için henüz yeterli etkileşim verisi bulunmaması ve platforma yeni dahil edilen ürünler için kullanıcı değerlendirme verisi olmamasıdır.

Her iki koşul da sistemin öneri kalitesini önemli ölçüde düşürmektedir (Schein, Popescu, Ungar ve Pennock, 2002).

1.5. POPÜLARİTE YANLILIĞI

ÖS karşılaşılan temel sorunlardan biri, sistemlerin popüler içeriklere aşırı ağırlık vermesidir. Bu durum, algoritmaların çoğunlukla çok sayıda kullanıcı tarafından beğenilen veya etkileşim alan içerikleri öne çıkarmasıyla ortaya çıkmaktadır. Sonuç olarak, öneri listelerinde çeşitlilik azalır ve kullanıcılar sürekli benzer, yaygın içeriklerle maruz kalmaktadır. Özellikle İF gibi yöntemler, kullanıcılar arasındaki benzerlikleri tespit ettiğinde, popüler içeriklerin tekrar tekrar önerilmesine yol açmaktadır. Bu tekrar eden öneri döngüsü, daha az bilinen veya niş içeriklerin arka planda kalmasına neden olmaktadır (Jannach, Lerche, Gedikli ve Bonnin, 2013). Popülerite yanlılığı, yalnızca ÖS adil ve kapsayıcı olmasını engellemekle kalmaz, aynı zamanda kullanıcıların deneyimini de olumsuz etkilemektedir (Abdollahpouri, Burke ve Mobasher, 2019). Kullanıcılar genellikle popüler içeriklere daha yüksek puan verme eğilimindedir bu durum da sistemin bu içerikleri daha sık önermesine sebep olmaktadır. Buna karşılık, az bilinen içeriklerin yeterince değerlendirilmemesi, algoritmanın bu içerikleri tanıma ve önerme ihtimalini azaltmaktadır ve bu ürünlere veya içeriklere ilgisi olan kullanıcılara önerme işlemi gerçekleşmemektedir. Böylece, öneri sisteminin sunduğu seçenekler daralır ve kullanıcıların yeni içeriklerle karşılaşma olasılığı düşmektedir (Zehlike ve diğerleri, 2018). Sonuç olarak, popülerlik odaklı önyargı, hem sistemin performansını hem de kullanıcıların platformdan aldığı faydayı sınırlamaktadır. Kullanıcılar çoğunlukla aynı türde ve bilindik içeriklerle karşılaşırken, ilgi alanlarına uygun yeni seçenekleri keşfetme şansları azalmaktadır (Klimashevskaya ve diğerleri, 2024).

1.5.1.1. Çok Ölçütlü Öneri Sistemlerinde Popülerite Yanlılığı

Tek ölçütlü öneri sistemlerinde karşılaşılan popülerite yanlılığı problemi, algoritmaların yalnızca tek bir değerlendirme kriterine odaklanarak öneriler üretmesi ve bu kriterde yüksek performans gösteren ürünlere aşırı eğilim göstermesi sonucunda kullanıcının tercih etmeyeceği yüksek puan alan ürünleri önermesi durumunu ifade etmektedir. Tek ölçütlü öneri sistemlerinde popülerite yanlılığı, genellikle İF algoritmalarının doğal bir sonucu olarak ortaya çıkmaktadır. Örneğin, bir film öneri sisteminde, yüksek

puan alan popüler filmler sürekli olarak önerilirken, düşük puanlı veya az bilinen filmler göz ardı edilmektedir. Bu algoritmalar, kullanıcılar arasındaki benzerlikleri temel alarak öneriler yaparken, popüler ürünlerin daha sık önerilmesine neden olmaktadır. Bu durum, sistemin çeşitliliğini azaltmakta ve kullanıcıların alternatif ürünlere erişimini sınırlandırmaktadır (Abdollahpouri, Burke ve Mobasher, 2017).

Öneri sistemlerinin çok boyutlu yapısı içerisinde gözlemlenen popülerite yanlılığı, aynı şekilde belirli özelliklerde yüksek değerlendirme alan içeriklerin sistem tarafından sürekli olarak öne çıkarılması sonucu ortaya çıkmaktadır. Bu durum, kullanıcıların farklı kriterlere göre değişkenlik gösteren beklenti ve tercih sıralamalarını yeterince dikkate almamaktadır. ÇÖÖS, ürün ya da hizmetlerin farklı özelliklerini ayrı bir şekilde değerlendirerek, bireysel kullanıcı tercihlerini daha iyi yansıtan öneriler geliştirmeyi amaçlamaktadır. Bu sistemler, her kullanıcının belirli kriterlere verdiği önemi esas alarak, daha kişiselleştirilmiş ve hassas öneriler sunabilir (Adomavicius ve Kwon, 2012). Örneğin, bir film öneri platformunda bazı kullanıcılar oyunculuk becerisine öncelik tanırken, diğerleri senaryo kalitesini daha üstün bulabilir. Çok ölçütlü öneri sistemleri bu bireysel farklılıkları gözleterek, her kullanıcıya özel seçimler sunma kapasitesine sahiptir ancak bu sistemler ne denli ileri düzeyde olursa olsun, popülerite önyargısı olarak adlandırılan bir meseleyle karşı karşıya kalabilirler. Sistem genel olarak yüksek puan almış içerikleri ön plana çıkardığında, daha az bilinen ama kullanıcıya potansiyel olarak daha uygun olabilecek seçenekler göz ardı edilebiliyor (Klimashevskaya, Jannach, Elahi, Trattner ve Trattner ChristophTrattner, 2024). ÇÖÖS’de ortaya çıkan bu yanlılık, her bir değerlendirme ölçütünün ayrı ayrı ele alınmasını gerektiren oldukça karmaşık bir sorun olarak kabul edilmektedir. Örneğin bir e-ticaret platformunda, kalite açısından yüksek puan almış bir ürün, fiyat-performans açısından düşük bir değerlendirme alabilir. Bu tür durumlar, her kriter özelinde popülerlik eğilimine dayalı bir önyargı analizinin yapılmasını gerekli kılmaktadır. Bu bağlamda, literatürde söz konusu soruna yönelik çeşitli çözüm yaklaşımları sunulmuştur. Bu yaklaşımlar; kriter bazlı önyargı azaltma yöntemleri, kullanıcı eğilimleri ile popülerlik arasında denge kurma stratejileri, etik ve kültürel değerlendirmeler ile modern teknolojik yöntemler gibi kategoriler altında incelenmektedir (Li, Liu, Satapathy, Wang ve Cambria, 2024). ÇÖÖS’de popülerite yanlılığının etkileri kullanıcı memnuniyetinden sistemin işleyişine kadar geniş bir yelpazede değerlendirilebilir. Örneğin, yaz tatili için sakin, temiz kriterlerinde otel arayan biri için fiyat açısından uygun temizlik

kriteri düşük önerilerin sunulması, kullanıcıların istedikleri içeriklere ulaşmasını zorlaştırmaktadır. Bu durum, kullanıcı deneyimini olumsuz yönde etkilerken, sistemin öneri kalitesini de düşürmektedir. Aynı şekilde, yalnızca yaygın olarak beğenilen içeriklerin öne çıkarılması, kullanıcıların farklı ve yeni içerikleri keşfetme olasılığını düşürerek sistemin çeşitlilik düzeyini azaltmaktadır (Knijnenburg, Willemsen, Gantner, Soncu ve Newell, 2012).

1.6. TEZİN AMACI VE KATKILARI

ÇÖÖS popülarite yanlılığı, tek kriterli sistemlere göre daha karmaşık bir yapıya sahiptir çünkü bir ürün bazı kriterlerde yüksek popülarliğe sahipken, diğer kriterlerde daha az popüler olabilmektedir. Örneğin, bir film görsel efektleri açısından yüksek popülarliğe sahipken, hikaye açısından daha az dikkat çekmiş olabilir. Bu durum, popülarite yanlılığının her bir kriter özelinde ayrı ayrı ele alınmasını gerektirmektedir. Günümüzde öneri sistemlerinin büyük çoğunluğu çok ölçütlü yapıda kurgulanmasına rağmen, literatürde çok ölçütlü öneri sistemlerinde popülarite yanlılığını sistematik olarak ele alan çalışmaların sayısı oldukça sınırlıdır. Bu eksiklik, sistemlerin performansını ve kullanıcı memnuniyetini olumsuz yönde etkilemekte, özellikle kullanıcıların farklı kriterlere verdikleri önem derecelerinin göz ardı edilmesine neden olmaktadır. Bu durum da hem sistem başarısı hem de kullanıcıların memnuniyet seviyesinin düşmesine yol açmaktadır.

Mevcut literatür kapsamlı bir şekilde incelendiğinde, ÇÖÖS popülarite yanlılığını azaltmaya yönelik çalışmalarda beş temel alanda önemli boşluklar tespit edilmiştir. İlk olarak, kriter bazlı popülarlik analizi konusunda belirgin bir eksiklik bulunmaktadır. Mevcut çalışmalar genellikle genel popülarlik kontrolü yaparken, her bir kriter için ayrı popülarlik eğilimlerinin analiz edilmesi ve bu eğilimlerin kullanıcı tercihleriyle nasıl etkileşime girdiği konusunda yeterli modelleme yapılmamıştır. İkinci olarak, bağlamsal puanlama davranışı konusunda önemli bir eksiklik söz konusudur. Kullanıcıların farklı kriterlerde farklı puanlama eğilimleri göstermesi ve bu eğilimlerin zaman içinde değişmesi, mevcut statik ağırlıklandırma yaklaşımlarında dikkate alınmamaktadır. Üçüncü olarak, dinamik kullanıcı tercihleri konusunda belirgin bir eksiklik bulunmaktadır. Kullanıcıların kriter önceliklerinin zaman içinde değişebileceği gerçeği, mevcut çalışmalarda yeterince ele alınmamıştır. Dördüncü olarak, çok boyutlu adalet metrikleri konusunda kapsamlı bir değerlendirme sistemi bulunmamaktadır. Son olarak, kullanıcı puanlama davranışlarının

senaryo bazlı analizi konusunda da önemli bir eksiklik vardır. Bu boşluklar, mevcut sistemlerin kullanıcıların gerçek ihtiyaçlarını ve tercihlerini tam olarak karşılayamamasına ve popülerite yanlılığının etkili bir şekilde azaltılamamasına neden olmaktadır.

Bu tezin temel amacı, öneri sistemlerinde karşılaşılan popülerite yanlılığı probleminin çözümüne yönelik yeni yaklaşımlar geliştirmek ve bu yaklaşımların etkinliğini çoklu kriter bazlı değerlendirme yöntemleriyle analiz etmektir. Tez kapsamında geliştirilen iki yeni yaklaşım önerilmektedir: Göreceli Tercih Modeli (Relative Preference Model- RelPref) ve Kriter Duyarlı Göreceli Tercih Modeli (Criterion-Aware Relative Preference Model- PriRelPref). RelPref yöntemi, kullanıcıların kriter bazlı puanlama davranışlarını analiz ederek, her bir kriter için ayrı popülerlik eğilimi hesaplar ve bu eğilimleri kullanıcı tercihleriyle karşılaştırarak daha dengeli öneriler üretir. Bu yaklaşım, literatürdeki genel popülerlik kontrolü yöntemlerinden ayrılmakta ve kullanıcıların her bir kriter için gösterdikleri farklı puanlama eğilimlerini ayrı ayrı analiz ederek daha hassas bir popülerite yanlılığı azaltma mekanizması sunmaktadır. PriRelPref yöntemi ise RelPref'in geliştirilmiş bir versiyonu olarak, kullanıcıların kriter önceliklerinin dinamik doğasını dikkate alır ve bu önceliklerin zaman içindeki değişimini modelleyerek daha kişiselleştirilmiş öneriler üretir. Bu yöntem, kullanıcıların en değer verdiği kriterler ile ürünlerin en güçlü olduğu boyutlar arasındaki uyumu optimize ederek, daha kullanıcı odaklı ve tarafsız bir öneri mekanizması oluşturur..

Önerilen bu yöntemler, literatürdeki mevcut yaklaşımlardan farklı olarak, kullanıcıların puanlama davranışlarının bağlamsal doğasını dikkate alan ilk çok ölçütlü popülerite yanlılığı azaltma yöntemleridir. Bu özellik, sistemin hem popülerite yanlılığını daha etkili şekilde azaltmasını hem de kullanıcıların kriter bazlı tercihlerini daha iyi yansıtmalarını sağlamaktadır. Ayrıca, bu çalışmada kullanıcı puanlama davranışlarını analiz etmek için üç farklı senaryo da incelenmektedir. Bu senaryolar, kullanıcıların puanlama eğilimlerini, ölçek algılarını ve kriter bazlı hassasiyetlerini detaylı bir şekilde inceleyerek, puanlama dinamiklerinin öneri modeline daha etkili entegrasyonunu ve kişiselleştirme doğruluğunun artırılmasını hedeflemektedir.

Bu tez çalışmasının temel katkıları aşağıdaki gibi özetlenmektedir:

- Popülarite yanlılığını ele almak için çok ölçütlü öneri sistemlerine özel bir temel model önerilmiştir. Bu temel yaklaşım, yanlılığı azaltmak için tasarlanan yeni yöntemlerin performansını nesnel olarak değerlendirmek için sistematik bir referans noktası sunmaktadır.
- Yeni nesil çok ölçütlü öneri sistemlerinde popülarite yanlılığını azaltmak için yenilikçi bir yöntem geliştirilmiştir. Geleneksel yaklaşımlardan farklı olarak, bu yöntem kullanıcıların en çok değer verdiği kriterler ile öğelerin mükemmelleştiği boyutlar arasındaki uyumu dikkate alarak, daha kullanıcı duyarlı ve tarafsız bir öneri mekanizması oluşturmaktadır.
- Çok ölçütlü ortamlarda popülarite yanlılığının etkilerini daha iyi analiz etmek için, kullanıcı puanlama davranışına odaklanan üç farklı senaryo önerilmiştir. Bu senaryolar, kullanıcıların puanlama eğilimlerinin, ölçek algılarının ve kriter tabanlı duyarlılıklarının detaylı incelenmesine olanak tanıyarak, puanlama dinamiklerinin öneri modeline entegrasyonunu geliştirmekte ve kişiselleştirme doğruluğunu artırmaktadır.
- Önerilen yöntemin popülarite yanlılığını azaltmadaki etkisi, uzun kuyruk öge görünürlüğü ve çeşitlilik (Gini indeksi) gibi çok boyutlu metrikler kullanılarak kapsamlı şekilde değerlendirilmiştir. Bu değerlendirme, yalnızca kullanıcı düzeyindeki faydaları değil, aynı zamanda yöntemin sistem düzeyinde adalet ve kapsayıcılık açısından etkilerini de göstermektedir.
- Bu çalışma, çok ölçütlü öneri sistemleri bağlamında popülarite yanlılığını sistematik olarak ele alan ilk çalışmadır. Literatürdeki kritik bir boşluğu doldurarak, bu alandaki gelecekteki araştırmalar için önemli bir teorik ve metodolojik temel oluşturmaktadır.

1.7. TEZ ORGANİZASYONU

Bu tez, toplam yedi bölümden oluşmaktadır. Birinci bölümde, öneri sistemlerinin genel bir tanıtımı yapılmakta, öneri sistemlerinin türleri ve karşılaşılan zorluklar detaylı olarak ele alınmaktadır. Çok kriterli sistemlerde popülarite yanlılığı probleminin önemi ve karmaşık yapısı vurgulanmakta, bu problemin çözümüne yönelik tezin amacı ve katkıları kapsamlı olarak açıklanmaktadır. Özellikle, ÇÖÖS’de popülarite yanlılığının farklı

kriterler üzerindeki etkileri ve bu etkilerin kullanıcı deneyimine yansımaları detaylı olarak incelenmektedir.

İkinci bölümde, öneri sistemleri ve popülerite yanlılığı konusunda kapsamlı bir literatür taraması yapılmaktadır.

Üçüncü bölümde, kullanıcı popülerlik tespit yöntemleri ve popülerite yanlılığını azaltan algoritmalar detaylı olarak ele alınmaktadır. Bu bölümde, kullanıcıların popülerlik eğilimlerini tespit etmek için kullanılan çeşitli yöntemler ve algoritmalar kapsamlı bir şekilde incelenmektedir. Popülerite önyargısını azaltmaya yönelik mevcut algoritmaların teorik temelleri, matematiksel modelleri ve uygulama detayları sunulmaktadır.

Dördüncü bölümde, önerilen RelPref ve PriRelPref yöntemleri detaylı olarak açıklanmaktadır. Bu bölümde, geliştirilen yeni yaklaşımların teorik altyapısı, algoritma adımları ve matematiksel modelleri kapsamlı bir şekilde sunulmaktadır. RelPref yönteminin kullanıcı tercihlerinin göreceli analizi üzerine kurulu yaklaşımı ve PriRelPref yönteminin kriter önceliklendirme mekanizması detaylı olarak incelenmektedir. Her iki yöntemin de algoritma adımları, sözde kodları kapsamlı bir şekilde ele alınmaktadır.

Beşinci bölümde, deneyler kapsamlı bir şekilde sunulmaktadır. Bu bölümde, kullanılan deneysel tasarım, araştırma yöntemi ve uygulama süreçleri detaylı olarak açıklanmaktadır. Kullanılan veri setlerinin özellikleri, seçim kriterleri ve ön işleme adımları kapsamlı bir şekilde sunulmaktadır. Değerlendirme metrikleri kapsamında, doğruluk metrikleri ve doğruluk ötesi metrikler detaylı olarak tanımlanmakta ve kullanım amaçları açıklanmaktadır.

Altıncı bölümde, deneysel sonuçlar kapsamlı bir şekilde analiz edilmektedir. Bu bölümde, önerilen RelPref ve PriRelPref yöntemlerinin performans sonuçları, mevcut yöntemlerle karşılaştırmalı analizleri ve farklı veri setleri üzerindeki davranışları detaylı olarak incelenmektedir. Performans metriklerinin karşılaştırmalı değerlendirmesi, yöntemlerin güçlü ve zayıf yönlerinin analizi ve elde edilen sonuçların yorumlanması bu bölümün ana odak noktalarını oluşturmaktadır.

Sonuç bölümünde ise, sonuç ve tartışmalar sunulmaktadır. Bu bölümde, tez kapsamında elde edilen bulgular özetlenmekte, geliştirilen yöntemlerin güçlü ve zayıf yönleri tartışılmakta ve elde edilen sonuçların pratik uygulamaları değerlendirilmektedir. ÖS’de popülerite yanlılığı probleminin çözümüne yönelik gelecek araştırmalar için spesifik öneriler sunulmakta, ÇÖÖS’de popülerite yanlılığının azaltılmasına yönelik yeni araştırma

alanları ve yöntemlerin farklı alanlara uygulanabilirliği gibi konular detaylı olarak ele alınmaktadır.



2. BÖLÜM

LİTERATÜR TARAMASI

Öneri sistemleri, dijital platformların hızla büyümesiyle birlikte kullanıcıların içerik denizinde yön bulmasını sağlayan kritik yapay zeka uygulamaları haline gelmiştir. Geleneksel öneri sistemleri, kullanıcıların ürünlere verdikleri genel puanları temel alarak çalışmakta ve işbirlikçi filtreleme ile içerik tabanlı filtreleme gibi temel yaklaşımları kullanmaktadır (Koren, Bell ve Volinsky, 2009) ancak bu sistemler, ürünlerin çok boyutlu doğasını göz ardı etmekte ve kullanıcıların farklı kriterlere verdikleri önem derecelerini dikkate almamaktadır. Örneğin, bir film değerlendirmesinde kullanıcılar oyunculuk, senaryo ve yönetmenlik gibi farklı kriterleri değerlendirirken, sistem bu değerlendirmeleri tek bir genel puan üzerinden ele almaktadır (Adomavicius ve Kwon, 2012). Son yıllarda, derin öğrenme tabanlı yaklaşımlar öneri sistemlerinde önemli ilerlemeler sağlamıştır. Wang ve arkadaşları (2014), derin öğrenme tabanlı öneri sistemlerinin klasik matris çarpalama yöntemlerine kıyasla kullanıcı ve ürün özelliklerini daha etkili şekilde öğrenebildiğini ve öneri doğruluğunu anlamlı ölçüde artırdığını göstermiştir (H. Wang, Wang ve Yeung, 2014). Sun ve ekibi (2019), öneri sistemlerinde “öz-dikkat (self-attention)” mekanizmasını kullanarak, kullanıcıların geçmiş etkileşimlerinden en anlamlı olanlarını öne çıkaran ve böylece öneri kalitesini yükselten bir yaklaşım geliştirmiştir (Sun ve diğerleri, 2019). Kang ve arkadaşları (2018) ise “öz-dikkat temelli sıralı öneri (self-attentive sequential recommendation)” yöntemiyle geçmiş etkileşimlerden en alakalı olanları seçme konusunda başarılı sonuçlar elde etmiştir (Kang ve McAuley, 2018). Xie ve arkadaşları (2020), “karşıt-öğrenme (contrastive learning)” yaklaşımını kullanarak kullanıcı ve ürün temsillerini iyileştirmiş ve veri seyrekliği sorununu aşmada önemli başarılar elde etmiştir (Xie ve diğerleri, 2020). Wang ve ekibi (2023), oturum tabanlı öneri algoritmalarını ve güncel eğilimleri kapsamlı bir şekilde incelemiş, bu alandaki farklı yaklaşımların avantaj ve dezavantajlarını detaylı bir şekilde analiz etmiştir (Wang ve diğerleri, 2023). Tek ölçütlü öneri sistemlerinin sınırlamalarını aşmak amacıyla, çok ölçütlü öneri sistemleri geliştirilmiştir. Bu doğrultuda geliştirilen çok ölçütlü öneri sistemleri, kullanıcıların ürünleri çeşitli kriterler temelinde değerlendirmesine olanak tanıyan daha bütüncül

bir yaklaşım sunmaktadır böylece her kullanıcının farklı kriterlere atfettiği önemi göz önünde bulundurarak, daha kişiselleştirilmiş ve kullanıcıya özel öneriler oluşturmayı amaçlar (Das, Sahoo ve Pradhan, 2022). ÇÖÖS alanında yapılan araştırmalar, kullanıcıların birden fazla kriter üzerinden değerlendirme yapabilmesinin öneri kalitesine ve kullanıcı memnuniyetine olan etkisini derinlemesine incelemiştir. Liu ve arkadaşları (2023), derin öğrenme tabanlı çok ölçütlü öneri sistemlerinin kapsamlı bir incelemesini sunmuş ve bu sistemlerin karmaşık kullanıcı tercihlerini modelleme konusunda umut verici sonuçlar sunduğunu göstermiştir (Liu ve diğerleri, 2023). Zhang ve Chen (2020), açıklanabilir öneri sistemlerinin önemini vurgulamıştır, bu durum çok ölçütlü sistemler için de kritik bir husustur (Zhang ve Chen, 2020). Jannach (2022), çok ölçütlü öneri sistemlerinde kriterler arası etkileşimleri modelleme konusunda önemli bir katkı sunmuştur (Jannach, 2022). Öneri sistemlerinde popülarite yanlılığı, sistemin popüler ürünleri orantısız biçimde ön plana çıkarması ve bunun sonucunda kullanıcıların daha çeşitli ve kişiselleştirilmiş önerilere erişiminin kısıtlanması şeklinde ortaya çıkan bir sorundur (Abdollahpouri ve diğerleri, 2017). Bu sorun, özellikle çok ölçütlü öneri sistemlerinde daha karmaşık bir hal almaktadır. Popülarite yanlılığı, öneri sistemlerinin adaleti, çeşitliliğini ve kullanıcı memnuniyetini olumsuz etkileyen önemli bir araştırma konusu olarak öne çıkmaktadır (Klimashevskaja, Jannach, Elahi ve Trattner, 2024). Kowald ve Lacic (2022), işbirlikçi filtreleme tabanlı çoklu ortam öneri sistemlerinde popülarite yanlılığını incelemiş ve bu sorunun farklı içerik türlerinde nasıl ortaya çıktığını analiz etmiştir (Kowald ve Lacic, 2022). Abdollahpouri ve arkadaşları (2019), popülarite yanlılığı, kalibrasyon ve adalet arasındaki bağlantıyı incelemiş ve bu üç kavramın birbirini nasıl etkilediğini göstermiştir (Abdollahpouri, Burke ve Mobasher, 2019). Steck (2018), kalibre edilmiş öneriler yaklaşımını önermiş ve bu yaklaşımın popülarite yanlılığını azaltmada etkili olabileceğini göstermiştir (Steck, 2018). Wei ve arkadaşları (2021) nedensel çıkarım ve “karşıt-gerçeksel” analiz yöntemlerini kullanarak popülerlik etkisini ayırtmaya çalışmış, bu yaklaşımın kullanıcı-ürün eşleşmesini daha adil hale getirebileceğini göstermiştir (Wei ve diğerleri, 2021). Çok ölçütlü öneri sistemlerinde popülarite yanlılığı, tek ölçütlü sistemlere göre daha karmaşık bir yapı sergilemektedir çünkü bir ürün bazı kriterlerde yüksek popülerlik gösterirken, diğer kriterlerde daha az tercih edilebilmektedir. Bu nedenle, popülarite yanlılığının her bir kriter özelinde ayrı

ayrı değerlendirilmesi ve analiz edilmesi gerekmektedir. Zhang ve Chen (2020), çok ölçütlü öneri sistemlerinde popülarite yanlılığını azaltmaya yönelik önemli bir katkı sunmuştur. Bu yaklaşım, literatürdeki genel popülarite kontrolü yöntemlerinden ayrılmakta ve daha hassas bir popülarite yanlılığı azaltma mekanizması sunmaktadır (Zhang ve Chen, 2020). Son yıllarda ülkemizde öneri sistemlerinde popülarite yanlılığı üzerine gerçekleştirilen araştırmalar, bu alandaki uluslararası literatüre anlamlı katkılar sağlamaktadır. Yalçın ve Bilge (2021), grup öneri sistemlerinde popülarite yanlılığının kullanıcı memnuniyeti ve öneri çeşitliliği üzerindeki olumsuz etkilerini kapsamlı biçimde analiz etmiş; bu yanlılığın azaltılması için yeniden sıralama ve ağırlıklandırma gibi çeşitli yöntemler geliştirmiştir (Yalcin ve Bilge, 2021). Takip eden çalışmalarında ise, popülarite yanlılığının bireylerin kişilik özellikleriyle nasıl ilişkilendiği incelenmiş ve farklı kişilik tiplerinin öneri sistemlerinde popülarite yanlılığına maruz kalma düzeylerinin değişkenlik gösterebileceği ortaya konmuştur (Yalcin ve Bilge, 2023). Bu bulgular, öneri sistemlerinde adil ve dengeli öneriler sunulabilmesi için kullanıcıların bireysel ve psikolojik özelliklerinin de dikkate alınmasının gerekliliğine işaret etmektedir. Bununla birlikte, Taclı, Yalçın ve Bilge (2022) tarafından geliştirilen “Ortalamadan Daha İyi (BTA)” yöntemi, kullanıcıların popülerlik eğilimini daha hassas biçimde ölçmeye yönelik yenilikçi bir yaklaşım sunmaktadır. BTA yöntemi, kullanıcının ortalama puanının üzerinde değerlendirdiği ürünleri işleyerek, popülarite yanlılığını geleneksel yöntemlere kıyasla daha duyarlı ve kişiselleştirilmiş şekilde analiz etmektedir (Taclı, Yalcin ve Bilge, 2022). Böylece, öneri sistemlerinde hem kişiselleştirme başarısı hem de adalet düzeyi artırılabilir ancak mevcut literatür incelendiğinde; çok ölçütlü öneri sistemlerinde popülarite yanlılığının kriter bazında dinamik ve bağlamsal olarak analiz edilmesine yönelik çalışmaların oldukça sınırlı olduğu görülmektedir. Özellikle, kullanıcıların farklı kriterlerdeki puanlama eğilimlerinin zaman içindeki değişimi ve bu eğilimlerin öneri sistemlerine etkin biçimde entegre edilmesi konusunda önemli araştırma boşlukları bulunmaktadır. Bu çalışma, söz konusu eksiklikleri gidermeyi ve çok ölçütlü öneri sistemlerinde popülarite yanlılığının daha kapsamlı, dinamik ve kişiselleştirilmiş bir yaklaşımla ele alınmasını hedeflemektedir. Öneri sistemleri alanında gelecek araştırmalar için öne çıkan yönler arasında çoklu kriterlerin dinamik modellenmesi, popülarite yanlılığının azaltılması, uzun kuyruk öğelerinin daha iyi işlenmesi, bağlamsal bilginin daha etkili entegrasyonu ve sistemlerin açıklanabilirliğinin artırılması yer almaktadır.

(Adomavicius ve Kwon, 2012; Park ve Tuzhilin, 2008; Zhoua ve diğ erleri, 2010). Mevcut literat r kapsamlı bir  ekilde incelendiğinde,  ok  l  tl   neri sistemlerinde pop larite yanlılıđını azaltmaya y nelik  alıřmalarda  nemli bořluklar olduđu g r lmektedir. Bu bořluklar, RelPref ve PriRelPref y ntemlerinin geliřtirilmesini gerektiren kritik alanları ortaya koymaktadır. İlk olarak, kriter bazlı pop lerlik analizi konusunda belirgin bir eksiklik bulunmaktadır. Mevcut  alıřmalar genellikle genel pop larite kontrol  yaparken, her bir kriter i in ayrı pop lerlik eđilimlerinin analiz edilmesi ve bu eđilimlerin kullanıcı tercihleriyle nasıl etkileřime girdiđi konusunda yeterli modelleme yapılmamıřtır. Zhang ve Chen (2020),  ok  l  tl  sistemlerde pop larite yanlılıđını azaltmaya y nelik bir yaklařım  nermiř olsa da, bu y ntem kullanıcıların kriter bazlı puanlama davranıřlarının dinamik dođasını tam olarak modelleyememektedir. İkinci olarak, bađlamsal puanlama davranıřı konusunda  nemli bir eksiklik s z konusudur. Kullanıcıların farklı kriterlerde farklı puanlama eđilimleri g stermesi ve bu eđilimlerin zaman i inde deđiřmesi, mevcut statik ađırlıklandırma yaklařımlarında dikkate alınmamaktadır.     nc  olarak, dinamik kullanıcı tercihleri konusunda belirgin bir eksiklik bulunmaktadır. Kullanıcıların kriter  nceliklerinin zaman i inde deđiřebileceđi ger eđi, mevcut  alıřmalarda yeterince ele alınmamıřtır. Bu durum,  zellikle uzun vadeli kullanıcı etkileřimlerinde  nemli bir sorun oluřurmaktadır. D rd nc  olarak,  ok boyutlu adalet metrikleri konusunda kapsamlı bir deđerlendirme sistemi bulunmamaktadır.  ok  l  tl  sistemlerde adalet,  eřitlilik ve uzun kuyruk g r n rl đ n n birlikte deđerlendirilmesi i in yeterli metrikler geliřtirilmemiřtir. Son olarak, kullanıcı puanlama davranıřlarının senaryo bazlı analizi konusunda da  nemli bir eksiklik vardır. Kullanıcıların farklı puanlama eđilimleri,  l  ek algıları ve kriter bazlı hassasiyetlerinin sistematik olarak analiz edilmesi ve bu analizlerin  neri modeline entegre edilmesi konusunda yeterli  alıřma yapılmamıřtır. Bu eksiklikler nedeniyle, pop larite yanlılıđı probleminin   z m  bu tez kapsamında  ok  l  tl  yapıda sistematik olarak ele alınmaktadır.

3. BÖLÜM

GENEL BİLGİLER

Bu bölümde, öneri sistemlerinde popülarite yanlılığı probleminin çözümüne yönelik temel yaklaşımlar ve yöntemler ele alınmaktadır. Popülerlik yanlılığının etkili bir şekilde azaltılabilmesi için öncelikle kullanıcıların popülerlik eğilimlerinin doğru bir şekilde tespit edilmesi gerekmektedir. Bu nedenle, kullanıcı popülerlik eğilimi belirleme yöntemleri detaylı olarak incelenmekte ve ardından popülerlik önyargısını azaltmaya yönelik geliştirilmiş literatürdeki algoritmalar kapsamlı bir şekilde değerlendirilmektedir. Bu bölüm, çok kriterli öneri sistemlerinde popülarite yanlılığının azaltılmasına yönelik yeni yaklaşımların geliştirilmesi için gerekli teorik altyapıyı oluşturmaktadır.

3.1. KULLANICI POPÜLERLİK EĞİLİMİ BELİRLEME YÖNTEMLERİ

Literatürde popülarite yanlılığını azaltmaya yönelik algoritmalar için üç temel yaklaşım bulunmaktadır; (i) işlem-öncesi, (ii) işlem-sırası ve (iii) işlem-sonrası. İşlem-öncesi yöntemler, öneri sisteminin eğitildiği verileri değiştirerek dengesizlikleri azaltmayı amaçlamaktadır (Park ve Tuzhilin, 2008). İşlem-sırası yöntemler, öneri algoritmasının dahili mekanizmasını değiştirerek popülerlik eğilimine karşı koymayı hedeflemektedir (Kamishima ve diğerleri, 2014). İşlem-sonrası yöntemler ise, geleneksel öneri sisteminin ürettiği sıralı listeyi yeniden düzenleyerek popüler ürünleri cezalandırıp az popüler ürünleri ön plana çıkarmaktadır (Jannach, Lerche, Kamehkhosh ve Jugovac, 2015) Ancak bu yaklaşımların çoğu, kullanıcıların popülerlik konusundaki bireysel tercihlerini dikkate almamaktadır. ÖS popülarite yanlılığını azaltmaya yönelik geliştirilen çeşitli yöntemler, genellikle son işleme tekniklerini kullanarak; öneri listelerinin yeniden popüler olmayan kişiye özgü içeriklerin ön plana çıkması için düzenlenmesini hedeflemekte, popüler ürünleri cezalandırırken az bilinen ürünleri ön plana çıkarmaktadır. Bu yaklaşımlar kullanıcıların ürün popülerliği konusundaki bireysel düşüncelerini göz ardı etmektedir. Gerçek uygulamalarda kullanıcıların popüler ürünlere olan tercihleri farklılık göstermektedir: bazı kullanıcılar popüler içerikleri tercih ederken, diğerleri daha az tanınan öğelere yönelme eğilimindedir. Dolayısıyla kişiye özel öneriler sunmak ve bu öneriler sunarken

memnuniyeti de korumak için, kullanıcıların popüler ürünleri tercih etme yönelimlerini doğru tespit etmek ve bu yönelimlerini öneri algoritmalarına entegre edilmesi büyük önem taşımaktadır (Abdollahpouri, Burke ve Mobasher, 2017). Bu nedenle, bu bölümde kullanıcıların popülerlik eğilimini ölçmek amacıyla literatürde yaygın olarak kullanılan yöntemler ele alınmaktadır.

3.1.1. Popüler Ürünlerin Oranı Yaklaşımı

Popüler ürünlerin oranı yaklaşımı (Ratio of Popular Items -RPI), kullanıcıların sistemdeki yaygın içeriklere olan ilgi düzeyini ölçmek amacıyla kullanılan bir değerlendirme yöntemidir (Abdollahpouri, Burke ve Mobasher, 2017). Bu yöntemde, platformdaki tüm öğeler toplam etkileşim sayılarına göre sıralanmakta ve en yüksek etkileşim alan, toplam etkileşimlerin yaklaşık %20'sini oluşturan öğeler popüler kategorisinde değerlendirilmektedir. Kullanıcının etkileşimde bulunduğu öğelerin bu popüler gruba dahil olma oranı hesaplanarak, kullanıcının popülerlik eğilimi belirlenmektedir. Örneğin, bir kullanıcının değerlendirdiği 10 öğeden 7'si popüler kategorisinde yer alıyorsa, bu kullanıcının RPI değeri 0.7 olarak hesaplanmaktadır. Bu sayede, öneri sistemleri kullanıcıların popülerlik tercihlerini daha etkili bir şekilde analiz edebilmektedir.

$$RPI_u = \frac{|\{i \in I_u \mid i \in H\}|}{|I_u|} \quad (1)$$

Bu formülde, RPI_u kullanıcının popüler içeriklere olan eğilimini gösteren bir orandır. i soyut olarak bir ürün, film, otel şarkı vs. olabilir. I_u , kullanıcının değerlendirdiği tüm öğeleri, H ise sistemde popüler olarak tanımlanan öğeleri temsil etmektedir. Başka bir deyişle, RPI_u değeri, kullanıcı u 'nun etkileşimde bulunduğu içeriklerin ne kadarının popülerler arasında yer aldığını ortaya koymaktadır.

3.1.2. Derecelendirilen Ürünlerin Ortalama Popülerliği

Kullanıcıların popüler içeriklere ilgi düzeyini ölçmek amacıyla geliştirilen bir diğer yaklaşım, Derecelendirilen Ürünlerin Ortalama Popülerliği (Average Popularity of Rated Items-APRI) yöntemidir. Bu yöntem, bir öğenin popülerliğini tespit etmek için o öğeyi değerlendiren kullanıcı sayısının sistemdeki toplam kullanıcı sayısına ora-

nını hesaplamaktadır. Böylece, bir kullanıcının etkileşimde bulunduğu öğelerin ortalama popülerlik düzeyi belirlenerek, kullanıcının genel popülerlik eğilimi nicel olarak analiz edilebilmektedir.

$$APRI_u = \frac{1}{|I_u|} \sum_{i \in I_u} \frac{|\{u' \in U \mid i \in I_{u'}\}|}{|U|} \quad (2)$$

Denklem 2'deki matematiksel gösterimde, U harfi öneri sistemine kayıtlı olan tüm kullanıcıların oluşturduğu kümeyi belirtirken, I_u ile gösterilen değişken, herhangi bir kullanıcının daha önce değerlendirme yaptığı ürün, film, müzik gibi içeriklerin kümesini ifade etmektedir.

3.1.3. Ortalamadan Daha İyi Yaklaşımı

Kullanıcıların popülerlik eğilimlerini belirlemede öne çıkan yaklaşımlardan biri olan Ortalamadan Daha İyi (Better Than Average- BTA) yaklaşımı (Tacli, Yalcin ve Bilge, 2022), geleneksel metotlardan farklı olarak kullanıcının öğelere verdiği bütün değerlendirmeleri yerine yalnızca yüksek değerlendirme yaptığı öğelere odaklanmaktadır. Bu yöntemde, her kullanıcı için özel bir beğeni sınırı tanımlanır; bu sınır, kullanıcının geçmişte öğelere yaptığı değerlendirme puanlarının ortalaması alınarak hesaplanmaktadır. Kullanıcıya özgü olarak hesaplanan sınır puanın üzerinde kalan öğe değerlendirmeleri, o kullanıcının öğeyi gerçek anlamda beğendiği ve tatmin olduğu içerikler olarak kabul edilmektedir.

BTA yaklaşımının geliştirilmiş bir versiyonu olan BTA_{PRI} yöntemi, yalnızca kullanıcının beğeni sınırını dikkate almakla kalmaz; aynı zamanda içeriklerin sistemdeki popülerlik düzeyini de analiz sürecine dahil eder. Bu yöntemde, içerikler öncelikle popülerliklerine göre iki gruba ayrılır. Sonrasında ise, kullanıcının beğeni sınırının üzerinde puanladığı içeriklerin, popüler içerikler arasında nasıl dağıldığı incelenir. Böylece, kullanıcının yüksek puan verdiği içeriklerin ne kadarının popüler grupta yer aldığı belirlenerek, popülerlik eğilimi daha ayrıntılı ve nesnel bir şekilde ortaya konur. Bu yaklaşım, öneri sistemlerinde kullanıcıların popüler içeriklere olan ilgisini daha hassas biçimde değerlendirmek için etkili bir araçtır.

$$BTA_{RPI_U} = \frac{\left| \left\{ i \in R_u \mid r_{u,i} > \frac{1}{|R_u|} \sum_{j \in R_u} r_{u,j} \wedge i \in H \right\} \right|}{\left| \left\{ i \in R_u \mid r_{u,i} > \frac{1}{|R_u|} \sum_{j \in R_u} r_{u,j} \right\} \right|} \quad (3)$$

BTA_{PRI} denkleminde, u bir kullanıcıyı, i sistemdeki öğeleri, R_u ise o kullanıcının değerlendirdiği öğelerin kümesini ifade eder. Kullanıcının i öğesine verdiği puan, $r_{u,i}$ değeri ile gösterilir. Kullanıcının tüm puanlarının ortalaması, $\frac{1}{|R_u|} \sum_{j \in R_u} r_{u,j}$ formülüyle hesaplanır ve bu değer, kullanıcının beğeni sınırı olarak kabul edilir (bkz. Denklem 3). Bu sınırın üzerinde puan alan öğeler, kullanıcı tarafından beğenildiği varsayılır. H kümesi, popüler öğeleri temsil eder ve bu öğeler genellikle Pareto prensibi kullanılarak popülerlik dağılımlarına göre belirlenir. Pareto prensibi, 19. yüzyılda İtalyan ekonomist Vilfredo Pareto tarafından ortaya konulmuş ve sonrasında George K. Zipf ile Joseph Moses Juran tarafından geliştirilmiştir. Bu prensip, sistemlerdeki sonuçların büyük bir kısmının, nedenlerin küçük bir bölümünden kaynaklandığını ifade etmektedir. Temel olarak, %80'lik sonuçların %20'lik nedenlerden türediği gözlemlenmiştir. Bu dengesiz dağılım, sadece ekonomik sistemlerde değil, doğal ve sosyal sistemlerin çoğunda da geçerli olmaktadır (Sanders, 1987). Pareto prensibi, verimlilik artırma amacıyla yaygın olarak kullanıldığından dolayı tercih edilmektedir. BTA_{RPI} değeri, beğenilen öğelerin popüler kategorideki oranını ölçer, böylece kullanıcının popüler öğelere olan eğilimini ortaya koymaktadır.

BTA_{APRI} yönteminde ise BTA_{RPI} yöntemi ile benzer bir yaklaşım izlenmektedir. Bu yöntemin farklı yönü ise kullanıcının tercih ettiği öğelerin popülerlik puanlarının ağırlıklı ortalamasının alınarak hesaplanmasıdır. Hesaplamaya dahil edilen öğeler kullanıcının belirlenen beğeni sınırının üzerindeki öğeleri kapsamaktadır. Bu yaklaşımla kullanıcının popüler olan ürünlere yönelimi belirlenmektedir.

$$BTA_{APRI_U} = \frac{\sum_{i \in R_u \mid r_{u,i} > \frac{1}{|R_u|} \sum_{j \in R_u} r_{u,j}} p_i}{\left| \left\{ i \in R_u \mid r_{u,i} > \frac{1}{|R_u|} \sum_{j \in R_u} r_{u,j} \right\} \right|} \quad (4)$$

BTA_{APRI} denkleminde i sembolü öğeleri, u sembolü bir kullanıcıyı temsil ederken, R_u ifadesi, bu kullanıcının puanladığı öğelerden oluşan kümeyi belirtmektedir. Kullanıcının i numaralı öğeye verdiği puan $r_{u,i}$ ile gösterilir. Kullanıcının tüm değerlendirdiği öğelere ilişkin ortalama puanı, $\frac{1}{|R_u|} \sum_{j \in R_u} r_{u,j}$ formülü ile hesaplanmakta olup,

bu değer ilgili kullanıcının bireysel beğeni sınırı olarak kabul edilmektedir (bkz. Denklem 4). Bu sınır değerinde kalan puanlara sahip öğelerin, kullanıcının gerçek tercihlerini yansıttığı varsayılmaktadır. Modelde yer alan p_i terimi, i numaralı öğenin popülerlik puanını temsil eder ve bu değer; oylama sayısı, satın alma durumu veya görüntülenme sıklığı gibi etkileşim temelli ölçütlere dayalı olarak belirlenebilir. BTA_{APRI} metriği, kullanıcı tarafından beğenildiği kabul edilen öğelerin popülerlik değerlerinin ağırlıklı ortalamasını alarak, kullanıcının popüler içeriğe yönelik eğilimini tahmin etmeyi amaçlamaktadır.

Her iki yaklaşımda da yalnızca bireysel beğeni eşiğini aşan öğeler dikkate alınmakta; bu sayede kullanıcının yalnızca gerçek tercihlerine odaklanılarak popülerlik eğilimi daha isabetli biçimde analiz edilmektedir.

3.2. POPÜLARİTE YANLILIĞINI AZALTAN ALGORİTMALAR

Popülarite yanlılığı, öneri sistemlerinde hem sistem performansını hem de kullanıcı deneyimini olumsuz etkileyen önemli bir sorundur (Abdollahpouri ve diğerleri, 2019). Bu problemi gidermek amacıyla literatürde çeşitli algoritmalar geliştirilmiştir (Vargas ve Castells, 2011). Bu bölümde, öneri sistemlerinde popülerlik önyargısını azaltmaya yönelik olarak yaygın şekilde kullanılan dört temel algoritma ele alınmıştır: Dinamik Kullanıcı Odaklı Yeniden Sıralama (Dynamic User-oriented re-Ranking -DUoR), Artırılmış Fayda Üretimi (Augmentative -Aug), Çarpımsal Fayda Öğrenme (Mul) ve Popülerlik Farkındalıklı Ürün Ağırlıklandırma (Popularity-aware item weighting -Paiw). Her bir algoritmanın temel prensipleri, öneri listelerinde popüler ve az popüler içerikler arasındaki dengeyi sağlama yaklaşımları açıklanmaktadır. Bu algoritmalar, öneri sistemlerinde popülarite yanlılığını azaltmak için farklı metodolojik yaklaşımlar sunmakta olup, sonraki bölümde tanıtılacak olan özgün yöntemlerimizle karşılaştırmalı olarak değerlendirilmektedir.

3.2.1. Dinamik Kullanıcı Odaklı Yeniden Sıralama Algoritması

DUoR algoritması, popülerlik yanlılığını azaltmak için kullanıcıların kişisel popülerlik yönelimlerini öneri dahil eden yenilikçi bir yeniden sıralama algoritmasıdır. Algoritmanın ilk aşamasında, sistem tarafından oluşturulan aday içerik listesi, Pareto analizi

temel alınarak yüksek popülerliğe sahip (baş) ve düşük popülerliğe sahip (kuyruk) gruplara ayrılır. Bu ayrım, kullanıcıların farklı popülerlik tercihlerinin öneri listelerine daha iyi yansıtılmasını sağlamak amacıyla yapılmaktadır. DUoR algoritması her kullanıcı için ayrı ayrı hesaplanan popülerlik eğilimi skorunu dikkate alarak, öneri listesini dinamik biçimde oluşturmaktadır. Baş ve kuyruk önerilerini her adımda yeniden sıralamaktadır bu özelliği ile içerik veya ürün seçiminin dengelenmesini sağlar popüler ürünlere ağırlık verilmesine engel olmaktadır. Böylece, oluşturulan öneri içeriği, kullanıcının bireysel tercihlerini yansıtan ve popülerite yanlılığını azaltan dengeli bir öneri sunar. DUoR'un en önemli avantajı, her kullanıcıya özgü popülerlik eğilimini dikkate alarak öneri listesini kişiselleştirmesi ve sistem genelinde popülerite yanlılığını etkin biçimde azaltabilmesidir (Gulsoy, Yalcin, Tacli ve Bilge, 2025).

3.2.2. Arttırılmış Fayda Üretimi Algoritması

Augmentative (Aug) algoritması, öneri sistemlerindeki içerik dağılımını dengelemek için geliştirilmiş yenilikçi bir yaklaşımdır (Yalcin ve Bilge, 2021). Bu yöntem, kullanıcı tercihlerini ve içerik popülerliğini harmanlayarak daha dengeli öneriler sunmayı amaçlamaktadır. Sistem, her içerik için iki farklı değerlendirme kriterini bir araya getirir: kullanıcının potansiyel ilgisi ve içeriğin popülerlik seviyesi. Yöntemin çalışma prensibi şöyle özetlenebilir: Bir müzik öneri sisteminde, bir kullanıcı için tahmin edilen 4.5 puanlık bir şarkı, popülerlik düzeyine göre ayarlanmış bir katsayı ile çarpılarak yeni bir değerlendirme puanına dönüştürülür. Örneğin, çok popüler bir şarkı için bu katsayı 0.7 olabilirken, daha az bilinen bir şarkı için 1.3 olabilir. Bu şekilde, sistem hem kullanıcı tercihlerini dikkate alır hem de içerik çeşitliliğini teşvik eder. Aug algoritmasının en önemli özelliği, iki farklı faktörü dengeli bir şekilde birleştirmesidir. Birinci faktör, kullanıcının içerikle etkileşim olasılığını tahmin eden makine öğrenmesi modelinin çıktısıdır. İkinci faktör ise, içeriğin popülerlik seviyesine göre belirlenen bir dengeleme katsayısıdır. Bu iki faktörün birleşimi, sistemin hem kişiselleştirilmiş hem de çeşitli öneriler sunmasını sağlar.

Sistemin pratik uygulamasında, bir kullanıcı için önerilen ilk 10 müzik parçası arasında, popüler hit şarkıların yanı sıra, bağımsız sanatçıların eserleri ve daha az bilinen müzik türleri de yer alabilir. Bu yaklaşım, kullanıcıların müzik keşif deneyimini zengin-

leřtirirken, sistemin öneri doğruluğunu da korur. Örneğin, bir kullanıcı popüler rock şarkılarını dinlemeyi seviyorsa, sistem hem benzer popüler rock şarkıları önerir hem de aynı türde daha az bilinen alternatif seçenekler sunmaktadır.

3.2.3. Çarpımsal Fayda Öğrenme Algoritması

Multiplicative (Mul) yöntemi, öneri sistemlerinde popüler içeriklerin etkisini minimize etmek için geliştirilmiş yenilikçi bir sıralama tekniğidir. Aug algoritması gibi popülerlik önyargısını dengeleme amacını taşısa da, uygulama prensibi açısından önemli farklılıklar gösterir. Aug'un doğrusal birleştirme yaklaşımının aksine, Mul çarpımsal bir dönüşüm mekanizması kullanarak daha radikal bir dengeleme sağlar.

Yöntemin temel işleyiři, her içeriğin tahmin edilen değerlendirme puanının, popülerlik seviyesiyle ters orantılı bir ağırlık katsayısıyla çarpılmasına dayanır. Bu matematiksel dönüşüm, yüksek popülerliğe sahip içeriklerin puanlarını daha belirgin şekilde düşürerek, öneri listelerinin başında yer alma olasılıklarını minimize eder. Böylece, sistem daha az bilinen ve niş kategorilerdeki içeriklere öncelik vererek, kullanıcılara daha çeşitli ve keşfedilmemiş seçenekler sunmayı başarır. Bu yeniden sıralama stratejisi, özellikle içerik çeşitliliğini artırma ve ana akım içeriklerin aşırı temsil edilmesini engelleme konusunda etkili sonuçlar vermektedir. Sistemin uyguladığı katı cezalandırma mekanizması sayesinde, popüler içeriklerin öneri listelerinde baskın olma eğilimi önemli ölçüde azaltılmakta ve kullanıcıların daha geniş bir içerik yelpazesıyla karşılaşması sağlanmaktadır (Yalcin ve Bilge, 2021).

3.2.4. Popülerlik Farkındahlı Ürün Ağırlıklandırma Algoritması

Popularity-aware item weighting (Paiw) algoritması, öneri sistemlerinde popülerite yanlılığını azaltmak ve daha çeşitli içeriklerin kullanıcıya sunulmasını sağlamak amacıyla geliştirilmiş etkili bir yeniden sıralama yöntemidir. Bu yaklaşım, öneri listelerinde sıkça karşılaşılan popüler içeriklerin baskınlığını azaltırken, az bilinen içeriklerin görünürlüğünü artırmayı hedefler (Abdollahpouri ve diğeri, 2017).

Paiw algoritmasının ilk aşamasında, sistemdeki her bir içeriğin popülerlik düzeyi, genellikle kullanıcı etkileşimlerinin (örneğin, puanlama veya görüntülenme sayısı) sıklığına göre belirlenir. Ardından, bu popülerlik skorları kullanılarak logaritmik ters ağırlık-

lar hesaplanır; böylece, yüksek popülerliğe sahip içeriklere daha düşük, az popüler içeriklere ise daha yüksek ağırlıklar atanır. Bu ağırlıklandırma, öneri sisteminin az temsil edilen içerikleri öne çıkarmasını teşvik eder. İkinci aşamada, elde edilen ağırlıklar, içeriklerin tahmini öneri puanlarıyla birleştirilir. Bu birleştirme işlemi, λ (lambda) adı verilen bir dengeleme parametresiyle kontrol edilir. Lambda değeri, orijinal öneri puanları ile popülerlik ağırlıkları arasındaki dengeyi sağlar ve genellikle 0.5 olarak seçildiğinde, öneri doğruluğu ile çeşitlilik arasında optimal bir denge elde edilir. Yapılan araştırmalar, bu yöntemin öneri sistemlerinde popülerite yanlılığını azaltırken, öneri kalitesini de yüksek seviyede koruduğunu göstermektedir (Abdollahpouri, Burke ve Mobasher, 2018).



4. BÖLÜM

ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİNDE POPÜLARİTE YANLILIĞINI AZALTMA

4.1. GİRİŞ

ÇÖÖS’de popülarite yanlılığı, tek ölçütlü sistemlerdekinden farklı olarak çok boyutlu bir karakter sergiler. Örneğin, bir film oyunculuk kriterinde çok popüler olabilirken, senaryo kriterinde orta düzeyde, görsel efektler kriterinde ise düşük popülerliğe sahip olabilir. Bu çok boyutlu popülerlik yapısı, her kriter için ayrı popülerlik analizi yapılmasını zorunlu kılar. Literatürdeki en kritik eksikliklerden biri, kriter bazlı popülerlik eğilimlerinin kullanıcı tercihleriyle nasıl etkileşime girdiğinin yeterince modellenmemesidir. Mevcut yaklaşımlar genellikle sistem genelindeki popülerlik dağılımını kontrol ederken, kullanıcıların belirli kriterlerdeki popülerlik eğilimlerini göz ardı etmektedir. Daha da önemlisi, kullanıcıların puanlama davranışları zaman içinde değişebilir - bir kullanıcı başlangıçta oyunculuğa öncelik verirken, zamanla senaryo kalitesine daha fazla önem verebilir. Bu dinamik tercih değişimleri, mevcut statik ağırlıklandırma modellerinde dikkate alınmamaktadır (Adomavicius ve Tuzhilin, 2005).

Bu bölümde, literatürdeki bu önemli boşlukları doldurmak amacıyla geliştirilen iki yeni algoritma detaylı olarak ele alınmaktadır, RelPref, kullanıcıların popülerlik eğilimlerini dinamik olarak modelleyerek popülarite yanlılığını azaltmayı amaçlarken Pri-RelPref çok ölçütlü sistemlerde kullanıcıların farklı kriterlerdeki tercihlerini ayrı ayrı analiz ederek daha kişiselleştirilmiş öneriler üretmeyi hedeflemektedir.

4.2. GÖRECELİ TERCİH MODELİ

Önerilen RelPref, öneri sistemlerinde karşılaşılan popülarite yanlılığı problemini çözmek üzere geliştirilmiş yenilikçi bir yaklaşımdır. Bu model, kullanıcıların popülerlik eğilimlerini dinamik olarak analiz ederek, öneri sürecinde bu eğilimleri dengeli bir şekilde yönetmeyi amaçlamaktadır. Şekil 2’de bu modelin sistem mimarisi sunulurken algoritmanın çok ölçütlü veri setlerindeki çalışma prensibini bu görselde detaylandırılmaktadır .

RelPref çerçevesi, iki temel modül etrafında organize edilmiştir: Çok Ölçütlü Veri Seti ve RelPref Yeniden Sıralama Modülü. Veri seti bileşeni, kullanıcı puanlama davranışlarının çok boyutlu analizini sağlayan üç farklı veri temsil formatını içerir: genel tabanlı, kriter tabanlı ve toplam tabanlı temsiller. Bu yapı, bireysel kriterler (hikaye, oynaculuk, yönetmenlik, görsel efektler gibi) seviyesinde popülerlik değerlendirmesi yapmayı mümkün kılar ve bu değerlendirmeleri algoritmanın karar verme mekanizmasına entegre eder. Yeniden sıralama modülü ise kullanıcı odaklı öneri prosedürünü yönetir. Algoritma, standart İF modeli kullanarak test kullanıcısı için $P_{1 \times n}$ boyutunda tahmin matrisi oluşturarak başlar. Bu matris, kullanıcının henüz değerlendirmedeği ancak potansiyel olarak ilgisini çekebilecek ürünler için tahmin edilen skorları barındırır. Tahmin edilen skorlar azalan sırada düzenlenerek $C_{1 \times m}$ boyutunda aday ürün kümesi oluşturulur ve bu kümedeki ürünler, popülerlik seviyelerine göre baş (popüler) ve kuyruk (daha az popüler) kategorilerine ayrılır. Kullanıcının bireysel popülerlik eğilimi, popülerlik oranı ($PopRatio_u$) olarak hesaplanır (Bölüm 3.1'e bakınız). Bu metrik, kullanıcının geçmiş değerlendirme davranışlarında popüler ürünlere yönelik tercihini yansıtan kişiselleştirilmiş bir gösterge olarak işlev görür. Aday kümeden en yüksek tahmin skoruna sahip ürün seçilir ve öneri listesine (RecList) dahil edilir. Bu seçim sürecinde, seçilen ürünün kategorisine bağlı olarak mevcut öneri listesinin popülerlik derecesi ($Pref_{RecList}$) hesaplanır.

Sonraki aşamalarda, ürün seçimi sadece tahmin skorlarına dayalı olmaktan çıkar ve kullanıcının göreceli tercih eğilimlerini yansıtan ek bir metriği de dikkate alır. Her aday ürün için, kullanıcıya özel tercih skoru $pref(r_{ui})$ hesaplanır. Bu skor, Borda sayım yönteminden esinlenerek geliştirilmiş olup, ürünün kullanıcının puanlama geçmişi içindeki göreceli konumunu dikkate alır. Özellikle, puanlama r_{ui} olan her değerlendirilmiş ürün i için aşağıdaki hesaplamalar gerçekleştirilir:

- Daha düşük puanlanan ürünlerin sayısı:

$$pref^-(r_{ui}) = |\{j \in R_u^+ \mid r_{uj} < r_{ui}\}|$$

- Aynı puan verilen ürünlerin sayısı:

$$pref^=(r_{ui}) = |\{j \in R_u^+ \mid r_{uj} = r_{ui}\}|$$

- Bu bileşenler, son göreceli tercih skorunu hesaplamak için doğrusal olarak birleştirilir:

$$pref(r_{ui}) = \alpha \cdot pref^-(r_{ui}) + \beta \cdot pref^+(r_{ui})$$

α ve β parametreleri ağırlıklandırma faktörleri olarak işlev görür ve literatürde yaygın olarak $\alpha = 1$, $\beta = 0.5$ değerleri benimsenmiştir. Bu mekanizma, eşit değerlendirilen ürünler arasında daha detaylı sıralama ayrımları yapabilmeyi mümkün kılar ve kullanıcının genel değerlendirme dağılımını oluşturmaktadır.

Tablo 1. RelPref algoritmasının adımları ve kullanılan yöntemler

Adım No	Adım Açıklaması	Kullanılan Yöntem/Süreç
1	Çok Ölçütlü Veri Girişi ve Temsili	Veri Türleri: Genel tabanlı, Kriter tabanlı ve Toplam tabanlı
2	Baş ve Kuyruk Ürünlerinin Ayrıştırılması	Pareto ilkesi, küresel popülerlik ölçütlerine dayalı sınıflandırma
3	Tahmini Puan Matrisi Oluşturulması ($P_{1 \times n}$)	İşbirlikçi Filtreleme (İF)
3.1	Aday Ürün Kümesinin Oluşturulması ($C_{1 \times m}$)	Tahmini puanlara göre sıralama, en yüksek puanlı m ürünün seçimi
3.2	Öneri Listesinin İnşası (RecList)	Kullanıcı eğilimine göre baş/kuyruk adaylarından seçim, $Pref_{RecList}$ hesaplanması
3.3	Öneri Listesi İçinde Yeniden Sıralama	$Pref_{RecList}$ ile $PopRatio_u$ karşılaştırmasına dayalı ürün seçimi
4	Kullanıcı Popülerlik Eğiliminin Hesaplanması ($PopRatio_u$)	RPI , $APRI$, BTA_{RPI} , BTA_{APRI} yöntemleri
5	Sürecin Sonlandırılması	Sabit uzunlukta nihai öneri listelerin oluşturulması

Hesaplanan $Pref_{RecList}$ değeri, kullanıcının bireysel popülerlik oranı ($PopRatio_u$) ile karşılaştırılmaktadır. Öneri listesinin popülerlik seviyesi belirlenen eşik değerinin altında kaldığında, sonraki ürün popüler kategoriden seçilmekte; aksi durumda ise az popüler kategoriden seçim yapılmaktadır. Bu iteratif mekanizma, öneri listesi hedeflenen boyuta ($topN$) ulaşana dek devam etmektedir. Bu yaklaşım aracılığıyla, RelPref modülü tahmin edilen uygunluk değerlerini ve kullanıcı tercih eğilimlerini dengeli bir biçimde birleştirerek daha kişiselleştirilmiş ve çeşitlilik içeren öneriler elde etmektedir. Algoritmanın en dikkat çekici özelliği, kullanıcıların bireysel eğilimlerine göre popülerlik kategorileri arasında esnek geçiş yapabilme kapasitesidir. RelPref sistemi, öneri listesinin popülerlik dengesini sürekli olarak izlemekte ve bu sayede kişiselleştirme seviyesini artırırken çeşitliliği de muhafaza etmektedir. Geleneksel DUoR algoritmasına kıyasla, bu çerçeve önemli bir ilerleme kaydetmektedir. Kriter bazlı popülerlik değerlendirmesinden

veya daha az bilinen ürünlere yönelik eğilimlerini dikkate alarak kişiselleştirme ve çeşitliliği artırmayı hedeflemektedir.

4.3. KRİTER- DUYARLI GÖRECELİ TERCİH MODELİ

PriRelPref, öneri sistemlerinde adalet ve kişiselleştirme düzeyini artırmak amacıyla geliştirilmiş ileri seviye bir yeniden sıralama çerçevesidir. Bu model, öneri mantığına kullanıcıya özgü baskın kriterleri doğrudan entegre ederek, öneri listesinin hem adil hem de kişiye özel olmasını sağlamayı hedefler. RelPref algoritmasının bir uzantısı olarak tasarlanan PriRelPref, selefının popülerlik duyarlı ve çeşitlilik odaklı özelliklerini korurken, çoklu kriter öğrenimi sayesinde kişiselleştirme düzeyini daha da geliştirmektedir. Önerilen PriRelPref modelinin mimarisi Şekil 3'te gösterilmektedir. Çerçeve iki temel modülden oluşmaktadır: (i) Baskın Kriter Belirleme Katmanı ve (ii) Kriter-Duyarlı RelPref Motoru. Baskın Kriter Belirleme: İlk modül, çok kriterli puanlama veri setlerinde her kullanıcı için baskın değerlendirme boyutunu (kriteri) tespit ederek kişiselleştirme düzeyini önemli ölçüde artırmaktadır. Bu amaçla, kullanıcının genel puanını birden fazla alt kriter (örneğin hikâye, oyunculuk, yönetmenlik, görsel efektler) üzerinden tahmin etmek için eğitilmiş Çoklu Doğrusal Regresyon (MLR) modeli kullanılmaktadır. Her bir kullanıcı u için aşağıdaki doğrusal model uygulanmaktadır:


$$\hat{r}_u = \gamma_1 \cdot c_{1u} + \gamma_2 \cdot c_{2u} + \dots + \gamma_k \cdot c_{ku} + \varepsilon \quad (5)$$

Burada:

- $\hat{r}_u$ kullanıcı u için tahmin edilen genel puanı ifade etmektedir,
- c_{ku} kullanıcı u 'nun k 'nci kritere verdiği puanı göstermektedir,
- γ_k k 'nci kriter için öğrenilen ağırlık katsayısını temsil etmektedir,
- ε ise modelin artık (residual) hata terimidir.

Regresyon analizinde en yüksek ağırlık katsayısına sahip olan kriter, o kullanıcı için baskın değerlendirme ölçütü olarak tanımlanmaktadır. Kullanıcının puanlama davranışında en belirleyici rolü üstlenen bu kriter, öneri listesinin yeniden sıralanmasında temel referans olarak kullanılmaktadır.

Kriter-Duyarlı RelPref Modeli: Kullanıcı u 'ya ait baskın kriter tespit edildikten sonra, yeniden sıralama süreci RelPref algoritmasındaki adımları takip etmektedir. Ancak bu aşamada hem popülerlik analizi hem de kullanıcıya özgü tercih skorlarının hesaplanması, yalnızca belirlenen baskın kriter üzerinden yürütülmektedir. Böylece, öneri listesi kullanıcının en çok önem verdiği değerlendirme boyutuna göre şekillendirilmektedir.



Şekil 3. PriRelPref'in temel yapısı

PriRelPref modeli, kullanıcıya özel kriter ağırlıklarını yeniden sıralama sürecine dahil ederek, öneri listesinin hem içerik uygunluğunu hem de çeşitliliğini belirgin şekilde geliştiren sofistike bir kişiselleştirme stratejisi ortaya koymaktadır. Bu yaklaşım, özellikle kullanıcı değerlendirmelerinin çoklu boyutlar içerdiği film, otel veya çok özellikli ürün gibi alanlarda modelin etkinliğini ve uygulama değerini önemli ölçüde artırmaktadır.

5. BÖLÜM

DENEYLER

Bu bölümde, RelPref ve PriRelPref yöntemlerinin etkinliğini ve performansını kapsamlı bir şekilde değerlendirmek amacıyla sistematik bir dizi deney gerçekleştirilmiştir. Çalışmanın bu aşamasında, karşılaştırmalı analiz için gerekli olan deneysel metodoloji, kullanılan veri setinin özellikleri ve detayları, ayrıca performans değerlendirmesi için kullanılan ölçütler ve metrikler detaylı bir şekilde açıklanmıştır. Bu metodolojik yaklaşım, önerilen yöntemlerin güvenilirliğini ve geçerliliğini sağlamak için titizlikle tasarlanmıştır.

5.1. TEST METODOLOJİSİ

Önerilen yaklaşımın etkinliğini ve güvenilirliğini kapsamlı bir şekilde değerlendirmek amacıyla, literatürde yaygın olarak kabul gören ve metodolojik sağlamlığı kanıtlanmış birini dışarıda bırakma (leave-one-out) çapraz doğrulama stratejisi metodolojik temel olarak benimsenmiştir. Bu titizlikle tasarlanmış deneysel yaklaşım, her bir değerlendirme iterasyonunda, veri setinden tek bir kullanıcının test kullanıcısı (u_{test}) olarak rastgele seçilme prensibine dayanmaktadır. Bu süreçte, kalan tüm kullanıcılar eğitim setini oluşturmak üzere kullanılarak, sistemin öğrenme kapasitesini maksimize eden bir yapı kurulmuştur.

Eğitim verilerinin sistematik analizi sonucunda, test kullanıcısının henüz değerlendirme yapmadığı tüm öğeler için tahmin edilen derecelendirme değerlerini üretmek üzere gelişmiş bir İF algoritması uygulanmıştır. Bu tahmin edilen skorlar, matematiksel kesinlikle azalan sırada düzenlenerek, en yüksek tahmin edilen skorlara sahip ilk M öğe, önerilen yenilikçi yöntemler tarafından gerçekleştirilecek yeniden sıralama işlemi için aday öğe seti C' 'yi oluşturmak üzere stratejik olarak seçilmiştir.

Deneysel konfigürasyon parametrelerinde, M değeri 250 olarak sabitlenirken, nihai öneri listesinin uzunluğunu belirleyen N parametresi 20 olarak optimize edilmiştir. Performans değerlendirmesi, özellikle top- N öneri sistemlerinin etkinliğine odaklanmış olup, nihai sıralı listedeki ilk 10 öğenin detaylı analizini içermektedir. Bu yaklaşım, kullanıcı

deneyiminin kalitesini en üst düzeye çıkarmayı hedefleyen pratik bir değerlendirme metodolojisi sunmaktadır.

Bu kapsamlı deneysel çerçeve, her kullanıcı için özelleştirilmiş ve gerçekçi bir değerlendirme ortamı yaratarak, gerçek dünya öneri sistemlerinin karşılaştığı zorlukları birbir simüle etmektedir. Bu bağlamda, öneri sistemi, kullanıcı tercihlerini yalnızca geçmiş etkileşim verilerine dayanarak çıkarmak zorunda kalmakta ve bu da sistemin adaptif kapasitesini test etmektedir. Sonuç olarak, leave-one-out stratejisi, modelin etkinliğinin, güvenilirliğinin ve kullanıcı odaklı performansının titiz, sistematik ve bilimsel olarak sağlam bir değerlendirmesini sağlamaktadır.

5.2. VERİ SETİ

Bu araştırmada, öneri sistemleri literatüründe yaygın olarak kullanılan ve metodolojik sağlamlığı kanıtlanmış iki çok kriterli veri seti kullanılmıştır: Yahoo! Movies (YM) ve TripAdvisor (TA) veri setleri. YM veri seti, kullanıcıların film tercihlerini dört temel kriter üzerinden değerlendirdiği kapsamlı bir veri koleksiyonu sunmaktadır: oyunculuk performansı, senaryo kalitesi, yönetim becerisi ve görsel efektler. Kullanıcılar, bu bireysel kriterlere ilişkin derecelendirmelerinin yanı sıra, her film için genel memnuniyet düzeylerini yansıtan bütünsel bir değerlendirme notu da vermişlerdir. Araştırmanın metodolojik tutarlılığını sağlamak amacıyla, veri setinin iki farklı yoğunluk seviyesindeki alt kümesi kullanılmıştır: YM10 ve YM20 veri setleri. Bu alt kümeler, sırasıyla hem kullanıcı hem de film için minimum 10 ve 20 derecelendirme eşliğini karşılayan veri noktalarını içermektedir. Orijinal derecelendirme ölçeğinin standartlaştırılması amacıyla, [13, 12, 11] ve [10, 9, 8] değerleri sırasıyla [5, 4]-yıldız seviyelerine karşılık gelecek şekilde 1-5 ölçeğine dönüştürülmüştür; 1 değeri ise 1-yıldız seviyesini temsil etmektedir. YM20 veri seti, 429 kullanıcı ve 491 film içeren, toplam 77.828 değerlendirmeye sahip yoğun bir veri setidir. %90,76 seyreklik oranı ile diğer veri setlerine göre daha yoğun bir yapı sergilemektedir. Kullanıcı başına ortalama 181,42 değerlendirme ile aktif bir kullanıcı profilini barındırmaktadır. Ortalama değerlendirme puanı 4,38 ve standart sapması 0,92 olarak hesaplanmıştır. YM10 veri seti, 1,827 kullanıcı ve 1,471 film ile en büyük veri setidir. Toplam 202,756 değerlendirme içeren bu veri seti, %98,11 seyreklik oranına sahiptir. Kullanıcı başına ortalama 110,98 değerlendirme ve film başına ortalama 137,84

değerlendirme ile orta seviye bir etkileşim yoğunluğu göstermektedir. Ortalama değerlendirme puanı 4.39 ve standart sapması 0.95 olarak ölçülmüştür. YM20 veri seti gibi, YM10 da her film için aynı dört kriter üzerinden değerlendirme içermektedir. Bu, iki veri seti arasında karşılaştırmalı analiz yapılmasına olanak sağlamaktadır. TA veri seti ise, turizm sektöründe hizmet kalitesi değerlendirmelerini içeren kapsamlı birçok kriterli veri setidir. Veri kalitesini optimize etmek amacıyla, her kullanıcının en az üç derecelendirme değerine sahip olduğu bir alt küme seçilmiştir. Bu metodolojik seçim, 1.291 otel için 1.354 kullanıcıdan elde edilen toplam 38.512 çok kriterli değerlendirmeyi içermektedir. %99,72 seyreklik oranı ile diğer veri setlerine göre en seyrek yapıyı sergilemektedir. Kullanıcı başına ortalama 28,44 değerlendirme ile düşük kullanıcı etkileşimine sahiptir. Ortalama değerlendirme puanı 4,05 ve standart sapması 0,95 olarak hesaplanmıştır. TA veri setinde, kullanıcılar otel değerlendirmelerini beş farklı kriter üzerinden gerçekleştirmektedir: konum avantajı, temizlik standartları, hizmet kalitesi, değer-fiyat oranı ve oda kalitesi. Bu değerlendirmeler, 1'den 5'e kadar ayrık ve sayısal 5 seviyeli derecelendirme ölçeği kullanılarak yapılmıştır. Her iki veri seti de 1-5 arası değerlendirme ölçeği kullanılmaktadır. Seyreklik oranları %90,76 ile %99,72 arasında değişmekte olup, bu durum öneri sistemleri için farklı zorluk seviyeleri oluşturmaktadır. Ortalama değerlendirmeler 4,05 ile 4,38 arasında değişmekte ve standart sapmalar 0,92 ile 0,95 arasında benzerlik göstermektedir. Kullanıcı başına değerlendirme sayıları veri setlerine göre önemli farklılıklar göstermekte, bu da farklı kullanıcı davranış profillerini yansıtmaktadır. Her iki veri setinin çok kriterli yapısı, kullanıcı tercihlerinin daha detaylı analiz edilmesine ve daha kişiselleştirilmiş öneriler sunulmasına olanak sağlamaktadır (Lakiotaki ve diğerleri, 2011; X. Wang, He, Wang, Feng ve Chua, 2019). Veri setlerine ait bilgiler Tablo 2'de sunulmaktadır.

Tablo 2. YM ve TA veri setine ait bilgiler

Veri seti	#Kullanıcı	#Ürün	#Seyreklik
YM20	429	491	90.76%
YM10	1827	1471	98.11%
TA	1346	1289	99.72%

5.3. DEĞERLENDİRME METRİKLERİ

Öneri sistemlerinin başarımını değerlendirmek için çeşitli metrikler kullanılmaktadır. Bu metrikler genel olarak iki ana gruba ayrılabilir: doğruluk metrikleri ve doğruluk ötesi metrikler. Doğruluk metrikleri, sistemin kullanıcılara ne kadar doğru öneriler sunduğunu ölçerken; doğruluk ötesi metrikler ise önerilerin çeşitliliği, yeniliği ve adaleti gibi daha geniş perspektiflerden sistemi değerlendirmeye olanak tanır. Bu bölümde, öncelikle öneri sistemlerinin doğruluğunu ölçmek için kullanılan temel metrikler, ardından ise doğruluğun ötesine geçen ve sistemin kullanıcıya kattığı değeri farklı açılardan inceleyen metrikler ele alınacaktır. Bu kapsamda, doğruluk metrikleri başlığı altında Kesinlik, Geri çağırma ve F1- ölçütü gibi ölçütler incelenecektir. Doğruluk ötesi metrikler başlığı altında ise Yenilik, Ortalama Uzun Kuyruk Popülerliği (Average Percentage of Long Tail Items -APLT), Uzun Kuyruk Kapsamı (Long Tail Coverage- LTC) ve Gini Katsayısı gibi ölçütler değerlendirilecektir.

5.3.1. Doğruluk Metrikleri

Öneri sistemleri üzerine yapılan araştırmalar ve gerçek yaşamdaki çalışmalar, öncelikli olarak sistemin kullanıcıya ne kadar doğru öneriler sunduğunun değerlendirilmesine odaklanmaktadır. Bu doğrultuda, öneri sistemlerinin performansını ölçmek amacıyla doğruluk metrikleri kullanılmaktadır. Doğruluk metrikleri, sistemin önerdiği öğelerin, kullanıcının gerçek tercihlerine ne kadar yakın olduğunu nicel olarak ortaya koyar. Bu tez kapsamında ele alınan başlıca doğruluk metrikleri; kesinlik, geri çağırma, F1-ölçütü olarak sıralanabilir. Bu metrikler, öneri sisteminin kullanıcı beklentilerini ne ölçüde karşıladığını değerlendirmek için temel araçlar olarak kabul edilmektedir (Herlocker, Konstan, Terveen ve Riedl, 2004; Jannach, Zanker, Felfernig ve Friedrich, 2010).

5.3.1.1. Kesinlik

Kesinlik, önerilen öğeler arasından gerçekten kullanıcıya uygun olanların oranını belirleyerek, sistemin kişiselleştirilmiş öneri üretme kapasitesini ortaya koyar. Popülerlik önyargısının yüksek olduğu durumlarda, sistem genellikle kullanıcıların bireysel tercihlerinden ziyade genel olarak popüler olan içerikleri ön plana çıkarır ve bu durum kesinlik değerinin düşmesine yol açabilir. Özellikle öneri listesinin uzunluğunun arttığı

ve kullanıcı hakkında yeterli bilgi bulunmayan soğuk başlangıç senaryolarında, popüler fakat kullanıcıya uygun olmayan içeriklerin önerilme olasılığı artar. Dolayısıyla, yüksek kesinlik değeri, sistemin gereksiz ve ilgisiz popüler içerikleri önermeden, kullanıcıya gerçekten hitap eden seçenekleri sunma yeteneğini gösterir. Kesinlik metriği, öneri sistemlerinde hem alaka düzeyinin hem de yanlılık etkisinin ölçülmesinde literatürde yaygın olarak tercih edilmektedir (Bellogín, Castells ve Cantador, 2017).

$$Kesinlik@K(u) = \frac{|Rel_u \cap Rec_u^K|}{|Rec_u^K|} \quad (7)$$

Kullanıcı u için ilgili öğelerin tamamı Rel_u kümesinde yer alırken, sistemin kullanıcıya sunduğu en iyi K adet öneri ise Rec_u^K kümesinde bulunmaktadır.

5.3.1.2. Geri Çağırma

Geri çağırma, öneri sistemlerinin başarısını değerlendirmek için yaygın olarak kullanılan temel ölçütlerden biridir. Bu metrik, sistemin kullanıcıya ait tüm ilgili öğeler arasından ne kadarını öneri listesine dahil edebildiğini gösterir (Alhijawi, Obeid, Awajan ve Tedmori, 2022). Dolayısıyla yüksek bir geri çağırma değeri, sistemin kullanıcıya hitap eden içerikleri geniş bir yelpazede sunabildiğini ve kullanıcı ilgi alanlarını daha kapsamlı şekilde karşılayabildiğini gösterir. Bu nedenle, bu metrik, öneri sistemlerinin kullanıcı beklentilerini karşılama düzeyini analiz etmek için önemli bir araçtır.

$$Duyarlılık@K(u) = \frac{|Rel_u \cap Rec_u^K|}{|Rec_u^K|} \quad (8)$$

Kullanıcı u için ilgili öğelerin tamamı Rel_u kümesinde yer alırken, sistemin kullanıcıya sunduğu en iyi K adet öneri ise Rec_u^K kümesinde bulunmaktadır.

5.3.1.3. F1- Ölçütü

Kesinlik ve geri çağırma değerlerinin harmonik ortalaması olan F1-ölçütü, bu iki performans metriğini dengeli bir şekilde birleştirerek sistemin genel başarısını değerlendirmeye olanak tanır (Herlocker, Konstan, Terveen ve Riedl, 2004). Bu ölçütün matematiksel ifadesi şu şekildedir:

$$F1@K(u) = 2 \times \frac{Precision@K(u) \times Recall@K(u)}{Precision@K(u) + Recall@K(u)} \quad (9)$$

5.3.2. Doğruluk Ötesi Metrikler

Öneri sistemlerinin kullanıcıya sunduğu değeri tam anlamıyla ortaya koymak için yalnızca doğruluk odaklı ölçütlere başvurmak çoğu zaman yetersiz kalmaktadır. Bir öneri sistemi, yüksek doğruluk oranlarına ulaşsa bile, önerdiği içeriklerin çoğunlukla popüler ve herkes tarafından bilinen ürünlerden oluşması, kullanıcıların yeni ve ilgi çekici seçeneklerle karşılaşmasını engelleyebilir. Bu durum, sistemin kullanıcıya özgü ve çeşitli öneriler sunma amacını gölgede bırakır. Kullanıcıların beklentileri, yalnızca geçmişte beğendikleri ya da popüler olan ürünlerle sınırlı değildir; aynı zamanda daha önce karşılaşmadıkları, özgün ve çeşitli içeriklere de erişmek isterler. Bu nedenle, öneri sistemlerinin başarısını değerlendirirken, doğruluk metriklerinin yanı sıra, önerilerin yenilik düzeyi, uzun kuyruk ürünlerin önerilme oranı ve öneri listesinin çeşitliliği gibi doğruluk ötesi metriklerin de dikkate alınması gerekmektedir. Bu tezde, öneri sistemlerinin performansını çok boyutlu olarak inceleyebilmek amacıyla, yenilik, Ortalama uzun kuyruk popülerliği (APLT), uzun kuyruk kapsamı (LTC) ve Gini indeksi gibi ölçütler de kullanılmaktadır.

5.3.2.1. Yenilik

Yenilik metriği, öneri sistemlerinin kullanıcılara tanıdık olmayan ancak ilgi alanlarına uygun yeni içerikler sunma yeteneğini ölçmektedir. Bu metrik, sistemin kullanıcıların daha önce karşılaşmadığı fakat beğenme olasılığı yüksek olan öğeleri önerme başarısını değerlendirir (Zhang, Zhang, Liu ve Ma, 2013). Yüksek bir yenilik değeri, sistemin

kullanıcıları yeni ve çeşitli içeriklerle tanıştırabildiğini, böylece kullanıcı deneyimini zenginleştirdiğini gösterir.

$$Yenilik = \frac{1}{|R|} \sum_{i \in R} -\log_2(p(i)) \quad (10)$$

Öneri listesindeki toplam öge sayısı R ile gösterilirken, $p(i)$ değişkeni, i numaralı ögenin herhangi bir kullanıcı tarafından değerlendirilme olasılığını ifade eder.

5.3.2.2. Ortalama Uzun Kuyruk Popülerliği

APLT, öneri sistemlerinin kullanıcılara sunduğu öneri listesinde yer alan az popüler veya niş içeriklerin dağılımını değerlendiren bir metriktir. Bu metrik, sistemin sadece popüler içeriklere odaklanmak yerine, kullanıcıların ilgi alanlarına uygun daha az bilinen içerikleri de önerme yeteneğini ölçer. Uzun kuyruk kavramı, pareto prensibine dayanarak, popüler olmayan ancak toplamda önemli bir çeşitlilik oluşturan içerikleri ifade eder. Herhangi bir K kullanıcısı için, sistemin oluşturduğu N_K öneri listesindeki uzun kuyruk öğelerinin oranı, *APLT* metriği kullanılarak hesaplanmaktadır.

$$APLT_K = \frac{|T \cap N_K|}{N} \quad (11)$$

Burada, uzun kuyruk öğelerinin kümesi T ile gösterilmektedir. Sistemin performansını değerlendirirken, tüm kullanıcılar için hesaplanan ortalama APLT değeri, öneri sisteminin az popüler veya niş içerikleri kullanıcılara sunma kapasitesini yansıtır. APLT değerinin düşük olması, sistemin öneri listesinde yeterli çeşitlilik sağlayamadığını ve genellikle popüler içeriklere ağırlık verdiğini gösterir. Buna karşılık, yüksek APLT değerleri, sistemin uzun kuyruk içeriklerini başarıyla öneri listesine dahil edebildiğini işaret eder. Ancak, yüksek APLT değeri tek başına öneri kalitesinin iyi olduğunu garanti etmez, çünkü sistem az popüler içerikleri önerirken kullanıcı tercihlerini göz ardı edebilir (Sanders, 1987).

5.3.2.3. Uzun Kuyruk Kapsamı

LTC metriği, öneri sisteminin tüm kullanıcılar için oluşturduğu öneri listelerinde yer alan az popüler içeriklerin genel dağılımını değerlendirir. Bu metrik hesaplanırken, her kullanıcının en iyi N önerisinden oluşan ve tekrarlanan öğelerin çıkarıldığı birleşik küme (I_N) kullanılır. LTC değeri şu formül ile hesaplanmaktadır:

$$LTC = \frac{|I_N \cap T|}{|T|} \quad (12)$$

LTC metriğinin yüksek değerler göstermesi, öneri sisteminin az popüler veya niş içerikleri daha kapsamlı bir şekilde öneri listelerine dahil edebildiğini işaret eder. Bu durum, sistemin sadece popüler içeriklere odaklanmak yerine, daha geniş bir içerik yelpazesini kullanıcılara sunabildiğini gösterir. Yüksek LTC değerleri, öneri sisteminin çeşitlilik açısından daha başarılı olduğunu ve popülerite yanlılığından daha az etkilendiğini ortaya koyar. Bu da kullanıcıların daha çeşitli ve kişiselleştirilmiş öneriler almasını sağlamaktadır (Burke, 2002).

5.3.2.4. Gini Katsayısı

Gini katsayısı, veri setindeki sınıfların dağılımını analiz ederek, bir düğümdeki verilerin ne kadar heterojen olduğunu ortaya koymaktadır. Gini değerinin sıfır olması durumunda, incelenen düğümdeki tüm verilerin aynı sınıfa ait olduğu, yani tam bir homojenlik sağlandığı anlaşılır. İndeks değeri arttıkça, düğümdeki sınıf çeşitliliği de arttırmaktadır (Breiman, Friedman, Olshen ve Stone, 2017).

$$Gini(D) = 1 - \sum p_i^2 \quad (13)$$

Gini değeri hesaplanırken, D ile gösterilen veri setindeki her bir sınıfın (i) dağılım oranı p_i değişkeni ile ifade edilir.

6. BÖLÜM


DENEYSEL SONUÇLAR

Bu çalışmada, çok kriterli veri yapıları bağlamında öneri sistemlerinde giderek daha belirgin hale gelen popülerite yanlılığı sorunu ele alınmaktadır. Çalışmanın temel amacı, kullanıcı derecelendirme davranışlarındaki bağlamsal farklılıklar dikkate alınarak popülerlik yanlılığını azaltmaya yönelik yeni metodolojiler önermektir. Bu doğrultuda, kullanıcıya özgü eğilimlerin yakalanması ve derecelendirme dağılımlarının bireysel davranışsal bağlamlara göre yorumlanması amacıyla iki yeni algoritma—RelPref ve Pri-RelPref—geliştirilmiştir. Ayrıca, önerilen modellerin karşılaştırmalı olarak değerlendirilmesi için dört yerleşik temel algoritma—DUoR, Paiw, Mul ve Aug—çalışmaya dahil edilmiştir.

Deneyisel analizler, YM20, YM10 ve TA olmak üzere üç çok kriterli veri seti üzerinde gerçekleştirilmiştir. Değerlendirme çerçevesi hem öneri doğruluğunu hem de modellerin popülerite yanlılığını azaltmadaki etkinliğini ölçmek üzere titizlikle yapılandırılmıştır. Özellikle, bireysel kullanıcı düzeyinde popülerlik eğilimi puanlarının hesaplanabilmesi amacıyla dört farklı kullanıcı popülerlik eğilimi tahmin yöntemi—*APRI*, *RPI*, *BTA_{APRI}* ve *BTA_{RPI}*—kullanılmıştır. Her bir öneri yaklaşımı, bu tahmin teknikleri altında ayrı ayrı değerlendirilerek, farklı kullanıcı profilleri altında performanslarının ayrıntılı bir şekilde analiz edilmesi sağlanmıştır.

Öneri sonuçlarının kapsamlı bir şekilde değerlendirilmesi amacıyla toplam altı temel metrik kullanılmıştır: Kesinlik, Geri Çağırma, F1-ölçütü, Yenilik, APLT ve LTC. Deneylerde, standart leave-one-out (birini dışarıda bırakma) değerlendirme stratejisi benimsenmiştir. Bu prosedürde, bir kullanıcı test kullanıcısı olarak seçilmekte, kalan kullanıcılar ise eğitim setini oluşturmaktadır. Her bir test kullanıcısı için, dört tahmin yönteminin her biriyle popülerlik eğilimi puanı hesaplanmakta ve öneri algoritmaları bu hesaplanan puanlara göre çalıştırılmaktadır. Bu yapı sayesinde, önerilen modellerin temel yöntemlerle karşılaştırıldığında, top-N öneri listelerinde doğruluk ve çeşitlilik dengesini sağlama yetenekleri titiz ve adil bir şekilde karşılaştırılabilmektedir.

Şekil 4, 5, 6 ve 7, kullanıcı popülerlik eğilimi belirleme yöntemleri kullanılarak TA veri seti üzerinde gerçekleştirilen toplama, kriter ve genel analizlerin sonuçlarını sırasıyla sunmaktadır.




Şekil 4. TA veri seti üzerinde BTA_{RPI} analiz sonuçları

Şekil 4a'daki toplama tabanlı analiz doğruluk metrikleri açısından incelendiğinde, DUoR ve RelPref yöntemleri Kesinlik değeri 0,0065 ile en yüksek performansı göstermektedir. Bu değer, otel seçimi yapmak isteyen bir kullanıcıya önerilen 10 otel arasından sadece birkaç önerinin kullanıcının beklentilerine uygun olduğunu göstermektedir. Mul yöntemi Precision değeri 0,0006 ile neredeyse hiç doğru öneri sunamamaktadır. Paiw yöntemi de 0,0028 Kesinlik değeri ile kullanıcı memnuniyetinde ciddi kayıplar yaşatmaktadır. Popülerite yanlılığını azaltma metrikleri (Yenilik ve APLT, LTC) açısından değerlendirildiğinde, Mul yöntemi Novelty değeri 1,0 ile yeni ürünleri tamamen önerirken, Paiw (0,9956) ve Aug (0,9891) yöntemleri de benzer şekilde yeni öneriler sunmaktadır. Ancak bu yöntemlerin doğruluk değerlerinin çok düşük olması, popülerlik yanlılığını azaltmada aşırı agresif davrandıklarını ve kullanıcının gerçek tercihlerini göz ardı ettiklerini göstermektedir. Önerilen PriRelPref yöntemi Yenilik değeri 0,134 ile daha dengeli

bir yaklaşım sergilemektedir. Çeşitlilik ve adalet açısından (Gini Katsayısı), Aug yöntemi 0,9092 ile en yüksek değeri elde ederken, PriRelPref 0,3327 ile en düşük değere sahiptir. Uzun kuyruk kapsamı (LTC) değerleri tüm yöntemlerde oldukça düşüktür (0,0005-0,0146). Genel değerlendirme açısından, toplama tabanlı analizde RelPref yöntemi doğruluk odaklı senaryolarda öne çıkmaktadır.

Şekil 4b'deki kriter tabanlı analiz grafiği incelendiğinde; bu analiz türünde, kullanıcıların konum avantajı, temizlik standartları, hizmet kalitesi, değer-fiyat oranı ve oda kalitesi kriterlerini ayrı ayrı değerlendirmesi dikkate alınmaktadır. Doğruluk metrikleri açısından bakıldığında toplama tabanlı analiz sonuçları ile aynı performans gözlemlenirken, önerilerin çeşitli kategorilerde olmasını RelPref ve PriRelPref yöntemleri 0,8716 Gini değeri ile benzer çeşitlilik seviyesi sunarak ve kıyaslanan algoritmalarından daha çeşitli içerikler sunma konusunda iyi performans gösterdiği gözlenmektedir.


Şekil 4c, TA veri seti üzerinde yapılan genel tabanlı analiz sonuçlarını sunmaktadır. Bu analiz türünde de doğruluk metrikleri ve sistem başarısı açısından ele alındığında önerilen yöntemin toplama tabanlı analiz ve kriter tabanlı analizde olduğu gibi RelPref yöntemi kesinlik değeri 0,0065 ile en yüksek performansı göstermektedir. Mul yöntemi Precision değeri 0,0006 ile neredeyse hiç doğru öneri sunamamaktadır. Paiw yöntemi de 0,0028 Precision değeri ile kullanıcı memnuniyetinde ciddi kayıplar yaşamaktadır. Popülerite yanlılığını azaltma metrikleri açısından, kriter tabanlı analiz ile birebir aynı sonuçları aldığı gözlemlenmektedir. Çeşitlilik ve adalet açısından, Aug yöntemi 0,9092 ile en yüksek değeri elde ederken, Mul 0,4441 ile en düşük değere sahiptir. RelPref ve PriRelPref yöntemleri 0,8716 Gini değeri ile benzer çeşitlilik seviyesi sunmaktadır bu durum da gösteriyor ki önerilen yöntemler kullanıcılara çeşitli öneriler sunarken kullanıcı memnuniyetini de sağlamaktadır.



Şekil 5. TA veri seti üzerinde BTA_{APRI} analiz sonuçları

BTA_{APRI} yöntemine göre elde edilen sonuçlar Şekil 5 'te gösterilmektedir. Şekil 5a, toplama tabanlı analiz kapsamında elde edilen sonuçlar, doğruluk metrikleri açısından incelendiğinde, BTA_{RPI} yönteminde elde edilen değerlerle aynı değerler elde edilmiştir. Bu değer, diğer karşılaştırılan yöntemlere göre yüksek olsa da kullanıcının ilgisini çekecek tarzda öneriler için yeterli değildir. Örneğin, kullanıcı merkezi konumda, temiz ve uygun fiyatlı bir otel ararken, sistem tarafından önerilen oteller bu kriterleri karşılamamaktadır. Mul yöntemi kesinlik değeri 0,0006 ile neredeyse hiç doğru öneri sunamamaktadır- bu durumda önerilen 10 otelden hiçbirisi kullanıcının gerçekten beğeneceği türde değildir. Doğruluk ötesi metrikler (Yenilik ve APLT) açısından değerlendirildiğinde, RelPref algortiması DUoR algoritmasına göre Yenilik, APLT, LTC metriklerinde yüksek performans gösterdiği gözlenmektedir. Çeşitlilik ve adalet açısından (Gini Katsayısı) RelPref algoritması 0,8716 değeri ile en çeşitli otelleri sunarak kullanıcıyı memnun ettiği ancak Aug algoritması en çeşitli ve popüler olmayan önerileri sunarak kullanıcıyı memnun etmediği bulgusuna varılmaktadır.

Şekil 5b ve şekil 5C’de, kriter ve genel tabanlı analiz kapsamında BTA_{APRI} yöntemi kullanılarak elde edilen sonuçları sunmaktadır. Bu yöntem kullanılarak elde edilen sonuçlar BTA_{RPI} yöntemi kriter ve genel tabanlı analizlerde elde edilen sonuçlarla birebir aynı sonuçlar elde edildiği gözlemlenmektedir




Şekil 6. TA veri seti üzerinde $APRI$ analiz sonuçları


Şekil 6a, 6b ve 6c’de sunulan TA veri seti üzerindeki üç farklı analiz türünün karşılaştırmalı değerlendirmesi sunulmaktadır.

Tüm analiz türlerinde doğruluk metriklerinde diğer yöntemlerde olduğu gibi RelPref algoritması kullanıcının ilgi alanlarına yönelik öneriler sunarak kullanıcı memnuniyetini ve sistem başarısını sağladığı gözlemlenmektedir. Şekil 6a ve 6b’de yeni ve popüler öneriler sunma konusunda kıyaslanan algoritmalarından DUoR yöntemi yüksek değerler alsa da bu durum kullanıcıyı memnun edecek öneriler olmadığı bulgusuna varılmaktadır. Toplama tabanlı ve genel tabanlı analizde önerilen yöntemler çeşitlilik konusunda farklı analiz türlerin de başarılı sonuçlar elde edildiğini gösterir niteliktedir.


Tüm analiz yöntemlerinde Mul, Paiw ve Aug yöntemleri: yeni ve popüler olmayan içerikler sunarken, doğruluk değerlerinde ciddi kayıplar yaşamaktadır. Bu durum, bu yöntemlerin popülerlik yanlılığını azaltmada aşırı agresif davrandığını ve kullanıcının gerçek tercihlerini göz ardı ettiğini göstermektedir. Ayrıca Mul yönteminin tüm analizlerle en düşük çeşitlilik değerine sahip olması da gözlemlenmektedir.



(a) Toplama tabanlı



(b) Kriter tabanlı



(c) Genel tabanlı


Şekil 7. TA veri seti üzerinde RPI analiz sonuçları

TA veri seti üzerinde işlem yapılan kullanıcı popülerlik belirleme yöntemlerinden sonuncusu olan RPI yöntemine göre elde edilen sonuçlar Şekil 7 'de gösterilmektedir.

Doğruluk metrikleri açısından incelendiğinde APRI yöntemine göre belirgin farklılıklar olduğu tespit edilmektedir. Doğruluk metrikleri açısından incelendiğinde üç analiz türünde de diğer yöntemlerde elde edilen sonuçlara benzer sonuçlar elde edildiği gözlemlenmektedir. Doğruluk ötesi metrikler açısından değerlendirildiğinde ise önerilen Pri-

RelPref yöntemi Toplama tabanlı analizde APRI yönteminden farklı olarak DUoR yönteminden daha yüksek değerler elde ederek kullanıcıya yeni ve popüler öneriler sunma konusunda daha başarılı performans sergilediği gözlemlenmektedir.

Şekil 8, 9, 10 ve 11 kullanıcı popülerlik eğilimi belirleme yöntemleri kullanılarak YM20 veri seti üzerinde gerçekleştirilen toplama, kriter ve genel analizlerin sonuçlarını sırasıyla sunmaktadır.




Şekil 8. YM20 veri seti üzerinde $BTARPI$ analiz sonuçları

Önceki analizlerin devamı olarak, $BTARPI$ yöntemi kullanılarak başka bir veri seti olan YM20 üzerinde gerçekleştirilen deneyler, algoritma performansına ilişkin çoklu değerlendirme metrikleri açısından daha fazla içgörü sağlamaktadır. Şekil 8a, Şekil 8b ve Şekil 8c sırasıyla toplama, kriter ve genel analizlerin sonuçlarını sunmaktadır. Şekil 8a'da toplama tabanlı analiz sonuçları incelendiğinde Doğruluk metrikleri açısından DUoR ve RelPref yöntemleri Kesinlik değeri 0,1428 ile en yüksek performansı göstermektedir. Doğruluk ötesi metrikleri açısından Mul yöntemi Yenilik değeri 0,9409 ile kullanıcının daha önce karşılaşmadığı öneriler sunmada başarılı iken Kesinlik, Geri çağırma,

F1-ölçütü değerlerindeki en düşük performansı gösteriyor ki bu durum kullanıcı memnuniyetini sağlayamamıştır. Önerilen RelPref ve PriRelPref yöntemi Yenilik, APLT ve LTC metriklerinde yenilik ve niş ürünler sunma konusunda DUoR algoritmasından üstün performans sergilemiştir. Gini Katsayısı metriğinde ise aynı durumun sağlandığı gözlenmektedir.

Şekil 8b’de kriter tabanlı analiz sonuçları incelendiğinde, tüm yöntemlerin performansında önemli farklılıklar olduğunu göstermektedir. Kullanıcı memnuniyeti açısından elde edilen sonuçlar oldukça dikkat çekicidir. RelPref yöntemi (Kesinlik: 0,21, Geri Çağırma: 0,0598, F1-ölçütü: 0,0881) en yüksek performansı sergilerken, PriRelPref yöntemi (Kesinlik: 0,2047, Geri Çağırma: 0,0592, F1-ölçütü: 0,087) ikinci en yüksek değerleri elde etmiştir. Paiw (Kesinlik: 0,0815, Geri Çağırma: 0,02, F1-ölçütü: 0,0301), Aug (Kesinlik: 0,0846, Geri Çağırma: 0,021, F1-ölçütü: 0,0316) ve Mul (Kesinlik: 0,059, Geri Çağırma: 0,0148, F1-ölçütü: 0,0223) yöntemleri en düşük performansı göstermiştir. Bu durum, önerilen yöntemlerin çok ölçütlü öneri sistemlerinde kullanıcılara kişisel öneriler sunma konusunda diğer yöntemlerden önemli ölçüde daha başarılı olduğunu göstermektedir. Mul, Paiw ve Aug yöntemleri az popüler, niş içerikleri önerme konusunda çok agresif stratejiler benimsediğini, ancak bu durumun kullanıcı memnuniyetini düşürdüğünü göstermektedir. Bu durumda BTA_{RPI} yöntemi ile kullanıcı popülerlik eğiliminde kullanıcıların popüler içeriklere daha fazla meyilli olduğunu ve önerilen yöntemlerin yüksek doğruluk değerli ile başarılı olduğunu göstermektedir. Önerilen yöntemler ise uzun kuyruk içeriklerini daha seçici bir şekilde önererek kullanıcı memnuniyetini korumayı başarmıştır. Çeşitlilik açısından bakıldığında önerilen RelPref yöntemi (Gini Katsayısı: 0,8874) DUoR’dan %2,4 daha yüksek çeşitlilik adaleti göstermektedir. Bu durum, RelPref yönteminin hem kullanıcı memnuniyetini artırırken hem de çeşitli içerikler sunabildiğini göstermektedir. Ancak PriRelPref yöntemi (Gini Katsayısı: 0,7651) DUoR’dan %11,7 daha düşük çeşitlilik adaleti göstermektedir. Bu bulgular, önerilen yöntemlerin çeşitlilik adaleti açısından farklı karakteristik özellikler sergilediğini göstermektedir. RelPref yöntemi kullanıcı memnuniyetini artırırken çeşitlilik adaletini de koruyabilirken, PriRelPref yöntemi kullanıcı memnuniyetini önceliklendirerek çeşitlilik adaletinden ödün vermiştir. Bu durum, çok ölçütlü öneri sistemlerinde farklı denge noktalarının mümkün olduğunu ve her yöntemin kendine özgü karakteristik özellikler sergilediğini ortaya koymaktadır.

Şekil 8c’de genel tabanlı analiz sonuçları incelendiğinde kriter tabanlı analiz sonuçları ile benzer sonuçlar elde edildiği gözlemlenmiştir.




Şekil 9. YM20 veri seti üzerinde BTA_{APRI} analiz sonuçları

YM20 veri seti üzerindeki değerlendirme genişletildiğinde, BTA_{APRI} yönteminin uygulanması Şekil 9a, Şekil 9b ve Şekil 9c sırasıyla toplama, kriter tabanlı ve genel analizlerin karşılaştırmalı sonuçlarını göstermektedir. Şekil 9a’da toplama tabanlı analiz sonuçları incelendiğinde, RelPref (Kesinlik: 0,1431, Geri Çağırma: 0,0475, F1-ölçütü: 0,064) değerleri ile önerilen yöntem en başarılı performans sergilemiştir. Aug, Mul ve Paiw kullanıcı memnuniyet ve sistem başarı bakımından düşük performans göstermişlerdir. Popülerite yanlılığını azaltma açısından Mul yöntemi (Yenilik: 0,9409, APLT: 0,9409, LTC: 0,056) en yüksek performansı göstermiş, ancak bu durum kullanıcı memnuniyetinde ciddi kayıplarla birlikte gelmiştir. PriRelPref algoritması DUoR ve RelPref algoritmasına göre yüksek değer olarak uzun kuyruk önerileri ve kullanıcının beğeneceği tarzda yeni ürünler sunma konusunda daha başarılı olmuştur. Bu durum, çok ölçütlü öneri

sistemlerinde önerilen yöntemlerin kullanıcının beğendiği tarzda daha etkili olduğunu göstermektedir.

Şekil 9c'de genel tabanlı analiz sonuçlarına bakıldığında, DUoR (Kesinlik: 0,2414, Geri Çağırma: 0,0726, F1-ölçütü: 0,1053) ve RelPref (Kesinlik: 0,2407, Geri Çağırma: 0,0724, F1-Ölçütü: 0,105) yöntemleri en yüksek performans sergilerken, Pri-RelPref'de benzer şekilde yüksek performans göstermiştir. Popülarite yanlılığını azaltma açısından tüm analiz türlerinde Mul, Paiw ve Aug yöntemleri en yüksek Yenilik, APLT ve LTC değerlerini elde ederken, önerilen yöntemler daha dengeli bir yaklaşım benimsemiştir. Çeşitlilik adaleti açısından Mul, Paiw ve Aug yöntemleri en yüksek Gini Katsayısı değerlerini elde ederken, önerilen yöntemler orta düzeyde performans göstermiştir.

Bu bulgular, tüm analiz yöntemleri karşılaştırdığında gösteriyor ki DUoR yöntemi tek ölçütlü öneri sistemlerinde başarı sağlarken aynı başarıyı kriter bazlı öneri sistemlerinde popülarite yanlılığı yönetmede göstermemiştir. Analiz yaklaşımının karmaşıklığı arttıkça önerilen yöntemlerin kullanıcı memnuniyeti açısından performansının iyileştiğini, popülarite yanlılığını azaltma konusunda ise dengeli bir strateji benimsediğini göstermektedir. Bu durum, önerilen yöntemlerin farklı analiz yaklaşımlarında tutarlı ve güvenilir performans sergilediğini ve çok ölçütlü öneri sistemlerinde etkili çözümler sunduğunu ortaya koymaktadır.




Şekil 10. YM20 veri seti üzerinde *APRI* analiz sonuçları


Şekil 10, YM20 veri seti üzerinde *APRI* yöntemiyle gerçekleştirilen genel, kriter tabanlı ve toplama değerlendirilmelere dayalı olarak çeşitli algoritmaların performansını göstermektedir. Kullanıcı memnuniyeti açısından *RelPref* yöntemi en yüksek performans sergilerken, *PriRelPref* (Kesinlik: 0,0993, Geri Çağırma: 0,031, F1-ölçütü: 0,0441) orta düzeyde kalmıştır. *Paiw*, *Aug* ve *Mul* yöntemleri ise en düşük performansı göstermiştir. Popülerite yanlılığını azaltma açısından diğer yöntem ve analizlerle benzer sonuçlar elde edildiği gözlenmektedir. Çeşitli ve kullanıcıyı memnun eden ürünler sunma konusunda önerilen *PriRelPref* yöntemi diğer yöntemlere kıyasla başarılı olduğu bulgusuna varılmaktadır.

Şekil 10b’de kriter tabanlı analiz sonuçları Kullanıcı memnuniyeti açısından incelendiğinde *RelPref* yöntemi en yüksek performansı sergilerken, yeni ve çeşitli öneriler sunma konusunda önerilen *RelPref* yöntemi sunulan 10 öneriden 8 tanesinin farklı kategorilerde öneriler olması ve bunlardan 2 tanesinin kullanıcının ilgi alanına hitap ettiği ve


beğendiği bulgusuna varılmaktadır. Şekil 10c’deki genel tabanlı analiz sonuçları incelendiğinde Doğruluk metrikleri açısından kriter tabanlı analiz sonuçları ile benzer sonuçlar elde edildiği gözlemlenmektedir. Ancak Gini Katsayısı metriğinde önerilen PriRelPref yönteminin kriter tabanlı analiz sonucu ile aynı olduğu diğer yöntemlerin çeşitli kategorilerde ürünler sunma konusunda başarısı düşerken önerilen yöntemin analiz türü değişse de başarının değişmediği bulgusuna varılmaktadır.



(d) Toplama tabanlı



(e) Kriter tabanlı



(f) Genel tabanlı

Şekil 11. YM20 veri seti üzerinde *RPI* analiz sonuçları

Şekil 11’de, YM20 veri seti üzerinde *RPI* yöntemi kullanılarak gerçekleştirilen Toplama, Kriter tabanlı ve Genel tabanlı analiz sonuçlarını sunmaktadır.

3 analiz türünde de kullanıcı memnuniyeti ve sistem başarısı açısından bakıldığında önerilen RelPref yönteminin diğer yöntemlere göre en yüksek performansı gösterdiği ve önerilen bir diğer yöntem olan PriRelPref yönteminin de 2. Sırada başarı gösterdiği gözlemlenmektedir. Bu durum, önerilen yöntemlerin kullanıcıların gerçek tercihlerini yansıtma konusunda mevcut yöntemlerden daha etkili olduğunu göstermektedir.


Popülerite yanlılığını azaltma açısından elde edilen sonuçlar ise diğer yöntemlerde elde edilen sonuçlara benzer sonuçlar sunmaktadır.

Şekil 11b'deki kriter tabanlı analizde Yenilik ve popülerite yanlılığı metriklerinde Mul, Aug ve Paiw algoritmaları yüksek değerlere sahip olsa da kullanıcı için kişiselleştirilmiş öneriler sunma konusunda ve sistemin başarısı açısından değerlendirildiğinde düşük performans göstermişlerdir. DUoR yöntemi (Yenilik: 0,8922, APLT: 0,8922, LTC: 0,0189) orta düzeyde performans göstermiştir. Önerilen RelPref (Yenilik: 0,7666, APLT: 0,7666, LTC: 0,0163) ve PriRelPref (Yenilik: 0,7736, APLT: 0,7736, LTC: 0,0164) yöntemleri ise bu metriklerde daha düşük değerler elde etmiştir ancak toplam tabanlı analize göre yüksek değerler elde edilmiştir. Önerilen yöntemlerin diğer algoritmalara göre çeşitlilik ve popülerite yanlılığı yönetme konusunda düşük performans göstermiştir ancak kullanıcı memnuniyeti ve sistemin başarısı açısından en yüksek performansı RelPref algoritması göstermektedir.

Şekil 11c'deki toplama tabanlı analiz sonuçları kriter tabanlı analiz sonuçları ile benzer nitelikler taşımaktadır.

RPI yöntemi kullanılarak yapılan analizler, önerilen RelPref ve PriRelPref yöntemlerinin, özellikle kriter tabanlı ve genel tabanlı değerlendirmelerde kullanıcı memnuniyeti açısından DUoR'a kıyasla üstün bir performans sergilediğini göstermektedir. Popülerite yanlılığını azaltma ve çeşitlilik sağlama konusunda Mul, Paiw ve Aug gibi yöntemler çok agresif bir yaklaşım benimseyerek yüksek değerler elde etse de, bu durum kullanıcı memnuniyetinde ciddi kayıplara yol açmaktadır. Önerilen yöntemler ise kullanıcı memnuniyeti ile popülerite yanlılığını azaltma ve çeşitlilik arasında daha dengeli bir yaklaşım sunmaktadır.

Şekil 12, 13 ve 14, 15, kullanıcı popülerlik eğilimi belirleme yöntemleri kullanılarak YM10 veri seti üzerinde gerçekleştirilen toplama, kriter ve genel analizlerin sonuçlarını sırasıyla sunmaktadır.



Şekil 12. YM10 veri seti Üzerinde BTA_{RPI} analiz sonuçları


Şekil 12a’da sunulan BTA_{RPI} yöntemiyle elde edilen toplama tabanlı analiz sonuçları incelendiğinde, kullanıcı memnuniyeti açısından DUoR yöntemi (Precision: 0,045) en yüksek performansı göstermiştir. RelPref (Precision: 0,0437) yalnızca %2,9 daha düşük bir değerle DUoR’un hemen arkasında yer alırken, PriRelPref (Precision: 0,0353) %21,5 daha düşük performans sergilemiştir. Paiw, Aug ve Mul yöntemleri ise doğruluk metriklerinde belirgin şekilde daha düşük sonuçlar elde etmiştir.

Popülerite yanlılığını azaltma açısından Mul yöntemi (Yenilik: 0,9889, APLT: 0,9889, LTC: 0,0135) en yüksek performansı göstermiştir. Paiw (Yenilik: 0,657, APLT: 0,657, LTC: 0,009) ve Aug (Yenilik: 0,602, APLT: 0,602, LTC: 0,0082) görece yüksek değerlere sahip olsalar da, bu durum kullanıcı memnuniyetinde ciddi kayıplarla birlikte

gerçekleşmiştir. PriRelPref (Yenilik: 0,1095, APLT: 0,1095, LTC: 0,0015) ise DUoR'a göre %150,6 daha yüksek performans göstermiştir. Çeşitlilik adaleti açısından Mul yöntemi (Gini: 0,868) en yüksek değere ulaşırken, RelPref (Gini: 0,8285) ve PriRelPref (Gini: 0,8291) DUoR'dan (Gini: 0,8182) %1,3 oranında daha yüksek performans sergilemiştir. Paiw ve Aug ise daha düşük çeşitlilik adaleti değerlerine sahiptir.

Şekil 12b'de sunulan kriter tabanlı analiz sonuçları incelendiğinde, önerilen RelPref yöntemi doğruluk metriklerinde diğer yöntemlere kıyasla daha başarılı sonuçlar elde ederek hem kullanıcı memnuniyetini hem de sistem başarısını sağlamıştır. Popülarite yanlılığını azaltma bakımından, önerilen yöntemlerin tümü DUoR'dan daha yüksek performans göstermiştir. Özellikle PriRelPref, 0,8993 Gini katsayısı ile çeşitlilik adaleti açısından en başarılı sonuçlara ulaşmıştır. Bu bulgular, önerilen yöntemlerin farklı performans kriterlerinde öne çıkan güçlü yönleri sahip olduğunu ortaya koymaktadır.


Şekil 12c'deki genel tabanlı analiz sonuçlarında, doğruluk metrikleri ile yeni ve popüler olmayan içeriklere ilişkin göstergelerin (Yenilik, APLT, LTC), kriter tabanlı analiz ile paralel sonuçlar verdiği görülmektedir. Kullanıcıya sunulan içeriklerin kategori çeşitliliği açısından ise, PriRelPref algoritması 0,8993 Gini katsayısı değeriyle en başarılı performansı sergilemiştir.




Şekil 13. YM10 veri seti Üzerinde BTA_{APRI} analiz sonuçları

Şekil 13'te BTA_{APRI} yöntemi kullanılarak elde edilen analiz sonuçları sunulmaktadır. Kullanıcı memnuniyeti ve sistem başarısı açısından değerlendirildiğinde, üç analiz türünde de önerilen RelPref yönteminin, kullanıcının tercihlerine uygun öneriler sunarak yüksek memnuniyet sağladığı bulgusuna ulaşılmaktadır. Üç analiz türünde, yeni ve popüler olmayan içeriklerin önerilmesi açısından kıyaslanan algoritmaların başarılı olduğu görülse de, bu içeriklerin kullanıcı ilgisini çekmemesi nedeniyle sistem başarısının tam olarak sağlanamadığı tespit edilmiştir. Ayrıca, tüm analiz türlerinde kullanıcıya sunulan 10 öneriden 8'inin farklı kategorilerde yer alması ve kullanıcının ilgi alanına yönelik olması, önerilen PriRelPref yönteminin başarısını bir kez daha ortaya koymaktadır.


Gerçekleştirilen üç farklı analiz yaklaşımının karşılaştırmalı değerlendirmesi, yöntemlerin performansında analiz türüne bağlı farklılıklar olduğunu göstermektedir. Popülerite yanlılığını azaltma metriklerinde ise toplama tabanlı analizde RelPref (Novelty: 0,0695) DUoR'dan (Novelty: 0,0578) %20,2 daha yüksek performans sergilerken, kriter tabanlı analizde bu fark %23,1'e çıkmıştır. Çeşitlilik adaleti açısından, PriRelPref yöntemi toplama tabanlı analizde (Gini: 0,8993) en yüksek değeri elde ederken, genel tabanlı analizde (Gini: 0,9018) daha da yüksek performans göstermiştir. Bu bulgular, analiz türünün karmaşıklık seviyesinin popülerite yanlılığını azaltma ve çeşitlilik adaleti üzerinde daha belirgin etki yarattığını, kullanıcı memnuniyeti açısından ise minimal farklılıklar oluşturduğunu ortaya koymaktadır.



(a) Toplam tabanlı



(b) Kriter tabanlı



(c) Genel tabanlı

Şekil 14. YM10 veri seti üzerinde APRI analiz sonuçları


Şekil 14'deki grafikler incelendiğinde RelPref yöntemlerinin kullanıcı memnuniyeti açısından en yüksek performansı sergilediğini, popülerite yanlılığını azaltma konusunda ise daha konservatif bir yaklaşım benimsediğini göstermektedir. Mul, Paiw ve Aug

yöntemleri popülerite yanlılığını azaltma konusunda agresif stratejiler benimsemiş, ancak bu durum kullanıcı memnuniyetinde ciddi kayıplara yol açmıştır. PriRelPref yöntemi ise her iki konuda da dengeli bir yaklaşım sergilemiştir. Yenilik, APLT metriklerinde literatürde sıkça tercih edilen algoritmaların dışında PriRelPref algoritması RelPref ve DUoR algoritmasından daha yeni ve uzun kuyruk ürünlerini sunma konusunda daha başarılıdır. Önerilerin çeşitliliğini Mul algoritması sağlarken PriRelPref algoritması da takip etmektedir.


Şekil 15b'deki kriter tabanlı analiz sonuçları incelendiğinde, doğruluk metrikleri sonuçları toplama tabanlı analiz sonuçları ile benzer niteliktedir. Yeni ve popüler olmayan içerikler sunma konusunda toplama tabanlı analize göre DUoR yöntemi yüksek değerler olsa da bu durum önerilerin çeşitliliği ve kullanıcı memnuniyeti açısından başarıyı sağlamamaktadır. Çeşitlilik metriğinde önerilen yöntemlerden RelPref ve PriRelPref yöntemi en çeşitli öneriler sunduğu gözlemlenmektedir.

Şekil 15c'deki genel tabanlı grafik incelendiğinde toplama tabanlı analiz ve Kriter tabanlı analiz sonuçları ile benzer sonuçlar elde edildiği Paiw, Aug ve Mul yöntemleri ise kullanıcı memnuniyeti metriklerinde belirgin şekilde daha düşük performans gösterdiği bulgusuna varılmaktadır. Popülerite yanlılığını azaltma açısından elde edilen sonuçlar toplama tabanlı sonuçlar ile benzer durum sergilemektedir. Çeşitlilik adaleti açısından elde edilen sonuçlarda PriRelPref yöntemi (Gini: 0,9018) tüm yöntemler arasında en yüksek çeşitlilik adaleti değerine sahip olurken, RelPref (Gini: 0,8951) ve DUoR (Gini: 0,8942) yöntemleri de yüksek değerler elde etmiştir.


Bu bulgular, *APRI* kriter tabanlı analizde RelPref ve PriRelPref yöntemlerinin kullanıcı memnuniyeti açısından en yüksek performansı sergilediğini Kullanıcıya sunulan önerilerin çeşitlilik açısından kullanıcıyı memnun ettiği, popülerite yanlılığını azaltma konusunda ise daha konservatif bir yaklaşım benimsediğini göstermektedir.



(d) Toplam tabanlı



(e) Kriter tabanlı



(f) Genel tabanlı

Şekil 15. YM10 veri seti üzerinde RPI analiz sonuçları

YM10 veri seti üzerinde RPI yöntemi kullanılarak gerçekleştirilen toplama tabanlı, kriter tabanlı ve genel tabanlı analizlerin karşılaştırmalı değerlendirilmesi, yöntemlerin farklı analiz yaklaşımlarında nasıl performans sergilediğini ortaya koymaktadır. Şekil 14a'daki toplama tabanlı analiz sonuçları, RelPref yönteminin (Precision: 0,04, Recall: 0,019, F1-measure: 0,0225) kullanıcı memnuniyeti açısından en yüksek performansı sergilediğini göstermektedir. Şekil 14b'deki kriter tabanlı analizde de RelPref (Precision: 0,0396, Recall: 0,0152, F1-measure: 0,0185) yöntemi öne çıkmıştır. Şekil 14c'deki genel tabanlı analizde ise benzer bir sonuç gözlemlenmiştir. Bu durum, RelPref yönteminin farklı analiz türlerinde tutarlı bir şekilde kullanıcı memnuniyeti açısından üstün performans sergilediğini göstermektedir. Popülerite yanlılığını azaltma metrikleri açısından ise analiz türleri arasında önemli farklılıklar gözlemlenmektedir. Şekil 14a'da Mul, Paiw ve Aug algoritmaları yüksek performans gösterirken, Şekil 14b'de ve Şekil 14c'de DUoR, RelPref ve PriRelPref algoritmalarının Yenilik (Novelty) ve APLT metriklerinde diğer

kullanıcı popülerlik eğilimi belirleme yöntemlerine kıyasla yüksek değerler aldığı gözlemlenmektedir. Bu bulgular, analiz türünün popülerite yanlılığını azaltma performansı üzerinde belirgin etki yarattığını göstermektedir. Öneri listesindeki çeşitlilik adaleti açısından da analiz türleri arasında farklılıklar gözlemlenmektedir. Şekil 14a'da Mul en yüksek çeşitlilik adaleti değerine sahip olurken, Şekil 14b'de de PriRelPref (Gini: 0,8291) öne çıkmıştır. Şekil 14c'de ise benzer bir trend devam etmiştir ve RelPref yöntemi de yüksek çeşitlilikte öneriler sunmuştur. Bu durum, PriRelPref yönteminin farklı analiz türlerinde tutarlı bir şekilde çeşitlilik adaleti açısından üstün performans sergilediğini göstermektedir.



SONUÇ

Bu çalışmada, çeşitli kullanıcı popülerlik eğilimi belirleme yöntemleri (RPI , $APRI$, BTA_{RPI} , BTA_{APRI}) ve çoklu öneri algoritmaları (DUoR, RelPref, Paiw, Mul, Aug, Pri-RelPref), üç farklı çok kriterli veri seti (TA, YM20 ve YM10) üzerinde kapsamlı bir şekilde değerlendirilmiştir. Analizler, öneri sistemlerinin doğruluk, yenilik, çeşitlilik, uzun kuyruk kapsama ve adalet açısından çok boyutlu performansını değerlendirmek amacıyla genel, kriter ve toplu olmak üzere üç farklı düzeyde gerçekleştirilmiştir. Veri setleri arasındaki yapısal farklılıklar hem algoritmaların hem de yöntemlerin performansını doğrudan etkilemiştir.

TA veri setinde, tüm analiz yöntemlerinde ve kullanıcı popülerlik eğilimi yöntemlerinde önerilerin doğruluğu ve sistem başarısında en seyrek veri seti olmasına rağmen RelPref yöntemi doğruluk metriklerinde kullanıcıya özgü içeriklerin sunulması ve sistem başarısının da üstün başarı göstermektedir. Yeni ve popüler olmayan ürünleri önerme bakımından Mul yöntemi ve Aug yöntemi ne kadar başarılı olsa da düşük kullanıcı ihtiyaçlarını karşılama ve sistem başarısı nedeniyle kullanıcı memnuniyeti sağlayamamıştır. Mul yöntemi tüm kullanıcı popülerlik eğilimi belirleme yöntemlerinde en düşük çeşitlilik sağlayan algoritma olduğu bulgusuna varılmıştır. Önerilen yöntemlerin başarısı incelendiğinde, RelPref yöntemi toplama tabanlı analizde Aug yönteminden sonra çeşitli öneriler sunan yöntem olarak seyrek veri setlerinde de çeşitli öneriler sunabildiğini göstermektedir. PriRelPref algoritması ise toplama tabanlı analizde düşük değerler olsa da kriter ve genel bazlı analizde performansını iki katına çıkardığı gözlenmektedir. PriRelPref algoritmasının tüm analiz ve kullanıcı popülerlik eğilimi yöntemlerinde doğruluk metriklerinde aynı değeri alması, performansını etkilemediği gözlemlenmiştir.

RelPref ve yöntemi PriRelPref özellikle RPI kullanıcı popülerlik tespit yöntemi ile birlikte kullanıldığında en başarılı sonuçları elde etmektedir. Bu kombinasyon doğruluk odaklı senaryolarda tercih edilmelidir. PriRelPref yöntemi özellikle BTA_{RPI} kullanıcı popülerlik tespit yöntemi ile birlikte kullanıldığında en yüksek çeşitlilik başarısını göstermektedir. Bu kombinasyon çeşitlilik odaklı senaryolarda tercih edilmelidir. Her iki yöntem de farklı kullanıcı popülerlik tespit yöntemleri ile birlikte kullanıldığında farklı avantajlar sunmaktadır ve kullanıcı ihtiyaçlarına göre tercih edilmelidir.

YM20 veri seti üzerinde gerçekleştirilen dört farklı kullanıcı popülerlik eğilimi belirleme yöntemi ile üç farklı analiz sonucunda, analizler teker teker değerlendirildiğinde toplama tabanlı analizde kullanıcıya en doğru ve kişiselleştirilmiş öneriler sunan ve öneri sisteminin başarısını sağlayan algoritma, BTA_{APRI} kullanıcı popülerlik eğilimi belirleme yönteminde RelPref algoritması olduğu gözlenmiştir. Uzun kuyruk önerileri ve yenilik açısından karşılaştırılan yöntemlerden olan Mul yöntemi, tüm analiz türlerinde ve kullanıcı popülerlik eğilimi yöntemlerinde başarılı olsa da kullanıcıyı memnun edecek ürünler sunamamıştır. Toplama tabanlı analizde önerilen yöntemlerin başarısına bakıldığında, RelPref ve PriRelPref BTA_{APRI} yönteminde doğruluk metriklerinde başarı göstermektedir. İki yöntem de popülerlik yanlılığının azaltılması bakımından RPI yönteminde başarılı olurken çeşitlilik açısından BTA_{APRI} yöntemlerinde kendi en üst değerlerini almışlardır.

Kriter tabanlı analizler incelendiğinde ise doğruluk metriklerinde RelPref yönteminin başarısı dikkat çekmektedir. Bu başarısı DUoR yöntemiyle başa baş gitse de Geri çağırma (Recall) ve F1-Score metriklerinde RelPref algoritması $APRI$ yöntemlerinde yüksek değer olarak göstermektedir $APRI$ senaryosu: 0.2501 (En yüksek) BTA_{APRI} senaryosu: 0.25 (İkinci en yüksek). Mul yöntemi kullanıcı popülerlik eğilimi ve çeşitlilik konularında ön plana çıksa da diğer yöntem ve analizlerde olduğu gibi sistem ve öneri doğruluğu açısından en düşük değerleri almıştır. PriRelPref algoritması Mul algoritmasından sonra en heterojen yapıda öneri sunarak kullanıcı memnuniyeti sağlandığı bulgusuna varılmıştır.

Genel tabanlı analiz incelendiğinde, kullanıcı memnuniyeti ve sistem başarısı açısından BTA_{APRI} yönteminde DUoR algoritması ile RelPref algoritması arasında küçük bir fark gözlemlenmekte ve niş ürünlerin önerilmesi açısından kriter tabanlı analizde varılan sonuçlarla eşdeğer sonuçlar taşımaktadır. Burada çarpıcı olarak değişiklik gösteren Aug algoritmasının genel tabanlı analizde en çeşitli öneri sunduğu bulgusudur. Çeşitli öneriler sunması kullanıcıyı tatmin etmemiş, sistem başarısı düşük olarak incelenmiştir. Genel tabanlı analizde doğruluk metriklerinde RelPref yönteminden sonra ikinci yüksek değer alan yöntem PriRelPref algoritmasıdır. Bu başarı $APRI$ kullanıcı popülerlik eğilimi belirleme yönteminde sağlanmıştır. Önerilen iki yöntem de popülerlik yanlılığını azaltma açısından kendi en yüksek performanslarını RPI yönteminde, en çeşitli önerileri de BTA_{RPI} yönteminde göstermişlerdir.

Genel olarak Doğruluk ve kullanıcı memnuniyeti açısından değerlendirildiğinde, tüm kullanıcı popülerlik eğilimi belirleme yöntemlerinde, önerilen RelPref ve PriRelPref yöntemleri çoğunlukla BTA_{APRI} yönteminde, kriter tabanlı ve toplama tabanlı analizlerde önerilen yöntemlerin kullanıcı memnuniyeti açısından daha yüksek performans gösterdikleri gözlemlenmiştir. Bu durum, çok ölçütlü öneri sistemlerinde önerilen yöntemlerin kullanıcı tercihlerini daha iyi yansıtabildiğini göstermektedir. Popülerite yanlılığını azaltma konusunda, BTA_{RPI} ve RPI yöntemi en başarılı sonuçları üretmiştir. Bu yöntemde önerilen yöntemler, kullanıcıların bireysel beğeni eşiklerini dikkate alarak daha etkili popülerite yanlılığı azaltma stratejileri geliştirmiştir.

Dört farklı kullanıcı popülerlik eğilimi belirleme yöntemi arasında, önerilen yöntemlerin BTA_{APRI} yönteminde kullanıcı memnuniyeti ve sistem başarısını sağlarken BTA_{RPI} ve RPI yönteminin en dengeli ve çeşitli sonuçları ürettiği gözlemlenmiştir. Bu yöntem, kullanıcıların bireysel beğeni eşiklerini dikkate alarak daha kişiselleştirilmiş değerlendirmeler yapmaktadır. YM20 veri seti TA veri setine göre daha yoğun veri seti olduğu için doğruluk metriklerinde daha yüksek sonuçlar elde edilmiştir. Önerilen yöntemlerin tüm kullanıcı popülerlik eğilimi belirleme yöntemlerinde kriter bazlı analizlerinde doğruluk değerleri diğer analizlere göre yüksek performans göstermektedir. Genel olarak ver setinin yoğunluğu arttıkça elde edilen doğruluk değerleri de önerilen yöntemlerin performansları da artmaktadır.

YM10 veri setinde gerçekleştirilen analizler sonucunda toplama tabanlı analizde kullanıcı memnuniyeti ve sistem açısından bakıldığında kullanıcı popülerlik eğilimi tespit yöntemlerinden $APRI$ yönteminde Relpref algoritması 0,0045 değeri ile en yüksek Precision değerine sahiptir. Yenilik ve uzun kuyruk önerilerinin öneri sürecine dahil edilmesi açısından ise tüm yöntemlerde Mul algoritması başarılı olsa da kullanıcı memnuniyeti ve sistem başarısı bakımından başarısı olmuştur. Sunulan önerilerin çeşitliği açısından önerilen yöntemlerden PriRelPref yöntemi tüm kullanıcı popülerlik eğilimi belirleme yöntemlerinde en yüksek değer (0,8291) ile en çeşitli öneri sunan algoritma olmuştur. YM10 veri seti toplama tabanlı analizlerde RelPref ve PriRelPref yöntemlerinin başarısına bakılacak olursa: Kullanıcı popülerlik eğilimi yöntemlerinden popülerite yanlılığını en iyi azaltan yöntem olarak RPI yönteminde başarılı olmuşlardır. PriRelPref algoritması kullanıcı memnuniyetini en iyi sağladığı yöntem BTA_{APRI} yönteminde (Precision: 0,0357, Recall: 0,0143, F1-Score: 0,0169) değerleri ile başarı göstermiştir.

Kriter tabanlı analizler incelendiğinde ise Kullanıcı memnuniyetini BTA_{APRI} yönteminde DUoR algoritması ve RelPref algoritması (0,0512, 0,0509) sistem başarı sağlamıştır. Popülarite yanlılığını yönetme açısından Mul algoritması agresif bir tavır sergileyerek yeniden ön plana çıkmıştır. Çeşitlilik açısından PriRelPref algoritması Tüm kullanıcı popülerlik eğilimi yöntemlerinde en çeşitli öneriyi sunan algoritma olmuştur. En yüksek performansı ise BTA_{APRI} kullanıcı popülerlik eğilimi belirleme yönteminde göstermiştir. BTA_{APRI} yöntemi önerilen algoritmaların hem kullanıcı ve sistem performansında hem de popülerlik yanlılığı azaltma açısından en yüksek performansları gösterdiği yöntem olmuştur.

YM10 veri seti genel tabanlı analizde DUoR yöntemi doğruluk metriklerinde ön plana çıksa da çeşitlilik ve uzun kuyruk ürünlerinde aynı başarıyı gösterememiştir. Genel tabanlı analizde çeşitlilik açısından yine PriRelPref yöntemi en başarılı çeşitli öneriler sunan algoritma olarak karşılaşmaktayız. Genel tabanlı analizde Popülarite yanlılığı yönetme ve uzun kuyruk ürünleri başarısı açısından Önerilen yöntemler değerlendirilecek olunursa RelPref ve PriRelPref algoritması RPI yönteminde diğer yöntemlerine göre üstün başarı sağlamıştır. Çeşitlilik açısından RelPref algoritması en iyi performansını BTA_{RPI} yönteminde göstermiştir.

YM10 veri seti kullanıcı sayısı en yüksek veri seti olduğu için önerilen PriRelPref algoritması çeşitlilik konusunda Toplama tabanlı, Kriter tabanlı ve Genel tabanlı analizlerin hepsinde en yüksek performansı göstermiştir. RPI ve APRI yöntemlerin de kriter bazlı analizde diğer kullanıcı popülerlik eğilimi yöntemlerine göre Novelty, APLT ve LTC metriklerin de kendi içlerinde en yüksek değerleri alarak hem popülarite yanlılığını azaltma hem de Precision, Recall ve F1-Score metrik değerlerinde yüksek performans sağlayarak çok ölçütlü öneri sistemlerinde kullanıcılara çeşitli türlerde öneriler sunarak hem kullanıcı memnuniyeti sağlandığı hem uzun kuyruk ürünlerinin önerildiği gösterilmektedir.

Bu tez kapsamında önerilen RelPref ve PriRelPref algoritmalarının, farklı kullanıcı popülerlik eğilimi belirleme yöntemleriyle birlikte kullanıldığında çok ölçütlü öneri sistemlerinde popülarite yanlılığını azaltma, öneri çeşitliliğini artırma ve kullanıcı memnuniyetini sağlama açısından yüksek performans sergilediği görülmüştür. Bu durum, geliş-

tirilen yöntemlerin hem sistem başarısını hem de kullanıcı deneyimini iyileştirme potansiyeline sahip olduğunu göstermektedir. Bu tez çok ölçütlü öneri sistemlerinde popülerlik yanlılığı problemini ele alan literatürde önemli boşlukları dolduran kapsamlı bir araştırma olarak literatüre katkı sağlamaktadır. Literatürde mevcut popülerlik yanlılığı azaltma çalışmaları genellikle genel popülerlik kontrolü yaparken, her bir kriter için ayrı popülerlik eğilimlerinin analiz edilmesi konusunda belirgin bir eksiklik bulunmaktadır. Bu çalışma, kullanıcıların farklı kriterlere verdikleri önem derecelerini dikkate alarak kriter bazlı popülerlik analizi yapan ilk kapsamlı araştırma olarak literatüre katkı sağlamaktadır.

Bu tez çalışması, literatürde çok ölçütlü öneri sistemleri bağlamında popülerlik yanlılığını sistematik olarak ele alan ilk kapsamlı araştırma olarak, bu alanda gelecekteki araştırmalar için önemli bir teorik ve metodolojik temel oluşturmaktadır. Önerilen yöntemler, literatürdeki mevcut yaklaşımlardan farklı olarak, kullanıcıların puanlama davranışlarının bağlamsal doğasını dikkate alan ilk çok ölçütlü popülerlik yanlılığı azaltma yöntemleridir. Yapılan kapsamlı deneysel analizler, bu yöntemlerin yalnızca doğruluk metrikleri açısından değil; aynı zamanda çeşitlilik, uzun kuyruk öge önerimi ve sistemsel adalet gibi çok boyutlu ölçütler bakımından da güçlü performans sergilediğini ortaya koymuştur. Farklı veri setleri ve kullanıcı senaryoları üzerinden gerçekleştirilen değerlendirmeler, önerilen modellerin hem kullanıcı odaklı hem de sistem bütünlüğünü gözeten dengeli çözümler sunduğunu göstermektedir. Doğruluk odaklı uygulamalarda RelPref, çeşitlilik odaklı uygulamalarda ise PriRelPref yönteminin tercih edilmesi önerilmektedir.

KAYNAKÇA

- Abdollahpouri, H., Burke, R. ve Mobasher, B. (2017). Controlling popularity bias in learning-to-rank recommendation. *RecSys 2017 - Proceedings of the 11th ACM Conference on Recommender Systems*, 42-46. doi:10.1145/3109859.3109912
- Abdollahpouri, H., Burke, R. ve Mobasher, B. (2019). Managing Popularity Bias in Recommender Systems with Personalized Re-ranking. <http://arxiv.org/abs/1901.07555>
- Adomavicius, G. ve Kwon, Y. O. (2012). Improving aggregate recommendation diversity using ranking-based techniques. *IEEE Transactions on Knowledge and Data Engineering*, 24(5), 896-911. doi:10.1109/TKDE.2011.15
- Adomavicius, G. ve Tuzhilin, A. (2005). 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*, 17(6), 734-749. doi:10.1109/TKDE.2005.99
- Alhijawi, B., Obeid, N., Awajan, A. ve Tedmori, S. (2022). New hybrid semantic-based collaborative filtering recommender systems. *International Journal of Information Technology (Singapore)*, 14(7), 3449-3455. doi:10.1007/S41870-022-01011-X
- Basilico, J. ve Hofmann, T. (2004). Unifying collaborative and content-based filtering. *Proceedings, Twenty-First International Conference on Machine Learning, ICML 2004*, 65-72. doi:10.1145/1015330.1015394
- Bellogín, A., Castells, P. ve Cantador, I. (2017). Statistical biases in Information Retrieval metrics for recommender systems. *Information Retrieval Journal*, 20(6), 606-634. doi:10.1007/S10791-017-9312-Z/FIGURES/9
- Breiman, L., Friedman, J. H., Olshen, R. A. ve Stone, C. J. (2017). Classification and regression trees. *Classification and Regression Trees*, 1-358. doi:10.1201/9781315139470/classification-regression-trees-leo-breiman-jerome-friedman-olshen-charles-stone/rights-and-permissions
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4), 331-370. doi:10.1023/A:1021240730564
- Das, C., Sahoo, A. K. ve Pradhan, C. (2022). Multi-Criteria-Based Entertainment Recommender System Using Clustering Approach. *Advanced Analytics and Deep Learning Models*, 33-63. doi:10.1002/9781119792437.CH3

- Goldberg, D., Nichols, D., Oki, B. M. ve Terry, D. (1992). Using collaborative filtering to Weave an Information tapestry. *Communications of the ACM*, 35(12), 61-70. doi:10.1145/138859.138867/asset/74169bf6-30c5-4f64-80ac-093322ab4cf5/assets/138859.138867.fp.png
- Gomez-Uribe, C. A. ve Hunt, N. (2015). The netflix recommender system: Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems*, 6(4). doi:10.1145/2843948
- Gulsoy, M., Yalcin, E., Tacli, Y. ve Bilge, A. (2025). DUoR: Dynamic User-oriented re-Ranking calibration strategy for popularity bias treatment of recommendation algorithms. *International Journal of Human-Computer Studies*, 203, 103578. doi:10.1016/J.IJHCS.2025.103578
- Hdioud, F., Frikh, B. ve Ouhbi, B. (2013). Multi-criteria recommender systems based on multi-attribute decision making. *ACM International Conference Proceeding Series*, 203-210. doi:10.1145/2539150.2539176
- Herlocker, J. L., Konstan, J. A., Terveen, L. G. ve Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems (TOIS)*, 22(1), 5-53. doi:10.1145/963770.963772
- Jannach, D. (2022). Multi-Objective Recommender Systems: Survey and Challenges. *CEUR Workshop Proceedings*, 3268. <https://arxiv.org/abs/2210.10309v1> adresinden erişildi.
- Jannach, D., Kamehkhosh, I. ve Lerche, L. (2017). Leveraging multi-dimensional user models for personalized next-track music recommendation. *Proceedings of the ACM Symposium on Applied Computing, Part F128005*, 1635-1642. doi:10.1145/3019612.3019756
- Jannach, D., Lerche, L., Gedikli, F. ve Bonnin, G. (2013). What recommenders recommend - An analysis of accuracy, popularity, and sales diversity effects. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7899 LNCS, 25-37. doi:10.1007/978-3-642-38844-6_3
- Jannach, D., Lerche, L., Kamehkhosh, I. ve Jugovac, M. (2015). What recommenders recommend: an analysis of recommendation biases and possible countermeasures.

- User Modeling and User-Adapted Interaction*, 25(5), 427-491. doi:10.1007/S11257-015-9165-3/TABLES/23
- Jannach, D., Zanker, M., Felfernig, A. ve Friedrich, G. (2010). Recommender Systems: An Introduction. *Recommender Systems: An Introduction*, 9780521493369, 1-335. doi:10.1017/CBO9780511763113
- Kamishima, T., Akaho, S., Asoh, H. ve Sakuma, J. (2014). *Correcting Popularity Bias by Enhancing Recommendation Neutrality*. <http://www.sfu.ca/~sja25/datasets/> adresinden erişildi.
- Kang, W. C. ve McAuley, J. (2018). Self-Attentive Sequential Recommendation. *Proceedings - IEEE International Conference on Data Mining, ICDM, 2018-November*, 197-206. doi:10.1109/ICDM.2018.00035
- Klimashevskaya, A., Jannach, D., Elahi, M. ve Trattner, C. (2024). A survey on popularity bias in recommender systems. *User Modeling and User-Adapted Interaction*, 34(5), 1777-1834. doi:10.1007/S11257-024-09406-0/FIGURES/12
- Klimashevskaya, A., Jannach, D., Elahi, M., Trattner, C. ve Trattner Christoph Trattner, C. (2024). A Survey on Popularity Bias in Recommender Systems. *User Modeling and User-Adapted Interaction*. doi:10.1007/s11257-024-09406-0
- Knijnenburg, B. P., Willemsen, M. C., Gantner, Z., Soncu, H. ve Newell, C. (2012). Explaining the user experience of recommender systems. *User Modeling and User-Adapted Interaction*, 22(4-5), 441-504. doi:10.1007/S11257-011-9118-4
- Konstan, J. A., Riedl, J., Konstan, J. A. ve Riedl, J. (2012). Recommender systems: from algorithms to user experience, 22, 101-123. doi:10.1007/s11257-011-9112-x
- Koren, Y., Bell, R. ve Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), 30-37. doi:10.1109/MC.2009.263
- Kowald, D. ve Lacić, E. (2022). Popularity Bias in Collaborative Filtering-Based Multimedia Recommender Systems. *Communications in Computer and Information Science*, 1610 CCIS, 1-11. doi:10.1007/978-3-031-09316-6_1
- Lakiotaki, K., Matsatsinis, N. F. ve Tsoukiàs, A. (2011). Multicriteria user modeling in recommender systems. *IEEE Intelligent Systems*, 26(2), 64-76. doi:10.1109/MIS.2011.33
- Lee, J., Sun, M. ve Lebanon, G. (2012). *A Comparative Study of Collaborative Filtering Algorithms*.

- Li, Y., Liu, K., Satapathy, R., Wang, S. ve Cambria, E. (2024). Recent Developments in Recommender Systems: A Survey [Review Article]. *IEEE Computational Intelligence Magazine*, 19(2), 78-95. doi:10.1109/MCI.2024.3363984
- Liu, Q., Hu, J., Xiao, Y., Zhao, X., Gao, J., Wang, W., ... Tang, J. (2023). Multimodal Recommender Systems: A Survey. *ACM Computing Surveys*, 57(2). doi:10.1145/3695461
- Lops, P., de Gemmis, M. ve Semeraro, G. (2011). Content-based Recommender Systems: State of the Art and Trends. *Recommender Systems Handbook*, 73-105. doi:10.1007/978-0-387-85820-3_3
- McNee, S. M., Riedl, J. ve Konstan, J. A. (2006). Being accurate is not enough: How accuracy metrics have hurt recommender systems. *Conference on Human Factors in Computing Systems - Proceedings*, 1097-1101. doi:10.1145/1125451.1125659
- Park, Y. J. ve Tuzhilin, A. (2008). The long tail of recommender systems and how to leverage it. *RecSys'08: Proceedings of the 2008 ACM Conference on Recommender Systems*, 11-18. doi:10.1145/1454008.1454012
- Pazzani, M. J. ve Billsus, D. (2007). Content-Based Recommendation Systems. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 4321 LNCS, 325-341. doi:10.1007/978-3-540-72079-9_10
- Ricci, F., Rokach, L. ve Shapira, B. (2011). Introduction to Recommender Systems Handbook. *Recommender Systems Handbook*, 1-35. doi:10.1007/978-0-387-85820-3_1
- Ricci, F., Shapira, B. ve Rokach, L. (2015). Recommender Systems: Introduction and Challenges. *Recommender Systems Handbook, Second Edition*, 1-34. doi:10.1007/978-1-4899-7637-6_1
- Sanders, R. (1987). The pareto principle: Its use and abuse. *Journal of Services Marketing*, 1(2), 37-40. doi:10.1108/EB024706
- Sarwar, B., Karypis, G., Konstan, J. ve Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th International Conference on World Wide Web, WWW 2001*, 285-295. doi:10.1145/371920.372071
- Schafer, J. Ben, Frankowski, D., Herlocker, J. ve Sen, S. (2007). Collaborative Filtering Recommender Systems. *Lecture Notes in Computer Science (including subseries*

- Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics*), 4321 LNCS, 291-324. doi:10.1007/978-3-540-72079-9_9
- Schein, A. I., Popescul, A., Ungar, L. H. ve Pennock, D. M. (2002). Methods and metrics for cold-start recommendations, 253-260. doi:10.1145/564376.564421
- Steck, H. (2018). Calibrated recommendations. *RecSys 2018 - 12th ACM Conference on Recommender Systems*, 154-162. doi:10.1145/3240323.3240372/suppl_file/p154-steck.mp4
- Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W. ve Jiang, P. (2019). BERT4Rec: Sequential Recommendation with Bidirectional Encoder Representations from Transformer. *International Conference on Information and Knowledge Management, Proceedings*, 11, 1441-1450. doi:10.1145/3357384.3357895
- Tacılı, Y., Yalcin, E. ve Bilge, A. (2022). Novel approaches to measuring the popularity inclination of users for the popularity bias problem. *ISMSIT 2022 - 6th International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*, 555-560. doi:10.1109/ISMSIT56059.2022.9932663
- Tang, T. Y. (2009). The Pedagogical Value of Papers: a Collaborative-Filtering based Paper Recommender. 15 Haziran 2025 tarihinde https://www.researchgate.net/publication/31914829_The_Pedagogical_Value_of_Papers_a_Collaborative-Filtering_based_Paper_Recommender adresinden erişildi.
- Vargas, S. ve Castells, P. (2011). *Rank and Relevance in Novelty and Diversity Metrics for Recommender Systems*.
- Wang, H., Wang, N. ve Yeung, D. Y. (2014). Collaborative Deep Learning for Recommender Systems. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2015-August*, 1235-1244. doi:10.1145/2783258.2783273
- Wang, S., Cao, L., Wang, Y., Sheng, Q. Z., Orgun, M. A. ve Lian, D. (2023). A Survey on Session-based Recommender Systems. *ACM Computing Surveys*, 54(7). doi:10.1145/3465401/SUPPL_FILE/WANG.ZIP
- Wang, X., He, X., Wang, M., Feng, F. ve Chua, T. S. (2019). Neural graph collaborative filtering. *SIGIR 2019 - Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 165-174. doi:10.1145/3331184.3331267

- Wei, T., Feng, F., Chen, J., Wu, Z., Yi, J. ve He, X. (2021). Model-Agnostic Counterfactual Reasoning for Eliminating Popularity Bias in Recommender System. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1791-1800. doi:10.1145/3447548.3467289
- Xie, X., Sun, F., Liu, Z., Wu, S., Gao, J., Ding, B. ve Cui, B. (2020). Contrastive Learning for Sequential Recommendation, *10243*, 11. doi:10.1145/1122445.1122456
- Yalcin, E. ve Bilge, A. (2021). Investigating and counteracting popularity bias in group recommendations. *Information Processing & Management*, 58(5), 102608. doi:10.1016/J.IPM.2021.102608
- Yalcin, E. ve Bilge, A. (2023). Popularity bias in personality perspective: An analysis of how personality traits expose individuals to the unfair recommendation. *Concurrency and Computation: Practice and Experience*, 35(9). doi:10.1002/CPE.7647
- Zehlike, M., Bonchi, F., Castillo, C., Hajian, S., Megahed, M. ve Baeza-Yates, R. (2018). FA*IR: A Fair Top-k Ranking Algorithm. *International Conference on Information and Knowledge Management, Proceedings, Part F131841*, 1569-1578. doi:10.1145/3132847.3132938
- Zhang, Y. ve Chen, X. (2020). Explainable Recommendation: A Survey and New Perspectives. *Foundations and Trends in Information Retrieval*, 14(1), 1-101. doi:10.1561/15000000066
- Zhang, Y., Zhang, M., Liu, Y. ve Ma, S. (2013). Improve collaborative filtering through bordered block diagonal form matrices. *SIGIR 2013 - Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 313-322. doi:10.1145/2484028.2484101
- Zhoua, T., Kuscsik, Z., Liu, J. G., Medo, M., Wakeling, J. R. ve Zhang, Y. C. (2010). Solving the apparent diversity-accuracy dilemma of recommender systems. *Proceedings of the National Academy of Sciences of the United States of America*, 107(10), 4511-4515. doi:10.1073/PNAS.1000488107/SUPPL_FILE/PNAS.1000488107_SI.PDF
- Ziegler, C.-N., McNee, S. M., Konstan, J. A. ve Lausen, G. (2005). Improving recommendation lists through topic diversification, 22. doi:10.1145/1060745.1060754

EKLER

EK 1. ORJİNALLİK RAPORU FORMU



ARDAHAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ ÇALIŞMASI ORJİNALLİK RAPORU

ARDAHAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANA BİLİM DALI BAŞKANLIĞINA

Tarih: 15/09/2025

Tez Başlığı: Çok Ölçütlü Öneri Sistemlerinde Popülarite Yanlılığını Yönetme

Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam 75 sayfalık kısmına ilişkin, 15/09/2025 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda işaretlenmiş filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 13 'tür.

Uygulanan filtrelemeler:

- 1- ☒ Kabul/Onay ve Bildirim sayfaları hariç
- 2- ☒ Kaynakça hariç
- 3- ☒ Alıntılar dâhil
- 4- ☒ 5 kelimeden daha az örtüşme içeren metin kısımları hariç

Ardaahan Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nde belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

15.09.2025

Adı Soyadı:	Nilüfer Ballı
Öğrenci No:	22408700019
Ana Bilim Dalı:	İleri Teknolojiler ABD.
Programı:	İleri Teknolojiler
Statüsü:	☒ Yüksek Lisans ☐ Doktora

DANIŞMAN GÖRÜŞÜ VE ONAYI

Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA

Detaylı Bilgi: <https://www.ardahan.edu.tr/birim.aspx?id=1002003>

Telefon: 0-4782117522

Faks: 0-4782117523

E-posta: sbe@ardahan.edu.tr

EK 2. ETİK KURUL İZNİ YA DA ETİK KURUL MUAFİYET FORMU

ARDAHAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ ÇALIŞMASI ETİK KOMİSYON MUAFİYETİ FORMU

ARDAHAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
İLERİ TEKNOLOJLER ANA BİLİM DALI BAŞKANLIĞINA

Tarih: 15/09/2025

Tez Başlığı: Çok Ölçütlü Öneri Sistemlerinde Popülarite Yanlılığını Yönetme

Yukarıda başlığı gösterilen tez çalışmam:

1. İnsan ve hayvan üzerinde deney niteliği taşımamaktadır,
2. Biyolojik materyal (kan, idrar vb. biyolojik sıvılar ve numuneler) kullanılmasını gerektirmemektedir.
3. Beden bütünlüğüne müdahale içermemektedir.
4. Gözlemsel ve betimsel araştırma (anket, mülakat, ölçek/skala çalışmaları, dosya taramaları, veri kaynakları taraması, sistem-model geliştirme çalışmaları) niteliğinde değildir.

Tez çalışmamın yürütülebilmesi için herhangi bir Etik Kurul/Komisyon'dan izin alınmasına gerek olmadığını; aksi durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

15.09.2025

Adı Soyadı: Nilüfer Ballı
 Öğrenci No: 22408700019
 Ana Bilim Dalı: İleri Teknolojiler ABD.
 Programı: İleri Teknolojiler
 Statüsü: ☒ Yüksek Lisans ☐ Doktora

DANIŞMAN GÖRÜŞÜ VE ONAYI

Dr. Öğr. Üyesi Tuğba TÜRKOĞLU KAYA

Detaylı Bilgi: <https://www.ardahan.edu.tr/birim.aspx?id=1002003>

Telefon: 0-4782117522

Faks: 0-4782117523

E-posta: sbe@ardahan.edu.tr

ÖZ GEÇMİŞ**Kişisel Bilgiler**

Adı Soyadı : Nilüfer Ballı

Doğum Yeri ve Tarihi :

Eğitim Durumu

Lisans Öğrenimi : Erzurum Teknik Üniversitesi,
Bilgisayar Mühendisliği Bölümü (2018-2022)

Yüksek Lisans Öğrenimi : Ardahan Üniversitesi Lisansüstü Eğitim Enstitüsü İleri
Teknolojiler Anabilim Dalı (2022-)

Bildiği Yabancı Diller : İngilizce

İş Deneyimi

Stajlar : Dinosoft Business Solutions (2022)
Atatürk Üniversitesi Bilgisayar Bilimleri Araştırma
ve Uygulama Merkezi (2021)

İletişim

E-Posta Adresi :

Tarih

Jüri Tarihi : 29.08.2025