



DAVRANIŞSAL EĞİLİMLERE DAYALI ÇOK ÖLÇÜTLÜ ÖNERİ SİSTEMLERİ: BADPM MODELİ

Tuğba TÜRKÖĞLU KAYA^{1*}

¹Ardahan University, Faculty of Engineering, Department of Computer Engineering, 75000, Ardahan, Türkiye

Özet: Günümüzde öneri sistemleri oldukça başarılı tavsiyeler üretse de kullanıcıların daha az bilinen ancak potansiyel olarak ilgi çekici ürünlere erişimini kısıtlayan önemli bir sorun olan popülerlik yanlılığı ile karşı karşıya kalmaktadır. Bu çalışmada çok ölçütlü öneri sistemlerinde popülerlik yanlılığı probleminin ele alındığı, memnuniyetin artırılıp buna ek olarak listede popüler olmayan ürünlerin yer aldığı bir mekanizma geliştirilmiştir. Önerilen yöntemde, bireylerin karar verme süreçlerinde kendi zevk ve eğilimlerine benzeyen kullanıcıların tercihlerine daha fazla önem vermesine, buna karşılık zıt eğilimlere sahip kullanıcıların değerlendirmelerini sınırlı düzeyde dikkate alma eğilimine dayanmaktadır. Dahası, zıt eğilimli kullanıcıların olumsuz değerlendirdiği ürünlerin kimi durumlarda hedef kullanıcı için daha çekici hâle gelebileceği varsayılmaktadır. Bu davranışsal temelden hareketle geliştirilen yaklaşım, öneri listesi oluştururken hem benzer kullanıcıların tercihlerini hem de zıt eğilimlere sahip kullanıcıların değerlendirmelerini birlikte ele almaktadır. Üç farklı veri seti üzerinde önerilen yöntem ile klasik yöntemlerin karşılaştırmalı analiz sonuçları yapılmış ve elde edilen sonuçlar, önerilen yaklaşımın popülerlik yanlılığını azaltmada ve öneri kalitesini artırmada başarılı olduğunu göstermiştir.

Anahtar kelimeler: Çok ölçütlü öneri sistemleri, Popülerlik yanlılığı, Kişiselleştirilmiş öneriler, Davranışsal modelleme

A Multi-Criteria Recommendation Systems Based on Behavioral Tendencies: BADPM Model

Abstract: Although contemporary recommender systems achieve highly effective recommendation performance, they continue to suffer from popularity bias—a pervasive issue that restricts users’ exposure to less popular yet potentially relevant items. This study develops a mechanism that addresses popularity bias in multi-criteria recommendation systems, increasing satisfaction and including unpopular products in the list. The proposed method is based on the tendency for individuals to prioritize the preferences of users who are similar to their own tastes and preferences in their decision-making processes, while only slightly considering the evaluations of users with opposing tendencies. Furthermore, it is assumed that products negatively evaluated by users with opposing tendencies can sometimes become more attractive to the target user. Building on this behavioral foundation, the approach considers both the preferences of similar users and the evaluations of users with opposing tendencies when generating a recommendation list. Comparative analyses of the proposed method with traditional methods are conducted on three different datasets, and the results demonstrate that the proposed approach is successful in reducing popularity bias and improving recommendation quality.

Keywords: Multi-criteria recommender systems, Popularity bias, Personalized recommendations, Behavioral modeling

*Sorumlu yazar (Corresponding author): Ardahan University, Faculty of Engineering, Department of Computer Engineering, 75000, Ardahan, Türkiye

E mail: tugbaturkoglu@ardahan.edu.tr (T. T. KAYA)

Tuğba TÜRKÖĞLU KAYA <https://orcid.org/0009-0006-8218-182X>

Gönderi: 24 Kasım 2025

Received: November 24, 2025

Kabul: 16 Şubat 2026

Accepted: February 16, 2026

Yayınlanma: 15 Mart 2026

Published: March 15, 2026

Cite as: Türköğlü Kaya, T. (2026). A multi-criteria recommendation systems based on behavioral tendencies: BADPM model. *Black Sea Journal of Engineering and Science*, 9(2), 759-768.

1. Giriş

Günümüz teknolojisinde yaşanan bilimsel ve teknik gelişmeler ile internet altyapısının hızlı bir biçimde genişlemesi, dijital ortamda devasa boyutlarda veri birikimine yol açmıştır. Ortaya çıkan bu büyük veri yığınları, kullanıcıların aradıkları bilgilere ulaşma ve karar verme süreçlerini önemli ölçüde zorlaştırmakta; zaman kaybına, dikkat dağınıklığına ve kullanıcı memnuniyetinin azalmasına neden olabilmektedir. Bu durum, özellikle rekabetin yoğun olduğu dijital hizmet platformlarında hizmet sağlayıcıların görünürliğini olumsuz etkileyerek alt sıralara düşmelerine yol açabilmektedir.

Söz konusu problemlerin giderilmesi amacıyla geliştirilen “Öneri Sistemleri”, aşırı bilgi yükü sorununu azaltarak

kullanıcıların çok sayıdaki alternatif arasından ihtiyaçlarına ve ilgilerine en uygun, anlamlı ve ilgi çekici seçeneklere yönlendirilmesini sağlamaktadır (Isinkaye vd., 2015). Bu sistemlerde kullanıcılar, deneyimlerine ilişkin değerlendirmelerini çoğunlukla metin yorumları veya puanlama yoluyla geri bildirim olarak sunmaktadır. Geleneksel tek ölçütlü öneri sistemlerinde kullanıcı görüşleri tek bir kritere dayalı olarak analiz edilirken, son yıllarda popülerliği giderek artan çok ölçütlü öneri sistemleri—kullanıcı tercihlerini birden fazla boyutta ele alarak—öneri doğruluğunu ve sistem performansını önemli ölçüde artırmaktadır. Bu çok ölçütlü yapılar, kullanıcıların ihtiyaç ve beklentilerini daha ayrıntılı biçimde modelleyebilme kapasitesi sayesinde daha kapsamlı, hassas ve kişiselleştirilmiş öneriler



sunmaktadır. Ancak her ne kadar bu sistemler üzerinde gerçekleştirilen çalışmalarda oldukça başarılı tavsiyeler üretilse de (Pichl vd., 2014; Ren vd., 2012; Cremonesi vd., 2010; Lee vd., 2016; Kang vd., 2016; Xue vd., 2019), bu sistemlerin popülerlik yanlılığı olarak adlandırılan, önerilerin çeşitliliğini sınırlandıran temel bir sorun yer almaktadır. Türkoğlu Kaya (2025a), SHAP tabanlı DUTR modeliyle kullanıcıların kriter önceliklerini dikkate alarak popülerlik yanlılığını azaltan açıklanabilir bir yaklaşım sunmuştur. Popülerlik yanlılığını kullanıcı eğilimleri üzerinden inceleyen Ballı ve Türkoğlu Kaya (2025) ise RelPop yöntemiyle yenilik ve çeşitlilik açısından geleneksel tekniklere göre daha başarılı sonuçlar elde etmiştir. Öte yandan Türkoğlu Kaya (2025c), kişilik özelliklerinin öneri doğruluğu ve popülerlik yanlılığı üzerindeki etkisini inceleyerek belirli kişilik boyutlarının uzun kuyruk performansını anlamlı biçimde etkilediğini göstermiştir. Abdollahpouri vd. (2017), popüler ve daha az popüler öğeler arasındaki dengeyi sağlamayı amaçlayan bir learning-to-rank algoritması geliştirmiştir. Bu yaklaşımın, öneri kalitesini hem doğruluk hem de çeşitlilik açısından iyileştirdiği gösterilmiştir. Başka bir çalışmada Abdollahpouri vd. (2018), uzun kuyruk öğelerinin önerilme oranını artırmak için popülerlik farkındalığına dayalı bir ağırlıklandırma yöntemi önermiştir. Aynı araştırmacıların bir sonraki çalışması, kişiselleştirilmiş yeniden sıralama yoluyla popülerlik yanlılığını azaltmaya odaklanmış ve her kullanıcının popüler ve uzun kuyruk öğelere yönelik bireysel toleransını dikkate alarak dengeli bir öneri listesi oluşturmayı amaçlamıştır (Abdollahpouri vd., 2019). Daha sonraki bir çalışmada Abdollahpouri vd. (2019b), popülerlik yanlılığının öneri sistemlerinde adaletsizliğe yol açtığını vurgulamış ve bu yanlılığı azaltmak için çeşitli çözümler önermiştir. Abdollahpouri vd.'nin çalışması (2021), popülerlik yanlılığını kullanıcı merkezli bir bakış açısıyla değerlendirmiş ve kişiselleştirilmiş yaklaşımların bu yanlılığı etkili bir şekilde azalttığını göstermiştir. Yalcın ve Bilge (2022), öneri sistemlerinde popülerlik yanlılığının kullanıcılar üzerindeki adaletsiz etkilerini incelemiştir. Bu çalışmalarında, farklı kullanıcı özelliklerini dikkate alarak popülerlik yanlılığından en fazla etkilenen kullanıcı gruplarını tanımlamış ve bu yanlılığı azaltmaya yönelik stratejilerin etkinliğini değerlendirmişlerdir. Aynı araştırmacılar tarafından yürütülen başka bir çalışmada (Yalcın ve Bilge, 2021), popülerlik yanlılığı "blockbuster" kavramı üzerinden ele alınmış, popüler ürünlerin aşırı önerilmesiyle oluşan dengesizlikler ve bunların kullanıcı deneyimine etkileri analiz edilmiştir. Aynı bir araştırmada ise bu yazarlar, kullanıcıların kişilik özelliklerinin öneri sistemlerinde popülerlik yanlılığına karşı duyarlılıklarını nasıl etkilediğini incelemiştir (Yalcın ve Bilge, 2023). Tacli vd. (2022) tarafından yürütülen bir çalışmada, kullanıcıların popüler ürünlere yönelik eğilimlerini daha doğru ölçmek amacıyla "Better-Than-Average" ve "Positively-Rated" adlı iki yeni yöntem önerilmiş ve bu yöntemlerin,

kullanıcıların tercih ettikleri ürün türlerini dikkate alarak popülerlik yanlılığının etkilerini azaltmayı hedeflediği ortaya konmuştur. Literatürde bu sorunu azaltmaya yönelik çeşitli çalışmalar geliştirilmiş olsada, bu problem çok ölçütlü yapıda kısıtlı olarak incelenmiştir.

Bu çalışmada, çok ölçütlü yapılarda kullanıcı popülerliğinin etkisini azaltmaya yönelik yeni bir yaklaşım önerilmektedir. Önerilen yöntemin temel dayanağı, gerçek hayatta bireylerin karar verirken kendi zevk ve eğilimleriyle benzerlik gösteren kişilerin tercihlerini daha fazla dikkate alma eğiliminde olmalarıdır. Buna karşılık, benzer eğilimlere sahip olunmayan kullanıcıların beğendikleri ürünler çoğu zaman karar sürecine dâhil edilmeyebilir; hatta bu kullanıcıların olumsuz değerlendirdiği ürünler hedef kullanıcı için daha çekici hâle gelebilir (Kaya, 2025b). Bu davranışsal varsayımdan hareketle, öneri listesi oluşturulurken hem benzer kullanıcıların tercihleri hem de zıt eğilimlere sahip kullanıcıların değerlendirmeleri dikkate alınmakta, böylece kullanıcının popüler olmayan ancak yüksek beğeni potansiyeli taşıyan ürünlere de erişmesi sağlanmaktadır.

Çalışmanın katkıları aşağıdaki gibi özetlenmektedir:

- Çok ölçütlü sistemlerde popülerlik yanlılığını azaltan yeni kullanıcı davranışı merkezli bir yaklaşım sunulmaktadır.
- Önerilen yaklaşım, karar sürecinde yalnızca benzer kullanıcıların tercihlerini değil, aynı zamanda zıt eğilimlere sahip kullanıcıların olumsuz değerlendirmelerini de dikkate alarak daha dengeli ve davranışsal gerçeklikle uyumlu bir öneri mekanizması geliştirmektedir.
- Gerçek hayatta karar verme dinamiklerinin çok ölçütlü öneri sistemlerine entegrasyonu yapılarak, literatüre yenilikçi bir katkı sunmaktadır.

2. Materyal ve Yöntem

Bu bölümde çalışma süresince kullanılan materyal ve yöntemlere yer verilmektedir.

2.1. Kullanıcı Popülerlik Eğilimi Belirleme Yöntemleri

Kullanıcıların değerlendirmelerine göre ürün popülerlik eğilimlerinin belirlenmesinde bu çalışmada iki yöntem ele alınmıştır.

Popüler Ürünlerin Oranı (Ratio of Popular Items- RPI): Bu yöntemde ilk olarak, pareto prensibi kullanılarak ürünlerin popüler ve popüler olmayan şeklinde etiketlenmesi yapılır ve bu etiketlemeye göre aktif kullanıcı tarafından derecelendirilen ürünlerin yüzde olarak popüler ürün etiketine sahip olduğu hesaplanır (Abdollahpouri vd., 2021; Sanders, 1987).

Derecelendirilen Ürünlerin Ortalama Popülerliği (Average Popularity of Rated Items-APRI): Bu yöntemde ilk olarak ürünlerin popülerliği hesaplanır. Bu hesaplamada, ilgili ürünü değerlendirmeye alan kullanıcı sayısının tüm kullanıcılar için oranı bulunur. Sonrasında aktif kullanıcı tarafından derecelendirilen ürünlerin, bu ürün

popülerliklerinin ağırlıklı ortalaması alınarak hesaplama yapılır (Abdollahpour vd., 2019).

2.2. Çoklu Doğrusal Regresyon Analizi

Çok değişkenli regresyon analizinde, bağımsız değişkenlerdeki değişimin bağımlı değişkendeki değişimi eşzamanlı olarak açıklaması amaçlanır (Ünver ve Gamgam, 1999). Çok değişkenli regresyon analizinin modeli aşağıdaki (eşitlik 1) gibi formüle edilir:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + \varepsilon \quad (1)$$

Burada,

y bağımlı, x_i bağımsız değişkeni, β_i katsayıyı ve ε hata terimini temsil etmektedir.

2.3. Değerlendirme Metrikleri

Bu bölümde öneri sistemlerinde popülerlik eğilimlerinin değerlendirilmesinde kullanılan metriklere yer verilmiştir.

Kesinlik (Precision); İlginç ürünlerin önerilme oranını ifade etmektedir (eşitlik 2).

$$Kesinlik@K(u) = \frac{|Rel_u \cap Rec_u^K|}{|Rec_u^K|} \quad (2)$$

Burada, Rel_u kullanıcı u için ilgili öğeler kümesini, Rec_u^K ise kullanıcı u için önerilen en iyi K öğe kümesini ifade etmektedir.

Geri çağırma (Recall); Bu metrik, sistemin kullanıcıya ait tüm ilgili öğeler arasından ne kadarını öneri listesine dahil edebildiğini gösterir (eşitlik 3).

$$Geri \text{ çağırma}@K(u) = \frac{|Rel_u \cap Rec_u^K|}{|Rec_u|} \quad (3)$$

Burada, Rel_u kullanıcı u için ilgili ürünlerin tamamını ifade ederken, Rec_u^K sistemin kullanıcıya sunduğu K öneri listesidir.

Yenilik (Novelty); Bu metrikte kullanıcı için üretilen öneri listesinde, yeni içeriklerin ne kadar yer aldığı hesaplanmaktadır (eşitlik 4).

$$Yenilik = \frac{1}{|R|} \sum_{i \in R} -\log_2(p(i)) \quad (4)$$

Burada, toplam öğe sayısı R ile gösterilirken, $p(i)$ değişkeni, i . öğenin herhangi bir kullanıcı tarafından değerlendirilme olasılığını ifade etmektedir.

Kuyruk Ürünlerin Önerilerde Ortalama Yüzdesi (APLT); Bu metrikte kullanıcılara sunulan öneri listesinde popüler olmayan ürünlerin dağılımı hesaplanmaktadır (eşitlik 5).

$$APLT_K = \frac{|T \cap N_K|}{N} \quad (5)$$

Burada, uzun kuyruk öğelerinin kümesi T ile gösterilirken, herhangi bir K kullanıcısı için, sistemin oluşturduğu öneri listesi ise N_K ile ifade edilmektedir.

Kuyruk Ürünlerin Kapsamı (LTC); Öneri listesinde kuyruk ürünlerin ne kadar kapsadığını ifade eden metriktir (eşitlik 6).

$$LTC = \frac{|I_{N \cap T}|}{|T|} \quad (6)$$

Ortalama Öneri Popülerliği (ARP): önerilen öğelerin ortalama popülerliğini ölçen bir metriktir (Abdollahpour vd., 2021) (eşitlik 7).

$$ARP = \frac{1}{|U|} \sum_{u \in U} \left(\frac{\sum_{i \in L_u} \varphi(i)}{|L_u|} \right) \quad (7)$$

Burada,

$\varphi(i)$, i ürününün popülerlik değerini, L_u kullanıcı u 'ya önerilen ürünlerin listesidir.

2.4. Önerilen Yaklaşım: Davranış Temelli Çiftli Tercih Modellemesi (Behavior-Aware Dual-Preference Modeling -BADPM)

Kullanıcılara öneriler sunulurken yalnızca beğenecekleri ürünlerin değil, aynı zamanda popüler olmayan, ancak onların keşfedebileceği ve sevebileceği ürünlerin de önerilmesi oldukça önemlidir. Dolayısıyla bu noktada hem kullanıcının popülerliliğinin korunduğu hemde yeni keşiflerin sunulduğu bir tavsiye mekanizmasının olması genel memnuniyeti arttıracak bir unsurdur. Davranış Temelli Çiftli Tercih Modellemesi (Behavior-Aware Dual-Preference Modeling -BADPM) olarak isimlendirilen bu yeni yaklaşımda, aktif kullanıcının davranışsal özellikleri temel alınarak kullanıcı odaklı yeni bir öneri üretme mekanizması tasarlanmıştır. Bu mekanizmada ilk olarak aktif kullanıcının (a) popülerlik eğilimi (pop_a) hesaplanmakta ve sonrasında sistemde bu kullanıcıyla benzer veya zıt davranışsal özellikler gösteren kullanıcı toplulukları belirlenmektedir. Bu aşamada benzerlik ölçütü olarak Pearson Korelasyon Katsayısı kullanılmakta; katsayının pozitif olması durumunda benzer davranış sergileyen kullanıcılar ($simUser$), negatif olması durumunda ise zıt davranışa sahip kullanıcılar ($oppUser$) olarak etiketlenmektedir. $simUser$ ve $oppUser$ kullanıcılar için pareto prensibi kullanılarak popüler ve popüler olmayan ürün grupları belirlenir. Bu belirlemenin ardından her bir davranışsal kullanıcı için ürünlerin popülerlik oranları belirlenir ancak burada iki farklı tutum benimsenerek hareket edilir. İlk aşamada *popüler ürün grupları* ($pItems$) için bir hesaplama işlemi gerçekleştirilir. Bu hesaplamada $simUser$ grubunda popüler, $oppUser$ grubunda popüler olmayan şeklinde ortak etiketlenen ürünler popüler ürün grubunu (PPI) oluşturacaktır. Çünkü aktif kullanıcı (a), $simUser$ grubuyla benzer davranışsal eğilimlere sahip olduğundan onların popüler olarak değerlendirdiği ürünlerin kendisi için de popüler kabul edilmesi beklenirken, zıt davranış yapısındaki $oppUser$ grubunda beğenilmeyen ürünler, a kullanıcı için potansiyel olarak sevilebilir ürünler kategorisine girebilmektedir.

Belirlenen popüler ürün grubu için popülerlik derece ($popDerece$) hesaplaması eşitlik 8 ve 9 kullanılarak gerçekleştirilir.

$$PPI = simUser_{pItems} \cap oppUser_{upItems} \quad (8)$$

$$popDerece_i =$$

$$|simUser_{PPI}| * \sum_{u \in simUser_{PPI}} sim_{a,u} \quad (9)$$

$$+ |oppUser_{PPI}| * \sum_{u' \in oppUser_{PPI}} sim_{a,u'}$$

İkinci aşamada ise **popüler olmayan ürün grubu (upItems)** içinde *popDerece* hesaplamasında (Eşitlik 10-11), önceki adımların benzeri tekrarlanır sadece burada *UPI* grubu için benzer davranışa sahip kullanıcı grubunun popüler olmayan ürünleri ile ters davranışsal yapıya sahip kullanıcı grubunun popüler ürün grubu dikkate alınarak süreç ilerletilir ve bundan sonrasında bu değerler kullanılarak öneri üretilmesi adımına geçilir (eşitlik 10 ve 11).

$$UPI = simUser_{upItems} \cap oppUser_{pItems} \quad (10)$$

$$popDerece_j = |simUser_{UPI}| *$$

$$\sum_{u \in simUser_{UPI}} sim_{a,u} + |oppUser_{UPI}| * \sum_{u' \in oppUser_{UPI}} sim_{a,u'} \quad (11)$$

Öneri listesi (*TopnList*) üretme adımında, *a* kullanıcısının her *i* ürünü için işbirlikçi filtreleme algoritması kullanılarak tahmini değer üretme (*pred_m*) işlemi gerçekleştirilir. Bu tahmini değerlerin azalan sırada sıralanmasının ardından, *popDerece* değeri en yüksek ilk ürün *TopnList* eklenir. Sonrasında,

- *TopnList* için popülerlik durumu hesaplanır ($pop_{list} = \sum popDerece / |TopnList|$),
- Eğer $pop_{list} > pop_a$ ise
 - $TopnList \cup \max(pred_j), j \in UPI$
- Değilse
 - $TopnList \cup \max(pred_i), i \in PPI$

adımları, kullanıcı tarafından istenilen öneri boyutu (*N*) kadar devam eder.

2.5. Veriseti

Bu çalışmada çok ölçütlü öneri sistemlerinde oldukça yaygın kullanılan Yahoo! Movies (YM) ve TripAdvisor (TA) veri setleri kullanılmıştır (Jannach vd., 2012; Wang vd., 2011). YM veri setinin iki alt veri seti olan YM10, YM20 veri setindeki kullanıcı ve ürünlerin minimum değerlendirme sayılarını ifade etmektedir. Örneğin YM10 veri setinde, her kullanıcı en az 10 ürünü değerlendirirken, her üründe en az 10 kullanıcı tarafından derecelendirilmiştir. Benzer durum diğer veri seti içinde geçerlidir. Bu iki alt veri seti 4 alt kriter ve genel bir değerlendirmeden oluşurken, TA veri setinde ise 7 alt kriter ve bir genel kriter yer almaktadır. Her bir veri seti için değerlendirme ölçeği 1-5 arasında değişmektedir. YM20 veri seti 429 kullanıcı, 491 ürün, YM10 veri seti 1827 kullanıcı, 1471 ürün ve son veri seti olan TA, 1346 kullanıcı ile 1289 ürün oluşmaktadır.

2.6. Deney Metodolojisi

Bu çalışmada çok ölçütlü veri seti üzerinde kullanıcının davranışsal modelinin etkisinin ele alındığı BADPM modelinde dört farklı senaryo benimsenmiştir.

Genel-kritere dayalı (S1): Bu senaryoda veri seti tek ölçütlü gibi ele alınıp, kullanıcıların sadece genel değerlendirmeleri üzerindeki dereceler dikkate alınarak deneysel süreç ilerletilmiştir.

Baskın-kritere dayalı (S2): Bu senaryoda sistemde aktif öneri bekleyen kullanıcının baskın kriteri belirlenmiş ve bu kriter üzerinden deneysel adımlar ilerletilmiştir.

Çekinik-kritere dayalı (S3): Bu senaryoda ise S2 senaryosunun tersine, aktif kullanıcı için baskın olmayan en önemsiz kriter dikkate alınarak, bu kriter verileri üzerinden süreç ilerletilmiştir.

Toplama-tabanlı (S4): Bu senaryoda her bir kriterin genel değerlendirme üzerindeki etkisini temsil eden ağırlık katsayıları (*w_i*) çoklu doğrusal regresyon kullanılarak hesaplanmış ve bu katsayılar kullanılarak ağırlıklandırılmış bir birleştirme (aggregate) işlemi uygulanmıştır. Daha sonra, ağırlıklandırılmış veri kümesi üzerinde gerçekleştirilen deneysel çalışmalar ile yöntemin performansı analiz edilmiştir.

Senaryolara göre kullanılacak veri seti yapısı belirlendikten sonra, *k*-fold çapraz doğrulama yöntemi uygulanarak veri kümesi eğitim ve test bölümlerine ayrılmıştır. Bu adımın ardından her bir test kullanıcısı için deneysel süreçler yürütülmüş ve önerilen yöntem ile temel yöntem karşılaştırması yapılarak performans analizi gerçekleştirilmiştir.

Performans analizi aşamasında, önerilen yaklaşımın temel yöntem ile kapsamlı bir karşılaştırması gerçekleştirilmiştir. Bu bağlamda temel yöntem (TRM), klasik öneri sistemlerinde yaygın olarak kullanılan ve kullanıcılara yalnızca tahmin edilen puanı en yüksek olan öğelerin sunulmasına dayanan geleneksel yaklaşımı temsil etmektedir. Böylece, önerilen yöntemin bu geleneksel yapıya kıyasla ortaya koyduğu iyileştirmeler, çeşitli performans ölçütleri üzerinden sistematik olarak değerlendirilmiştir.

3. Bulgular

Bu bölümde, çalışmada önerilen yöntemin performansını değerlendirmek amacıyla üç farklı veri seti (YM20, YM10, TA) ve dört farklı senaryo (S1, S2, S3, S4) üzerinden gerçekleştirilen deneysel analizlerin bulguları sunulmaktadır. Analiz sürecinde, sonuçların istatistiksel olarak daha güvenilir ve genellenebilir olmasını sağlamak için veri kümesi 5-fold çapraz doğrulama tekniği kullanılarak eğitim ve test bölümlerine ayrılmıştır. Her bir fold'un test kümesi olarak ayrı ayrı değerlendirilmesiyle elde edilen performans değerleri ortalama alınarak karşılaştırılmış; böylece yöntemlerin tutarlılığı ve kararlılığı bütüncül bir biçimde incelenmiştir.

YM20 veri seti üzerinde dört farklı senaryo kapsamında BADPM ve TRM yöntemlerinin karşılaştırmalı analiz sonuçları ve her iki yöntemin Top-N seviyelerinde kesinlik, geri çağırma ve yenilik performansları Tablo 1' de gösterilmektedir. Elde edilen sonuçlar incelendiğinde, S1 (Genel-kritere dayalı) senaryosunda yenilik performans metriği haricinde diğer metriklerde en

başarılı sonucun BADPM, APRI yöntemi ile elde edildiği görülmektedir. Örneğin, kullanıcıya 10 ürünlük bir lista hazırlandığında, bu üründen kullanıcının memnun kalma yüzdesi APRI yöntemi ile 5-6 ürün iken, RPI yönteminde bu oran yarıya inebilmektedir. Dahası TRM yönteminde her senaryo için %45'lere varan başarılar elde edilirken, BADPM yönteminde bu oranın üzerine APRI popülerlik yöntemi ile elde edilmektedir. RPI yönteminde bu başarı düşebilmektedir. Ancak kullanıcı için yenilik kriteri ön plana çıktığında, en ideal sonucun benzer şekilde önerilen yöntemle ve kullanıcı popülerlik yöntemi olan RPI ile oluştuğu söylenebilir. Yenilik açısından değerlendirildiğinde, BADPM yönteminin özellikle S1-RPI ve S3-APRI senaryolarında dikkat çekici bir üstünlük sergilediği görülmektedir. S1-RPI için Top-10 yenilik değeri %66,82, Top-15 ise %83,14 olarak elde edilmiş ve bu değerler TRM yönteminin sırasıyla %16,32 ve %15,36 olan yenilik performansını açık ara geride bırakmıştır. Bu sonuçlar, önerilen yöntemin sadece kesinlik ve geri çağırma gibi doğruluk temelli metriklerde değil, aynı zamanda kullanıcıya yeni ve daha az popüler ürünler sunma kapasitesini ölçen yenilik metriğinde de kayda değer iyileştirmeler sağladığını göstermektedir. Genel olarak tablo, BADPM yönteminin çok-kriterli senaryolarda TRM modeline kıyasla hem doğruluk hem de çeşitlilik açısından daha dengeli ve kullanıcı odaklı bir performans sunduğunu ortaya koymaktadır. Dahası senaryolar açısından bakıldığında, genel değerlendirme ve kullanıcı için önem derecesi en az olan kriter baz alınarak oluşturulan bu yapının daha başarılı olduğu görülmektedir. Burada aslında kullanıcı için önemsiz olan kriterin popüler yanlılığı üzerinde olumlu etkiye sahip olduğu söylenebilir ve kullanıcı için keşiflerin arttırıldığı memnuniyetin yükseltildiği çıkarımı yapılabilir.

YM10 veri seti üzerinde elde edilen bulgular için Tablo 2'ye bakıldığında, BADPM yönteminin özellikle APRI varyantı ile hem doğruluk temelli hem de çeşitlilik odaklı metriklerde TRM yaklaşımından anlamlı derecede daha başarılı olduğunu göstermektedir. Özellikle S1-APRI ikilisi kullanıldığında, on ürünlük bir liste hazırlanması kullanıcının üç üründen memnun olduğu çıkarımı yapılabilir. TRM yöntemiyle karşılaştırıldığında (örneğin Top-5 için %1,59, Top-10 için %2,00), BADPM'nin yaklaşık 15-20 kat daha yüksek kesinlik performansı sergilediği görülmektedir. Geri çağırma sonuçları da benzer şekilde BADPM önde olacak şekildedir: S4-APRI senaryosu Top-10'da %18,12, Top-15'te %27,38 ile en yüksek değerleri sunarken TRM'nin aynı metriklerde %1-1,3 aralığında kaldığı gözlemlenmektedir. Kullanıcı popülerliği açısından S1-APRI senaryosu %29,78, S3-APRI senaryosu ise %25,51 ile BADPM grubunda en yüksek değerlere ulaşmıştır. Buna karşılık TRM'nin kullanıcı popülerliği değeri tüm senaryolarda %2 civarında seyretmiş ve BADPM yöntemine göre yaklaşık 10-15 kat daha düşük kalmıştır.

Son veri seti olan TA için sonuçlara bakıldığında, diğer iki veri setinin tersine kullanıcı popülerlik yönteminin RPI

olması halinde kesinlik ve geri çağırma metrikleri açısından en başarılı sonuçları verdiği Tablo 3'e bakılarak çıkartılabilir. Yenilik kriterinin ön planda olması halinde ise APRI popülerliğinin sırayı aldığı görülmektedir. Kesinlik metriklerinde BADPM'nin RPI ve APRI varyantlarının TRM'ye üstünlüğü açık şekilde görülmektedir. Örneğin BADPM (S3-RPI), Top-5 için %18,7, Top-10 için %12,81, Top-15 için %9,09 kesinlik değerlerine sahiptir; bu değerler TRM'nin aynı metriklerde sırasıyla %0,9, %0,4, %0,3 seviyesinde kalmaktadır. Bu durum BADPM'nin TA gibi seyrek ve farklı kriter uzayına sahip bir veri setinde dahi yüksek doğruluk sağlayabildiğini göstermektedir. Geri çağırma sonuçlarında BADPM'nin özellikle RPI tabanlı varyantlarda belirgin bir üstünlük sergilediği izlenmektedir. S1-RPI, Top-10 geri çağırma %85,11, Top-15'te %94,72 oranlarına ulaşarak tabloda en yüksek sonuçları vermiştir. Benzer şekilde S4-RPI, Top-10'da %88,67, Top-15'te %91,42 değerleri ile güçlü bir performans sunmaktadır. Buna karşılık TRM'nin geri çağırma değerleri tüm senaryolarda %0,2-2,5 aralığında seyretmektedir. Bu fark, BADPM'nin özellikle yüksek keşif yeteneği gerektiren veri setlerinde kullanıcıların tercih ettiği ürünleri yakalama kapasitesinin daha etkili olduğunu ortaya koymaktadır.

Yenilik açısından BADPM'nin APRI varyantları dikkat çekmektedir. S1-APRI, Top-10 yenilikte %81,96, Top-15'te %87,97 ile en yüksek çeşitlilik değerlerine ulaşmıştır. Bu değerler, TRM'nin %36-45 aralığında kalan yenilik performansına göre oldukça yüksektir. BADPM'nin özellikle TA veri setinin geniş ürün uzayında yeniliği yüksek öneriler sunması, yöntemin keşif odaklı yapısının güçlü bir göstergesidir. Üç veri setine birlikte bakıldığında, BADPM'in farklı yoğunluklarda dahi çizgisini koruyan bir performans sergilediği görülüyor. Daha kompakt ve nispeten daha az seyrek olan YM20'de yöntem, özellikle kesinlik ve geri çağırma açısından oldukça güçlü sonuçlar üretirken, veri boyutu büyüyüp yapı seyrekleştğinde (YM10) bile TRM'in oldukça üzerinde kalmayı başarıyor. TA veri seti ise en zorlayıcı senaryo; çünkü kullanıcı-ürün ilişkileri oldukça dağınık. Buna rağmen BADPM hem doğru öneriler sunma hem de kullanıcıya yeni ürünler keşfettirme konusunda tutarlı bir davranış gösteriyor. TRM ise sparsity yükseldikçe belirgin şekilde zorlanıyor ve çoğu durumda anlamlı bir öneri listesi üretilmiyor. Genel tablo, BADPM'in sadece yoğun veri koşullarında değil, veri seyrekliğinin belirginleştiği ortamlarda da daha esnek ve dayanıklı bir yapı sunduğunu ortaya koyuyor.

Tablo 1. YM20 veri seti için karşılaştırmalı sonuçlar

Yöntem	Senaryo	Kullanıcı Popülerliği	Kesinlik			Geri Çağırma			Yenilik		
			Top-5	Top-10	Top-15	Top-5	Top-10	Top-15	Top-5	Top-10	Top-15
BADPM	S1	RPI	0,2391	0,137	0,1005	0,0486	0,0557	0,0616	0,6682	0,7889	0,8314
	S1	APRI	0,5917	0,507	0,454	0,1116	0,1843	0,2423	0,1012	0,0888	0,0782
	S2	RPI	0,2253	0,1449	0,1102	0,0435	0,0559	0,0642	0,6357	0,7522	0,7935
	S2	APRI	0,5628	0,5091	0,4668	0,0988	0,1736	0,2351	0,0647	0,0624	0,0582
	S3	RPI	0,2246	0,1403	0,1048	0,0427	0,0558	0,0635	0,6444	0,7635	0,8077
	S3	APRI	0,5912	0,5245	0,4763	0,1018	0,1791	0,2379	0,0401	0,0287	0,0246
	S4	RPI	0,214	0,132	0,1009	0,0545	0,0677	0,079	0,648	0,7649	0,8069
	S4	APRI	0,5119	0,4644	0,4204	0,1225	0,2091	0,2719	0,0648	0,0693	0,0679
TRM	S1	-	0,4597	0,4175	0,3849	0,0808	0,1437	0,1954	0,1632	0,1536	0,1484
	S2	-	0,3864	0,3799	0,3582	0,0603	0,119	0,1692	0,1726	0,1679	0,1669
	S3	-	0,4005	0,3877	0,3634	0,0624	0,1216	0,1682	0,1865	0,1741	0,1633
	S4	-	0,386	0,3555	0,3333	0,0869	0,1536	0,2087	0,1767	0,1704	0,1651

S1= genel-kritere dayalı, S2= baskın-kritere dayalı, S3= çekinik-kritere dayalı, S4= toplama-tabanlı.

Tablo 2. YM10 veri seti için karşılaştırmalı sonuçlar

Yöntem	Senaryo	Kullanıcı Popülerliği	Kesinlik			Geri Çağırma			Yenilik		
			Top-5	Top-10	Top-15	Top-5	Top-10	Top-15	Top-5	Top-10	Top-15
BADPM	S1	RPI	0,2291	0,1984	0,1808	0,0765	0,1436	0,2033	0,1951	0,2917	0,3417
	S1	APRI	0,2978	0,2999	0,2929	0,0905	0,1897	0,2816	0,0663	0,0882	0,0934
	S2	RPI	0,193	0,178	0,1697	0,0589	0,1188	0,1771	0,1441	0,2195	0,2643
	S2	APRI	0,2477	0,258	0,2623	0,0679	0,1473	0,2295	0,0444	0,0565	0,0601
	S3	RPI	0,2001	0,1849	0,1757	0,0597	0,1216	0,1795	0,142	0,2264	0,2738
	S3	APRI	0,2551	0,2675	0,2716	0,0677	0,1513	0,2343	0,0429	0,0582	0,0639
	S4	RPI	0,1868	0,1712	0,1622	0,0734	0,1448	0,2105	0,1432	0,2195	0,2612
	S4	APRI	0,2389	0,247	0,2476	0,0846	0,1818	0,2738	0,0366	0,0516	0,0577
TRM	S1	-	0,0159	0,0204	0,0231	0,0021	0,0057	0,0102	0,2022	0,1955	0,1913
	S2	-	0,0193	0,0222	0,0247	0,0027	0,0065	0,011	0,1995	0,1966	0,1903
	S3	-	0,0201	0,0212	0,0241	0,0027	0,006	0,0102	0,1968	0,1916	0,1879
	S4	-	0,0172	0,0203	0,0227	0,0033	0,0084	0,0133	0,195	0,1937	0,1921

S1= genel-kritere dayalı, S2= baskın-kritere dayalı, S3= çekinik-kritere dayalı, S4= toplama-tabanlı.

Tablo 3. TA veri seti için karşılaştırmalı sonuçlar.

Yöntem	Senaryo	Kullanıcı Popülerliği	Kesinlik			Geri Çağırma			Yenilik		
			Top-5	Top-10	Top-15	Top-5	Top-10	Top-15	Top-5	Top-10	Top-15
BADPM	S1	RPI	0,1773	0,15	0,1132	0,5268	0,8511	0,9472	0,2405	0,3835	0,5056
	S1	APRI	0,0701	0,0483	0,0322	0,2121	0,2753	0,2753	0,6828	0,8196	0,8797
	S2	RPI	0,1833	0,1283	0,0956	0,6014	0,7667	0,8264	0,3933	0,5208	0,6067
	S2	APRI	0,0983	0,055	0,0367	0,3319	0,3611	0,3611	0,7	0,8208	0,8806
	S3	RPI	0,1879	0,1281	0,0952	0,6621	0,8091	0,8646	0,1547	0,3568	0,5056
	S3	APRI	0,0526	0,033	0,022	0,1954	0,2621	0,2621	0,6514	0,7819	0,848
	S4	RPI	0,192	0,1355	0,0946	0,6183	0,8867	0,9142	0,2363	0,383	0,4956
	S4	APRI	0,0783	0,0517	0,0344	0,265	0,39	0,39	0,596	0,728	0,8087
TRM	S1	-	0,0114	0,0057	0,005	0,0238	0,0238	0,0329	0,4977	0,3673	0,4544
	S2	-	0,0067	0,0033	0,0022	0,0111	0,0111	0,0111	0,4217	0,3417	0,3967
	S3	-	0,0092	0,0046	0,0031	0,0282	0,0282	0,0282	0,5218	0,3129	0,3624
	S4	-	0	0,005	0,0042	0	0,025	0,0317	0,4823	0,3187	0,4598

S1= genel-kritere dayalı, S2= baskın-kritere dayalı, S3= çekinik-kritere dayalı, S4= toplama-tabanlı.

Kesinlik, geri çağırma ve yenilik metrikleri ile ilgili sonuçlarından ardından, APLT, LTC ve ARP metrikleri açısından incelemelerde, bu metriklerin değişimleri dikkate alınarak sonuçlar verilmiştir. Δ APLT, Δ LTC, Δ ARP metrikleri sırasıyla BADPM yönteminden elde edilen sonucun klasik yöntem olan TRM tabanlıya göre farkını

ifade etmektedir. Bu farkın pozitif olması durumunda önerilen yöntemin oldukça başarılı olduğu sonucu çıkartılmaktadır.


Bu bilgiler ışığında ilk veri seti olan YM20 için elde edilen sonuçlar Şekil 1' de gösterilmektedir. APLT, LTC ve ARP metrikleri üzerinden hesaplanan Δ değerleri, BADPM

yönteminin kuyruk ürünlere duyarlılığı ve popülerlik dağılımına etkisini TRM ile karşılaştırmalı olarak değerlendirmeye imkân sağlamaktadır. APLT sonuçları incelendiğinde, özellikle S1-RPI, S2-RPI, S3-RPI ve S4-RPI senaryolarında pozitif ve yüksek değerlerin elde edilmesi, BADPM'nin kullanılan tüm senaryolarda TRM'ye kıyasla daha fazla kuyruk ürün önerdiğini göstermektedir. APLT'nin Top-10 ve Top-15 aralıklarında %58-69 düzeylerine ulaşması, yöntemin uzun kuyruk ürünleri sistematik biçimde listeye dahil etme kapasitesinin güçlü olduğuna işaret etmektedir. Buna karşılık APRI varyantlarında görülen negatif değerler, popülerlik uyumunun yüksek olduğu bu varyantlarda BADPM'nin TRM'ye göre biraz daha az kuyruk ürün sunduğunu, fakat bunun yöntem yapısından kaynaklanan popülerlik-kuyruk dengesinin doğal bir sonucu olduğunu göstermektedir. LTC değerleri genel olarak APLT'e paralel şekilde pozitif sonuçlar üretmiş ve özellikle S1-RPI, S2-RPI ve S3-RPI senaryolarında kuyruk ürün kapsamının TRM'ye göre belirgin şekilde genişlediği görülmüştür. Top-15 seviyesinde %9-10'a varan pozitif Δ değerleri, BADPM'nin yalnızca kuyruk ürünleri öneri listesine eklemekle kalmadığını, aynı zamanda bu ürünlerin liste içindeki kapsama oranını da artırdığını göstermektedir. Negatif değerlere sahip APRI senaryoları ise yine popülerlik yanlı doğası gereği daha dengeli bir öneri listesi oluşturmakta, bu nedenle TRM'ye kıyasla kuyruk kapsama oranı bir miktar düşük kalmaktadır. ARP sonuçları incelendiğinde, BADPM'nin önerdiği ürünlerin ortalama popülerlik düzeyinin TRM'den biraz daha düşük olduğu anlaşılmaktadır. Özellikle S1-, S2-, S3-, S4-RPI senaryolarındaki Top-10 ve Top-15 sonuçları, yöntemin popülerlik-kuyruk dengesini korurken kullanıcıya aşırı popüler öğeler yerine orta düzey popülerlikte, keşif potansiyeli yüksek ürünler sunduğunu ortaya koymaktadır. ARP değerlerinin negatif olmasıyla APLT ve LTC değerlerinin aynı senaryolarda yüksek olması, sistemin popüler olmayan ürünleri önerdiği ancak kullanıcı memnuniyetinin de arttırıldığı, yeniliğin öne çıktığı söylenebilir.


Diğer veri seti olan YM10 için sonuçlara bakıldığında, kuyruk ürünlerin listede yer alması durumunda, memnuniyetin yüksek olduğu APRI senaryosunda popüler olmayan ürünlerin yer alma oranının yüksek olduğu Şekil 2' ye bakılarak söylenebilir. Tablo genel olarak incelendiğinde, BADPM yöntemi ile TRM arasındaki farkı temsil eden Δ değerlerinin büyük bölümünün negatif olduğu görülmektedir. Bu durum, özellikle APLT ve LTC metriklerinde BADPM'nin kuyruk ürünleri önerme ve bu ürünlerin kapsamını artırma açısından TRM'ye göre daha düşük bir performans sergilediğini göstermektedir. APLT sonuçlarında sadece birkaç senaryoda (örneğin S1-RPI ve S3-RPI) Top-10 ve Top-15 düzeylerinde hafif olumlu değerler elde edilmiş olsa da genel eğilim negatif yönlüdür. Bu negatif değerler, BADPM'nin öneri listesinde uzun kuyruk ürünlere daha

az yer verdiğini ve TRM'nin bu açıdan bir miktar daha kapsayıcı davrandığını düşündürmektedir. LTC metriğinde de benzer bir tablo ortaya çıkmakta; BADPM çoğu senaryoda TRM'ye göre kuyruk ürün kapsamını genişletmemektedir. Buna karşın ARP metriği diğer iki metriğe kıyasla daha dengeli bir görünüm sunmakta ve neredeyse tüm senaryolarda küçük de olsa pozitif Δ değerleri ortaya çıkmaktadır. Bu sonuç, BADPM'nin önerdiği ürünlerin popülerlik düzeyinin TRM'den hafifçe daha yüksek olduğunu, ancak bu farkın dengeli ve sınırlı düzeyde kaldığını göstermektedir. Genel olarak bu bulgular, BADPM'nin bu veri setinde uzun kuyruk odaklı çeşitlilik artırma noktasında TRM kadar güçlü performans gösteremediğini, ancak popülerlik açısından daha dengeli ve kontrollü öneriler üretme eğiliminde olduğunu ortaya koymaktadır.


Son veri seti TA için elde edilen sonuçlar ise Şekil 3'te gösterilmektedir. Kullanıcıya sunulan öneri listesinde memnuniyetin RPI yöntemi ile ön planda olduğunu ancak uzun kuyrukların oranında BADPM yönteminde başarının sınırlı olduğu söylenebilir. Özellikle bu başarı diğer veri setlerine göre daha düşük oranlarda yer aldığı negatif olarak %25-36 arasında değiştiği görülmektedir. Sonuçlarda özellikle S2-APRI senaryosunda Top-5'te %27,83, Top-10'da %47,92, Top-15'te ise %48,39 oranında pozitif Δ elde edilmiş olması, BADPM'nin bu senaryoda TRM'ye göre çok daha fazla uzun kuyruk ürünü önerdiğini göstermektedir. Benzer şekilde S1-APRI ve S3-APRI senaryolarında da %18-48 aralığında değişen pozitif farklar görülmekte, bu da BADPM'nin belirli kullanıcı davranış modellerinde uzun kuyruk ürünleri listeye daha etkin biçimde dahil ettiğini göstermektedir. Bununla birlikte S1-RPI, S2-RPI, S3-RPI ve S4-RPI senaryolarında negatif değerler bulunması (-%2,83 ile -%36,72 arasında), BADPM'nin popülerlik odaklı bu varyantlarda TRM'ye göre daha sınırlı uzun kuyruk başarısı gösterdiğini işaret etmektedir. LTC metriği açısından değerlendirildiğinde, BADPM'nin bazı senaryolarda kuyruk kapsamını artırdığı, bazılarında ise TRM'nin gerisinde kaldığı görülmektedir. Örneğin S2-APRI senaryosunda Top-15 düzeyinde %3,39 pozitif Δ değeri elde edilirken, S3-RPI ve S4-RPI senaryolarında -%0,58 ile -%0,89 arasında negatif farklar ortaya çıkmaktadır. Bu durum, BADPM'nin TA veri setinin oldukça seyrek yapısında kuyruk kapsamını genişletme kapasitesinin senaryo türüne bağlı olarak değiştiğini göstermektedir. ARP metriği incelendiğinde ise daha istikrarlı ve dengeli bir tablo görülmektedir. ARP önerilen ürünlerin ortalama popülerliğini ölçtüğünden, pozitif Δ değerleri BADPM'nin TRM'ye göre biraz daha popüler ürünler önerdiğini göstermektedir. Δ değerlerinin tüm senaryolarda %0,05 ile %0,34 arasındaki oldukça dar bir aralıkta pozitif yönde olması, BADPM'nin popülerlik dağılımını önemli ölçüde bozmadan, dengeli bir öneri listesi ürettiğini göstermektedir.



Şekil 1. YM20 veri seti için $\Delta APLT$, ΔLTC , ΔARP sonuçları.



Şekil 2. YM10 veri seti için $\Delta APLT$, ΔLTC , ΔARP sonuçları.



Şekil 3. TA veri seti için $\Delta APLT$, ΔLTC , ΔARP sonuçları.

BADPM yönteminin TRM'ye kıyasla özellikle yoğun veri yapısına sahip veri setlerinde (YM20) uzun kuyruk başarısını belirgin biçimde artırdığı, APLT ve LTC metriklerinde ise %40–%80'e varan olumlu farklar sağladığı görülmektedir. Daha seyrek olan YM10 veri setinde sonuçlar daha dengeli olup, bazı senaryolarda BADPM kuyruk öğeleri artırırken bazı senaryolarda TRM'nin gerisinde kalmıştır; buna karşın ARP değerleri her iki yöntemin popülerlik dengesini koruduğunu göstermiştir. En seyrek yapıdaki TA veri setinde ise özellikle APRI varyantlarında APLT ve LTC metriklerinde %20–%48 arasında değişen önemli pozitif farklar elde edilmiş, bu da BADPM'nin zor veri koşullarında dahi belirli senaryolarda uzun kuyruk ürünlerini daha etkili biçimde önerdiğini ortaya koymuştur. Tüm veri setlerinde ARP sonuçlarının düşük ama pozitif olması (%0,05–%0,3), BADPM'nin popülerlik dengesini bozmadığını ve öneri çeşitliliğini koruduğunu göstermektedir. Genel olarak BADPM, veri yapısı değişse bile TRM'ye kıyasla daha esnek, daha uyumlu ve uzun kuyruk ürünlerini daha iyi yakalama eğiliminde olan bir yöntemdir.

5. Tartışma

Bu çalışmada çok ölçütlü öneri sistemleri üzerinde popülerlik yanlılığı probleminin ele alındığı kullanıcı için yeni bir öneri üretme sürecinin gerçekleştirildiği bir yapı oluşturulmuştur. Önerilen yöntemin (BADPM) klasik yöntemle (TRM) karşılaştırmalı analizi verilmiş ve deneysel sonuçlar elde edilmiştir. Bu sonuçlara göre BADPM yönteminin farklı yoğunluk seviyelerine sahip veri setlerinde TRM yaklaşımına kıyasla daha dengeli ve kararlı bir performans sunduğunu göstermektedir.

Özellikle yoğun veri yapısına sahip YM20 veri setinde APLT ve LTC metriklerinde gözlenen yüksek pozitif Δ değerleri, yöntemin uzun kuyruk ürünlerini öneri listelerine etkili bir şekilde dahil ettiğini ortaya koymuştur. Buna karşın sparsity seviyesi daha yüksek olan TA veri setinde performans senaryolara göre değişmiş, ancak özellikle APRI varyantlarında yüksek uzun kuyruk başarısı sürdürülmüştür. Bu durum, modelin farklı kullanıcı davranış biçimlerine adapte olabilmeye kapasitesine işaret etmektedir. Elde edilen sonuçlar genel olarak literatürde çok ölçütlü modellerin çeşitlilik odaklı önerilerde daha başarılı olduğuna dair bulgularla uyumludur. Bununla birlikte BADPM'nin popülerlik metriği açısından dengeli bir öneri listesi sunması, modelin popülerlik yanlılığını aşırı derecede artırmadan çalıştığını göstermektedir. Buna rağmen, veri setlerinin farklı sparsity seviyeleri performansın değişkenlik göstermesine neden olmuş ve özellikle RPI tabanlı senaryolarda uzun kuyruk başarısı sınırlı kalmıştır. Bu durum, modelin popülerlik duyarlılığı yüksek kullanıcı profilleri için iyileştirilmesi gerektiğine işaret etmektedir.

Çalışmanın bazı sınırlılıkları bulunmaktadır. Kullanıcı davranışlarının sabit varsayılması, tek veri kaynağının kullanılması ve gerçek zamanlı kullanıcı etkileşimlerinin modele dahil edilmemesi sonuçların genellenebilirliğini sınırlandırabilir. Gelecek çalışmalar, modelin dinamik kullanıcı profilleriyle güncellenmesi, derin öğrenme tabanlı çok kriterli yapılarla genişletilmesi ve popülerlik yanlılığını azaltan ek mekanizmaların eklenmesi üzerine yoğunlaştırılabilir.

Katkı Oranı Beyanı

Yazarın katkı yüzdeleri aşağıda verilmiştir. Yazar makaleyi incelemiş ve onaylamıştır.

	T.T.K.
K	100
T	100
Y	100
VTI	100
VAY	100
KT	100
YZ	100
KI	100
GR	100
PY	100
FA	100

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

Çalışma Beyanı

Yazar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Kaynaklar

- Abdollahpouri, H., Burke, R., & Mobasher, B. (2017). Controlling popularity bias in learning-to-rank recommendation. *RecSys 2017: Proceedings of the 11th ACM Conference on Recommender Systems*, 42–46.
- Abdollahpouri, H., Burke, R., & Mobasher, B. (2018). Popularity-aware item weighting for long-tail recommendation. *arXiv*. <https://arxiv.org/abs/1802.05382>.
- Abdollahpouri, H., Burke, R., & Mobasher, B. (2019). Managing popularity bias in recommender systems with personalized re-ranking. *arXiv preprint arXiv:1901.07555*.
- Abdollahpouri, H., Mansoury, M., Burke, R., & Mobasher, B. (2019b). The unfairness of popularity bias in recommendation. *arXiv preprint arXiv:1907.13286*.
- Abdollahpouri, H., Mansoury, M., Burke, R., Mobasher, B., & Malthouse, E. (2021). User-centered evaluation of popularity bias in recommender systems. *In Proceedings of the 29th ACM conference on user modeling, adaptation and personalization* (pp. 119–129).
- Balli, N., & Kaya, T. T. (2025). Kullanıcı eğilimlerinin göreceli modellenmesinin popülerlik yanlılığına etkisi. *Cukurova University Faculty of Engineering Journal*, 40(3), 671–686.
- Cremonesi, P., Koren, Y., & Turrin, R. (2010). Performance of recommender algorithms on top-n recommendation tasks. *In Proceedings of the fourth ACM conference on Recommender*

systems (pp. 39–46).

- Isinkaye, F. O., Folajimi, Y., & Ojokoh, B. (2015). Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, 16, 261–273.
- Jannach, D., Karakaya, Z., & Gedikli, F. (2012). Accuracy improvements for multi-criteria recommender systems. *Proceedings of the 13th ACM Conference on Electronic Commerce*, 674–689.
- Kang, Z., Peng, C., Yang, M., & Cheng, Q. (2016). Top-n recommendation on graphs. *Proceedings of the 25th ACM CIKM*, 2101–2106.
- Kaya, T. T. (2025a). Mitigating popularity bias in fair and explainable recommender systems using SHAP. *Duzce University Journal of Science and Technology*, 13(3), 1180–1199.
- Kaya, T. T. (2025b). A novel clustering-based multi-criteria group recommender system. *Neurocomputing*, 132329.
- Kaya, T. T. (2025c). Analysis of Performance and Popularity Bias in Recommender Systems Based on Personality Traits. *In SETSCI-Conference Proceedings* (Vol. 22, pp. 11–15). *SETSCI-Conference Proceedings*.
- Lee, J., Lee, D., Lee, Y., Hwang, W., & Kim, S. (2016). Improving the accuracy of top-n recommendation using a preference model. *Information Sciences*, 348, 290–304.
- Pichl, M., Zangerle, E., & Specht, G. (2014). Combining Spotify and Twitter Data for Generating a Recent and Public Dataset for Music Recommendation. *In Grundlagen von Datenbanken* (pp. 35–40).
- Ren, Y., Li, G., & Zhou, W. (2012). Learning user preference patterns for Top-N recommendations. *In 2012 IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology* (Vol. 1, pp. 137–144). IEEE.
- Sanders, R. (1987). The Pareto principle: Its use and abuse. *Journal of Services Marketing*, 1(2), 37–40.
- Taceli, Y., Yalcin, E., & Bilge, A. (2022). Novel approaches to measuring the popularity inclination of users for the popularity bias problem. *In 2022 International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 555–560). IEEE.
- Ünver, Ö., & Gamgam, H. (2008). Uygulamalı temel istatistik yöntemler.
- Wang, H., Lu, Y., & Zhai, C. (2011). Latent aspect rating analysis without aspect keyword supervision. *In Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 618–626).
- Xue, F., He, X., Wang, X., Xu, J., Liu, K., & Hong, R. (2019). Deep item-based collaborative filtering for top-n recommendation. *ACM Transactions on Information Systems (TOIS)*, 37(3), 1–25.
- Yalcin, E. (2021). Blockbuster: A new perspective on popularity-bias in recommender systems. *In 2021 6th International Conference on Computer Science and Engineering (UBMK)* (pp. 107–112). IEEE.
- Yalcin, E., & Bilge, A. (2022). Evaluating unfairness of popularity bias in recommender systems: A comprehensive user-centric analysis. *Information Processing & Management*, 59(6), 103100.
- Yalcin, E., & 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), e7647.