

Editör
Dr. Meltem DİŞLİ

**GÜNCEL
BİLGİ VE BELGE
YÖNETİMİ
ARAŞTIRMALARI VE
UYGULAMALARI - II**

Çevrimiçi Kütüphane Katalogları İçin Alternatif İlgi Sıralaması Algoritması Modeli

An Alternative Relevance Ranking Algorithm Model for Online Public Access Catalogs

Müge Akbulut¹

Öz

Kullanıcılar, bilgi miktarının üstel olarak arttığı dijital ortamı, hem merak ettikleri konuda bilgi almak hem de günlük haber ve bilgi ihtiyaçlarını karşılamak amacıyla kullanmaktadır. Bu ortamda kişiye özel arama sonuçlarının oluşturulması için filtreler önemli bir avantaj sunarken, öte yandan algoritmaların oluşturduğu bu filtreler, kullanıcıların farklı görüşlere erişimini kısıtlayarak “filtre baloncukları” yaratabilmektedir. Bu durum, özellikle sınırsız içeriğe sahip web ortamında dezavantajlı olabilirken, yapısal verilerin bulunduğu Çevrimiçi Kütüphane Katalogları (OPAC) gibi ortamlarda bir avantaja dönüştürülebilir. Bu çalışmanın temel hipotezi, web ortamında bilgi erişimini daraltabilen filtreleme ve kişiselleştirme mekanizmalarının, OPAC’larda kullanıcıların niş kaynakları ve disiplinlerarası bağlantıları keşfetmesine yardımcı olabileceğidir. Bu hipotezi test etmek amacıyla, Latent Dirichlet Allocation (LDA), X-means kümeleme ve Local Outlier Factor (LOF) gibi yapay öğrenme algoritmalarını kullanıcı davranış verileriyle birleştiren bir model geliştirilmiştir. Model, Amazon kitap veri seti üzerinde test edilmiş; kullanıcıların etkileşim verileri eklenerek oluşturulan “geliştirilmiş sıralama”nın,

1 Dr. Öğretim Üyesi, Ankara Yıldırım Beyazıt Üniversitesi Bilgi ve Belge Yönetimi Bölümü, Ankara, Türkiye. E-posta: mugeakbulut@gmail.com

geleneksel üst veri tabanlı “standart sıralama”ya kıyasla daha çeşitli ve disiplinlerarası sonuçlar ürettiği, niş kaynakların keşfine olanak tanıdığı ve ilgililik-çeşitlilik dengesi açısından başarılı olduğu gözlemlenmiştir. Çalışma, OPAC’larda serendipiti (şans eseri değerli buluş) potansiyelini artıracak alternatif bir sıralama yaklaşımı sunmaktadır.

Anahtar Sözcükler: Çevrimiçi filtreler, yapay öğrenme, ilgi sıralaması, OPAC, çeşitlendirme, serendipiti, konu modelleme, kümeleme, x-means, aykırı değer analizi.

Abstract

Users utilize the exponentially growing digital environment both to obtain information on subjects they are curious about and to meet their daily news and information needs. While filters for creating personalized search results offer significant advantages in this environment, these algorithm-driven filters can also restrict users’ access to diverse viewpoints, creating “filter bubbles.” While this can be disadvantageous in the boundless web environment, it may be turned into an advantage in environments with structured data, such as Online Public Access Catalogs (OPACs). The main hypothesis of this study is that filtering and personalization mechanisms, which can narrow information access on the web, might be beneficial in OPACs by helping users discover niche resources and interdisciplinary connections. To test this hypothesis, a model combining machine learning algorithms like Latent Dirichlet Allocation (LDA), X-means clustering, and Local Outlier Factor (LOF) with user behavior data was developed. The model was tested on the Amazon book dataset. The results indicate that the “enhanced ranking,” created by incorporating user interaction data, produces significantly more diverse and interdisciplinary results compared to the traditional metadata-based “standard ranking,” enables the discovery of niche resources, and performs well in balancing

relevance and diversity. The study proposes an alternative ranking approach for OPACs aimed at increasing serendipity potential.

Keywords: *Online filters, machine learning, relevance ranking, OPAC, diversification, serendipity, topic modeling, clustering, x-means, outlier detection.*


1. Giriş

Çevrimiçi Kütüphane Katalogları (OPAC'lar)², kullanıcıların kaynaklara erişimini sağlamada temel bir işlev görse de geleneksel sıralama algoritmaları bu sistemlerin keşif potansiyelini önemli ölçüde kısıtlamaktadır. Genellikle anahtar kelime çakışması, konu başlıkları veya yayın tarihi gibi standart faktörlere dayanan bu yaklaşımlar, kullanıcıları yapısal olarak tanımlanmış bilgi sınırları içinde tutarak, özellikle disiplinlerarası araştırma yapan akademisyenler veya yeni fikirler arayan kullanıcılar için beklenmedik değerli kaynakların keşfedilmesini zorlaştırmaktadır. Bu durum, OPAC'ların kullanıcıların “şans eseri değerli buluş” (serendipiti) yapma potansiyelini sınırlandırmaktadır. Dolayısıyla, mevcut OPAC sistemlerinde, salt ilginin ötesine geçerek kullanıcıların bilgi ufkunu genişletecek ve tematik çeşitliliği artıracak yenilikçi sıralama modellerine ihtiyaç duyulmaktadır.

Bu çalışmadaki temel fikir, açık web ortamında sorun yaratan bazı mekanizmaların —örneğin kişiselleştirme ve kullanıcı davranışı analizi— OPAC'ların yapısal ve kontrollü ortamında avantaja dönüştürülebileceğidir. Google ve Meta gibi teknoloji şirketleri, kullanıcıların ilgisini canlı tutmak amacıyla kişiselleştirilmiş içerik akışları sunmaktadır. Ancak bu süreç, kullanıcıların sürekli kendi bakış açılarıyla uyumlu içeriklere maruz kalmasına yol açarak bir tür “filtre baloncuğu” oluşturmaktadır; yani kişinin dünyayı, yalnızca algoritmaların seçtiği dar bir bilgi kümesi üzerinden görmesine neden olmaktadır. Bu durum, insanların mevcut inançlarını doğrulayan bilgilere yönelme eğilimi olan “doğrulama sapması” ile birleştiğinde entelektüel izolasyonu daha da artırabilir. Oysa aynı mekanizmalar, koleksiyon sınırları belirli olan OPAC ortamında, tam tersine kullanıcıların farklı disiplinlerden kaynaklara ulaşmasını ve beklenmedik bağlantılar keşfetmesini sağlayabilir.

2 Kütüphanenin dijital ortamda erişilebilen katalog sistemi.

Bu fikrin kavramsal altyapısı, dijital ortamdaki devasa bilgi hacmini yönetmek üzere geliştirilen stratejilerden ilham almaktadır. Geleneksel “filtrele ve sonra yayınla” modelinin yerini büyük ölçüde “yayınla ve sonra filtrele” modelinin alması, benzeri görülmemiş bir içerik yelpazesi yaratmaktadır. Bu içerik dağılımı, genellikle “kuvvet yasası” veya “uzun kuyruk” olarak bilinen dengesiz bir örüntü sergilemektedir. Bu bağlamda, Shirky’nin (2008) Flickr fotoğrafçıları üzerine yaptığı çalışma, az sayıda popüler içeriğin yüksek görünürlük kazanırken, geri kalan büyük çoğunluğun (uzun kuyruk) daha az ilgi gördüğünü somut bir şekilde göstermektedir (Şekil 1).




Şekil 1. 2005 yılı Coney Adası Denizkızı Geçidi'nin fotoğrafını yükleyen fotoğrafçıların dağılımı (Shirky, 2008, s.109).

Bu yaklaşım, Netflix veya Spotify gibi platformların öneri sistemlerinin ardındaki temel mantıkla örtüşmektedir; bu sistemler, kullanıcı davranış verilerini analiz ederek “uzun kuyruk” (Anderson, 2006) olarak adlandırılan niş içeriklere erişimi kolaylaştırır ve konu çeşitlendirmesi yoluyla (Ziegler ve diğerleri, 2005) serendipiti potansiyelini artırmaktadır.

Benzer şekilde, yenilikçilik genellikle farklı bilgi alanlarının verimli kesişimlerinde ortaya çıkmaktadır. Poetz ve Prügl’ün

(2010) araştırmaları, ilk bakışta farklı görünse de temelde benzer problem veya çözüm yapılarına sahip “analog alanlardaki” uzmanlığa erişimin, yenilikçi fikir üretimini önemli ölçüde hızlandırdığını göstermektedir. Geliştirdikleri piramit araştırma tekniği, araştırmacıları kendi uzmanlık alanlarından kavramsal olarak uzaklaştırarak daha radikal ve yenilikçi çözümler üretmeye teşvik eden sistematik bir yöntem sunmaktadır (Şekil 2).



Şekil 2. Piramit araştırma tekniği (Poetz ve Prügl, 2010, s.35)

Bu çalışmada önerilen model de benzer bir mantıkla, kullanıcıları kendi bilgi sınırlarının dışına çıkararak farklı disiplinler arasındaki görünmez bağlantıları keşfetmelerini ve bu sayede serendipiti potansiyellerini artırmayı hedeflemektedir.

Öte yandan, üretken yapay zekâ sistemlerinin yükselişi bilgi erişiminde yeni olanaklar sunsa da, bu sistemlerin bir tür “kara kutu” gibi çalışması ve halüsinasyon (yanıltıcı bilgi üretimi) gibi sorunlar barındırması önemli sınırlamalar doğurmaktadır. Bu noktada, özellikle OPAC ortamı için kontrollü, hesaplanabilir ve şeffaf yaklaşımların daha sürdürülebilir olacağı öngörülmektedir. Bu bağlamda araştırma, OPAC’lardaki geleneksel sıralama algoritmalarının ötesine geçerek, kullanıcıların keşif potansiyelini en üst düzeye çıkarmayı hedefleyen çok katmanlı bir ilgi sıralama

modeli önermektedir. Çalışmanın hipotezi, “Web ortamında filtre baloncukları yaratma riski taşıyan kişiselleştirme, kullanıcı davranışı analizi ve gelişmiş filtreleme teknikleri, OPAC gibi daha kontrollü bir ortamda, kullanıcıların kavramsal derinliğini artırmak, disiplinlerarası ve analog alanlardaki kaynakları keşfetmelerini sağlamak ve serendipiti potansiyelini artırmak için bir avantaja dönüştürülebilir” şeklinde formüle edilmiştir.

Söz konusu hipotezi test etmek amacıyla, Latent Dirichlet Allocation (LDA), X-means kümeleme ve Local Outlier Factor (LOF) gibi yapay öğrenme algoritmalarını kullanıcı davranış verileriyle birleştiren bir model geliştirilmiş ve etkinliği sınanmıştır. Bu çalışma, aşağıdaki temel araştırma sorularına yanıt aramaktadır:

- Önerilen sıralama algoritması, standart sıralamayla karşılaştırıldığında erişilen kaynakların çeşitliliğini (ILS@20) nasıl etkilemektedir? (AS 1)
- Önerilen sıralama algoritmasının, erişilen kaynakların çeşitliliği (ILS@20) ve ilgi-çeşitlilik dengesi (Alpha-nDCG@20) metrikleri üzerindeki etkisi, standart sıralama ile karşılaştırıldığında nasıl bir değişim göstermektedir? (AS 2)
- Kullanıcı verilerinin algoritmaya dahil edilmesi, arama sonuçlarının tematik kümelenmesini nasıl farklılaştırmaktadır? (AS 3)

2. Yöntem

2.1. Veri Seti, Ön İşleme ve Entegrasyon

Araştırma kapsamında Stanford Network Analysis Project (SNAP) tarafından derlenen ve kamuya açık olan Amazon kitap veri seti (McAuley ve Leskovec, 2013) kullanılmıştır. Bu veri setinin seçilmesindeki temel etkenler: Yaklaşık 930.000 özgün

kitaba ve Haziran 1995 ile Mart 2013 arasındaki 18 yıllık dönemi kapsayan 12,8 milyondan fazla kullanıcı incelemesine sahip olması, başlık, yazar, kategori gibi çeşitli üst verileri barındırması ve özellikle metin tabanlı incelemeler, 1-5 arası sayısal derecelendirmeler ve örtük etkileşim logları (örn., birlikte görüntülenen ürünler) gibi zengin kullanıcı geri bildirimlerini içermesidir. Bu niteliklerin, hem kaynakların derinlemesine anlamsal analizini (özellikle metin incelemeleri aracılığıyla) hem de kullanıcı tercihleri ile kolektif davranış örüntülerinin modellenmesini sağlayarak, önerilen çok yönlü sıralama modelinin etkinliğini test etmek için ideal bir zemin sunduğu düşünülmektedir.

Ham veri setinin sonraki analiz adımlarına uygun hale getirilmesi amacıyla, yapısal üst veriler (bibliyografik bilgiler), metin içerikleri (başlıklar, özetler, incelemeler), kullanıcı puanları ve etkileşim logları gibi heterojen veri türlerini kapsayan sistematik bir ön işleme ve entegrasyon süreci yürütülmüştür. Bu süreçte, ilk olarak farklı kaynaklardan gelen veriler tutarlı bir yapıda birleştirilmiştir. Ardından, anlamsal analizin temelini oluşturan metinsel veriler, standart Doğal Dil İşleme (Natural Language Processing - NLP) teknikleri kullanılarak işlenmiştir. Bu bağlamda, metinler tek tip harf düzenine (küçük harf) dönüştürülmüş, sayısal karakterler, noktalama işaretleri ve özel semboller temizlenmiş, metinler anlamlı birimlere (token) ayrıştırılmış (tokenizasyon), anlamsal katkısı düşük yaygın kelimeler (stop words) çıkarılmış ve kelimeler, bağlamı koruyarak anlamsal köklerine indirgenmiştir (lemmatization). Uygulanan bu ön işleme adımları, ham veri setinde yer alan 12,8 milyondan fazla kullanıcı incelemesinden oluşan metinleri standart bir formata getirmeyi hedeflemiştir. Bu sürecin metodolojik bir sınırlılığı olarak, filtreleme adımları sırasında kapsam dışı bırakılan incelemelerin sayısı ve nihai veri kaybı oranı detaylı olarak kaydedilmemiştir. Anlamsal kök bulma (lemmatization) sürecinde ise, işlemin tekrarlanabilirliğini sağlamak amacıyla

Python programlama dilinin NLTK (Natural Language Toolkit) kütüphanesinden yararlanılmıştır. Bu sayede veri seti yapay öğrenme algoritmalarının üzerinde koşturulabileceği temiz, tutarlı ve yapılandırılmış bir formata dönüştürülmüştür.

Araştırmada kullanılan Amazon kitap veri setinin, OPA-C'lardan farklı olarak ticari bir amaca hizmet ettiği ve bu nedenle kullanıcı davranış motivasyonlarının (örneğin, tüketim, değerlendirme, öneri alma odaklı aramalar) akademik arama davranışlarından (örneğin, belirli bir kaynağı bulma, literatür tarama) farklılık gösterebileceği kabul edilmektedir. Bu farklılıklara karşın söz konusu veri seti; (1) milyonlarca kullanıcı etkileşimini (puanlama, metin incelemeleri, birlikte görüntüleme logları) barındıran zengin ve yapısal bir içeriğe sahip olması, (2) OPAC ortamlarında henüz bu ölçekte kamuya açık bir veri setinin bulunmaması ve (3) önerilen çok katmanlı sıralama modelinin teknik fizibilitesini ve algoritmik performansını test etmek için ideal bir zemin sunması nedenleriyle bir vekil ortam (proxy environment) olarak tercih edilmiştir. Dolayısıyla bu çalışma, modelin gerçek bir OPAC'taki kullanıcı deneyimi üzerindeki etkisini ölçmekten ziyade, bu tür bir modelin algoritmik olarak nasıl inşa edilebileceğini ve potansiyel faydalarını (örneğin, çeşitliliği artırma) ortaya koymayı hedeflemektedir.

2.2. Anlamsal Konu Modelleme ve Kullanıcı Verisi Entegrasyonu

Kaynakların metinsel içeriğindeki gizli anlamsal temaları ortaya çıkarmak ve kullanıcı davranışlarını modele dahil etmek amacıyla, olasılıksal konu modelleme alanında yaygın olarak kullanılan LDA algoritması (Blei ve diğerleri, 2003) uygulanmıştır. LDA, her kitabı konular üzerindeki bir olasılık dağılımı, her konuyu ise kelimeler üzerindeki bir olasılık dağılımı olarak modelleyerek, ön işlenmiş metin külliyatından (kitap başlıkları,

özetleri ve kullanıcı incelemeleri) her kitap için çok boyutlu bir anlamsal kimlik (konu dağılım vektörü) türetmektedir (Akbulut ve Tonta, 2022). Modelin oluşturduğu konuların daha anlamlı olmasını ve genel performansını (genelleme yeteneğini) iyileştirmek için, kaç tane konu üretileceği gibi önemli ayarlar belirlenmiştir. Bu ayarlar yapılırken, konuların kendi içindeki anlam bütünlüğünü ölçen konu tutarlılığı (topic coherence) ve konuların belgeleri ne kadar iyi sınıflandırdığını gösteren belge sınıflandırma (document classification) gibi ölçütler kullanılarak en iyi sonuçlar hedeflenmiştir (Terragni ve diğerleri, 2022). Bu kapsamda, model için en uygun konu sayısını (k) belirlemek amacıyla dört farklı metrik (Arun ve diğerleri, 2010; Cao ve diğerleri, 2009; Deveaud ve diğerleri, 2014; Griffiths ve Steyvers, 2004) kullanılmıştır. Metriklerin ortaklaşa işaret ettiği optimum aralığa ve üçüncü metriğin (Deveaud ve diğerleri, 2014) tutarsız ve bilgilendirici olmayan örüntüsü nedeniyle analiz dışı bırakılmasına dayanarak, konu tutarlılığını en iyi temsil eden $k=80$ değeri nihai model için en uygun parametre olarak belirlenmiştir.

Modelin anlamsal analiz yeteneğini kullanıcıların kolektif davranış verileriyle zenginleştirmek amacıyla, metin dışı özellikler de türetilmiştir. Bu doğrultuda, kullanıcıların verdiği 1-5 arası sayısal derecelendirmeler (puanlar), her bir kaynak için doğrudan bir özellik (feature) olarak kullanılmıştır. Bu puanlar, kaynakların genel popüleritesini ve kullanıcı memnuniyetini yansıtan bir metrik olarak, özellikle kümeleme ve aykırı değer analizi aşamalarında kaynak vektörlerine dahil edilmiştir. Ayrıca, örtük etkileşim verilerinden olan “birlikte görüntülenen ürünler” logları ise, kaynaklar arasında kullanıcı davranışına dayalı bir ağ oluşturmak için kullanılmıştır. Bu veriler, bir tür işbirlikçi filtreleme mantığıyla, bir kaynakla ilgilenen kullanıcıların başka hangi kaynaklara yöneldiğini modellemek için işlenmiş ve ilişkiler, kaynakların tematik yakınlıklarını güçlendiren ek bir ağırlık olarak hesaba katılmıştır.

Bu süreçler sonunda, her bir kaynak (bu çalışmadaki veri seti için kitap) için sıralama modeline girdi olarak sunulan nihai özellik vektörü şu üç ana bileşenden oluşturulmuştur: (1) LDA modelinden elde edilen ve kitabın anlamsal içeriğini temsil eden konu dağılım vektörü, (2) Kullanıcılar tarafından verilen ve kaynağın nicel popülerliğini yansıtan ortalama puan, ve (3) Örtük etkileşim verilerinden türetilen ve kaynağın diğer kaynaklarla olan davranışsal ilişkisini gösteren ağ merkezilik skoru. Bu heterojen özellikler, bir sonraki aşamada (bkz. Kümeleme, Aykırı Değer Analizi ve Sıralama Çeşitlendirmesi) normalize edilerek model için tutarlı bir girdi formatına dönüştürülmüştür.

2.3. Kümeleme, Aykırı Değer Analizi ve Sıralama Çeşitlendirmesi

LDA ve kullanıcı verisi entegrasyonu ile elde edilen ilk sıralamanın potansiyel tematik yoğunlaşmasını gidermek, sonuç listesindeki çeşitliliği artırmak ve serendipiteyi teşvik etmek amacıyla bir dizi ileri analiz tekniği zincirleme olarak uygulanmıştır. İlk adım olarak, farklı ölçek ve birimlerde olabilen heterojen özellikler (LDA konu vektör bileşenleri, kullanıcı puanları, etkileşim sayıları vb.) normalize edilerek³ karşılaştırılabilir hale getirilmiştir. Ardından, normalleştirilmiş veriler üzerinde, kaynakları anlamsal ve/veya davranışsal benzerliklerine göre gruplara ayırmak için, küme sayısını Bayesian Information Criterion (BIC) gibi istatistiksel model seçme kriterleri ile otomatik olarak belirleyen X-means algoritması (Pelleg ve Moore, 2000) kullanılmıştır.


Tutarlı tematik kümelerin belirlenmesinin ardından, bu kümelerin sınırlarında yer alan veya belirgin bir gruba tam olarak ait olmayan, ancak potansiyel olarak farklı ve değerli (analog alan olabilecek) kaynakları tespit etmek amacıyla, yoğunluk tabanlı

³ $x_{\text{normalize}} = (x - x_{\text{min}}) / (x_{\text{max}} - x_{\text{min}})$

bir aykırı değer saptama tekniği olan Yerel Aykırı Değer Faktörü (Local Outlier Factor - LOF)⁴ algoritması uygulanmıştır. Tamamen ilgisiz kaynakları filtrelerken disiplinlerarası veya yenilikçi potansiyeli olan bağlantıları kaçırmamak için, LOF skoruna dayalı aykırılık eşiği dinamik olarak ayarlanmıştır; örneğin, LOF skorları dağılımının en yüksek %10'luk dilimde olan kaynaklar potansiyel aykırı değer olarak etiketlenmiştir. LOF ile tespit edilen bu aykırı kaynaklar, doğrudan elenmek yerine, serendipiti potansiyeli taşıyan adaylar olarak değerlendirilmiş ve yeniden sıralama aşamasında önceliklendirilmiştir.

Son aşamada, bu bilgilerle zenginleştirilmiş kaynak havuzu üzerinde çeşitlendirme odaklı bir yeniden sıralama stratejisi uygulanmıştır. Bu süreç, sorguyla en ilgili ana kümeden, diğer komşu kümelerden ve LOF ile “keşif adayı” olarak belirlenen kaynaklardan oluşan bir aday listesi üzerinden, Maksimum Marjinal İlgi (Maximal Marginal Relevance - MMR) algoritması (Ziegler ve diğerleri, 2005) kullanılarak gerçekleştirilmiştir. MMR, listenin en başına en ilgili kaynağı yerleştirdikten sonra, sonraki her adımda, aday kaynaklar arasından hem sorguyla ilgisi yüksek hem de listeye eklenmiş diğer kaynaklardan anlamsal olarak en farklı olanı seçerek ilerler. Bu iterative yaklaşım, bilgi tekrarını (redundancy) azaltırken aynı zamanda ilgi ve çeşitlilik arasında optimize edilmiş bir denge kurarak nihai sonuç listesini oluşturur. Bu dengenin ayarlanmasında, MMR algoritmasının λ parametresi 0,5 olarak belirlenmiş, böylece ilgi ve çeşitlilik arasında eşit bir ağırlıklandırma hedeflenmiştir.

4 LOF veri kümesindeki aykırı değerleri tespit eden yoğunluk tabanlı bir algoritmadır. Bir noktanın yerel yoğunluğunu komşularıyla karşılaştırarak çalışır ve bu sayede lokal (küresel olmayan) aykırı değerleri daha etkili şekilde belirler (Breunig ve diğerleri, 2000).




Şekil 3. X-means Kümeleme Sonuçlarının Kavramsal Görselleştirmesi.

2.4. Model Mimarisi, Uygulama ve Çıktılar

Geliştirilen bütünlük modelin genel yapısını gösteren mimari Şekil 4’te şematik olarak sunulmuştur. Söz konusu model, ardışık ve birbirini besleyen modüllerden oluşmaktadır: (1) Veri Toplama ve Ön İşleme, (2) LDA ile Anlamsal Konu Modelleme, (3) Kullanıcı Davranış Verisi Entegrasyonu, (4) Özellik Normalizasyonu, (5) X-means ile Anlamsal/Davranışsal Kümeleme, (6) LOF ile Aykırı Değer Tespiti ve Analog Alan Belirleme ve (7) Çeşitlendirme Odaklı Yeniden Sıralama.

Modelin prototip uygulaması Python programlama dili kullanılarak gerçekleştirilmiştir. Uygulama sürecinde, metin ön işleme adımları için NLTK veya spaCy, LDA modellemesi için Gensim, kümeleme (X-means, K-means), normalizasyon, LOF ve değerlendirme metrikleri için Scikit-learn, veri manipülasyonu için ise Pandas ve NumPy kütüphanelerinden yararlanılmıştır.



Şekil 4. Önerilen Modelin Genel Mimarisi ve Veri Akışı

Modelin etkinliğini geleneksel yaklaşımlarla nesnel bir şekilde kıyaslayabilmek amacıyla, örnek sorgu için standart ($tf \cdot idf$) ve gelişmiş (bu çalışma kapsamında önerilen) olmak üzere iki farklı sıralama üretilmiş ve detaylı olarak incelenmiştir. Bu iki sıralamanın etkinliğini karşılaştırmak amacıyla, ilk 20 ($k=20$) sonuç üzerinden, literatürde yerleşik bilgi erişim metrikleri kullanılarak değerlendirmeler yapılmıştır. Bu değerlendirmelerde, UMBRELA yaklaşımıyla belirlenen ilgi değerleri temel alınarak hem duyarlılık ($Precision@20$) ve anma ($Recall@20$) gibi ilgi metrikleri hem de sıralama kalitesini ölçen $nDCG@20$ hesaplanmıştır. Ayrıca, önerilen kaynaklar arasındaki tematik çeşitlilik, LDA konu vektörleri arasındaki kosinüs benzerliğine dayalı Liste İçi Benzerlik ($ILS@20$) ile ve ilgi-çeşitlilik dengesi ise α - $nDCG@20$ ($\alpha=0,5$) metriği ile ölçülmüştür. Önerilen sıralama, standart listenin gözden kaçırabileceği veya alt sıralara itebileceği, farklı disiplinlerden gelen, niş konulara ait veya beklenmedik ancak

potansiyel olarak değerli ve yenilikçi kaynakları bilinçli olarak ön plana çıkarmayı amaçlamaktadır.

2.5. Çalışmanın Sınırlılıkları

Bu çalışmada sunulan model ve elde edilen bulgular, alana yönelik önemli çıkarımlar sunmakla birlikte, sonuçların yorumlanmasında dikkate alınması gereken bazı metodolojik sınırlılıklara sahiptir. İlk olarak, çalışmanın en temel sınırlılığı kullanılan veri setinden kaynaklanmaktadır. Araştırmada kullanılan Amazon kitap veri seti, 1995 ile 2013 arasını kapsamaktadır ve güncel olmaması, o tarihten bu yana değişen kullanıcı davranışları nedeniyle bulguların günümüz sistemlerine genellenebilirliğini kısıtlamaktadır. Buna ek olarak veri setinin ticari bir platforma ait olması, en temel metodolojik sınırlılığı oluşturmaktadır. Amazon kullanıcılarının arama motivasyonları sıklıkla tüketim, değerlendirme veya anlık öneri alma odaklıyken, OPAC kullanıcıları genellikle belirli bir araştırma hedefi doğrultusunda hareket etmektedir. Bu motivasyonel farklılık, kullanıcıların etkileşim sinyallerinin (örneğin, 1-5 arası puanlama ile akademik atıf sayısı arasındaki anlamsal fark) niteliğini değiştirebilir. Bu nedenle, Amazon veri seti üzerinde elde edilen performans metriklerinin ve bulguların, gerçek bir kütüphane OPAC ortamına doğrudan aktarılabilirliği sınırlıdır. Çalışmanın bulguları, modelin gerçek dünyadaki etkinliğinin bir kanıtı olarak değil, bu tür gelişmiş sıralama algoritmalarının potansiyelini gösteren bir kavram kanıtı (proof-of-concept) olarak yorumlanmalıdır. Veri setinin doğasından kaynaklanan bu kısıtlara ek olarak, performans değerlendirme metodolojisi de bir diğer sınırlılığı oluşturmaktadır. Modelin başarısı, yalnızca GPT-4 tabanlı otomatik puanlayıcı olan UMBRELA algoritmasına dayandırılmış, insan değerlendirmeleri gibi alternatif doğrulama yöntemlerine yer verilmemiştir.


Analizin kapsamı ve hipotez doğrulamanın niteliği de dikkate alınması gereken diğer sınırlılıklardır. Performans metrikleri, her sorgu için yalnızca ilk 20 sonuca ($k=20$) odaklanarak hesaplanmış, bu da algoritmanın daha derin sıralardaki performansına dair bütüncül bir tablo sunulmasını engellemiştir. Ayrıca, çalışmanın hipotezinde belirtilen “disiplinlerarası kaynakları keşfetme” iddiası, yalnızca algoritmik çeşitlilik metrikleri ile nicel olarak desteklenmiştir. Bulgular istatistiksel olarak çeşitliliğin arttığını gösterse de, keşfedilen disiplinlerarası bağlantıların niteliği veya kullanıcı için anlamlılığı bu araştırma kapsamında nitel olarak analiz edilmemiştir.

3. Bulgular ve Yorum

3.1. Filtreleme Algoritmasının Örnek Senaryo Üzerinde Uygulanması

Bu bölümde geliştirilen modelin uygulamasını ve etkisini göstermek amacıyla temsili bir senaryo üzerinden elde edilen bulgular sunulmaktadır. Örnek senaryo olarak, “sosyal ağların gücü” (power of social networks) konusuna ilişkin bir kitap araması simüle edilmiştir.


İlk olarak, standart sıralama yaklaşımıyla ($tf*idf$) erişilen ilk 20 kaynak listelenmiştir. Bu sonuçların üst verilerine dayalı ağ gösterimi Şekil 5'teki gibidir. Bu sıralamada sorguyla ilgi puanı yüksek “The Hidden Power of Social Networks: Understanding How Work Really Gets Done in Organizations” gibi başlıklar ön plandadır ve sıralama, bu ana tema etrafında kümelenme eğilimi göstermektedir. Bu yaklaşım, kullanıcının veya diğer kullanıcıların davranışsal geçmişini dikkate almamaktadır.



Şekil 5. Standart Sıralama: “Sosyal Ağların Gücü” Sorgusu için Üst Veriye Dayalı Olarak Erişilen İlk 20 Kaynağın Ağ Gösterimi

İkinci aşamada ise geliştirilmiş sıralama yaklaşımı uygulanmıştır. Kullanıcı log verileri analize dahil edilmiş ve yöntem bölümünde açıklanan kümeleme (X-means) ve aykırı değer analizi (LOF) teknikleri uygulanarak sıralama yeniden oluşturulmuştur. Şekil 6, bu geliştirilmiş sırala yöntemi ile erişilen ilk 20 kitabın, kullanıcı davranışlarını ve anlamsal çeşitliliği yansıtan ağ gösterimini yansıtmaktadır. Şekil 5 ile karşılaştırıldığında, Şekil 6’daki dağılımın daha çeşitli olduğu ve farklı renklerle temsil edilen belirgin kümelerin ortaya çıktığı gözlenmiştir. Bu durum nicel olarak da doğrulanmıştır: Standart sıralama, tek bir baskın tematik grup etrafında yoğunlaşırken (1 küme), X-means algoritması geliştirilmiş sıralamada belirgin 3 farklı tematik küme (sosyal ağ analizi, karmaşıklık teorisi ve ağ bilimi) tespit etmiştir. Ayrıca, önerilen kaynaklar arasındaki tematik çeşitliliği ölçen Liste İç Benzerlik (ILS@20) skoru, standart sıralamada 0,44 iken geliştirilmiş sıralamada 0,18’e düşerek %60’lık bir çeşitlilik artışına işaret etmiştir. Bu

kümelerdeki kitaplar, standart sıralamada daha altlarda yer alan veya hiç görünmeyen (örn., “Emergence”, “Sync”, “Complexity” temalı kitaplar), ancak kullanıcı davranışları ve anlamsal analiz sonucunda sorguyla dolaylı olarak ilişkili veya potansiyel olarak yenilikçi bulunan niş kaynakları temsil etmektedir. Diğer bir deyişle marjinal ilgili kaynakları temsil etmektedir.



Şekil 6. Geliştirilmiş Sıralama: “Sosyal Ağların Gücü” Sorgusu İçin Kullanıcı Verisi ve Anlamsal Analizle Çeşitlendirilerek Erişilen İlk 20 Kaynağın Ağ Gösterimi

Bu bulgular, geliştirilmiş sıralamanın, standart sıralamanın gözden kaçırabileceği potansiyel olarak ilgili ancak daha az belirgin veya farklı alanlardan kaynakları üst sıralara yerleştirme potansiyeline sahip olduğunu göstermektedir. Geleneksel kataloglamadaki başlık veya konu başlığı sınırlılıkları, kullanıcıların kolektif etkileşimlerinden elde edilen örtük anlamsal bağlantılarla kısmen aşılabilmektedir (AS 3). Bu durum, özellikle disiplinlerarası araştırma yapan veya yeni fikirler arayan kullanıcılar için değerlidir. X-means algoritmasının küme sayısını


otomatik belirlemesi ise farklı sorgulara uyum sağlama esnekliği açısından avantajdır.

3.2. Performans Değerlendirme

Önerilen sıralama algoritmasının etkinliğini ortaya koymak amacıyla, standart yaklaşımla karşılaştırmalı bir değerlendirme süreci yürütülmüştür. Bu değerlendirme, 50 farklı kullanıcı sorgusu üzerinden gerçekleştirilmiş olup, her sorgu için her iki algoritmanın ürettiği ilk 20 ($k=20$) kitap önerisi detaylı bir analize tabi tutulmuştur. İnsan değerlendirmelerinin büyük ölçekli veri setlerinde uygulanmasındaki pratik zorluklar göz önüne alındığında, ilgi değeri belirlenmesi için otomatik bir yöntem olan GPT-4 tabanlı UMBRELA (UMBrela is the Bing RElevance Assessor) algoritmasından yararlanılmıştır. UMBRELA, sıfır-vuruşlu (zero-shot) DNA prompt tekniği aracılığıyla her bir belge-sorgu çifti için 0 (ilgisiz) ile 3 (tamamen alakalı) arasında dereceli bir ilgi puanı atamaktadır (Upadhyay ve diğerleri., 2024b). Bu yaklaşım TREC Deep Learning gibi standart bilgi erişim senaryolarında insan yargılarıyla yüksek düzeyde korelasyon sağlamıştır ve özellikle kısa metin sorgularda etkili olduğu rapor edilmiştir (Upadhyay ve diğerleri, 2024b). Ancak UMBRELA tarafından üretilen puanların algoritmik tahminler olduğu ve yaklaşık %3-5 oranında sapma içerebileceğini de hatırlatmakta yarar vardır (Upadhyay ve diğerleri, 2024a; 2024b).

Değerlerin hesaplanması sürecinde, UMBRELA tarafından belirlenen ilgi puanları, ölçülmek istenen performans boyutuna göre farklı ölçeklerle incelenmiştir. Özellikle, algoritmanın ne kadar ilgili belge döndürdüğünü ölçen Precision@20 (P@20, duyarlılık) ve mevcut ilgili belgelerin ne kadarını bulabildiğini ölçen Recall@20 (R@20, anma) metrikleri için ikili (binary) işaretleme yapılmıştır. Bu sistemde UMBRELA puanı 0 olan belgeler “ilgisiz”, 1 veya daha yüksek puan alanlar ise “ilgili”

olarak kabul edilmiştir. Öte yandan hem ilgi derecesini hem de ilgili belgelerin sıralamadaki konumunu dikkate alan Normalleştirilmiş İndirimli Birikimli Kazanç (nDCG@20) metriğinin hesaplanmasında, UMBRELA'nın orijinal 0-3 aralığındaki dereceli puanları muhafaza edilmiştir. Şekil 7'de önerilen ve standart algoritmanın temel metriklere göre karşılaştırılması yer almaktadır.



Şekil 7. Algoritmaların ortalama performans ölçütleri karşılaştırması (k=20, N=50 sorgu)

Şekil 7'de önerilen algoritmanın tüm metriklerde üstünlüğü göze çarpmaktadır. Precision@20 değeri 0,65'ten 0,75'e yükselerek +%15'lik bir artış göstermiştir ($t(49) = 2.45, p = .018$). Benzer şekilde, Recall@20 değeri de 0,85'ten 0,93'e çıkarak +%9'luk bir iyileşme kaydetmiştir. Sıralama kalitesinin kritik bir göstergesi olan nDCG@20 metriğinde ise değer 0,88'den 0,95'e ulaşarak +%8'lik bir gelişme sağlamıştır. Bu üç temel metrikte gözlemlenen tutarlı ve pozitif yönlü değişim, önerilen algoritmanın hem daha fazla sayıda ilgili kaynağa üst sıralarda erişme hem de bu kaynakları kullanıcı için optimal bir sırada sunma konusunda daha başarılı olduğunu göstermektedir.

Algoritmaların çeşitlilik üzerindeki etkisi, Liste İçi Benzerlik (Intra-List Similarity, ILS@20) metriği aracılığıyla değerlendirilmiştir. Söz konusu metrik önerilen ilk 20 kaynak arasındaki anlamsal benzerliği LDA konu vektörleri arasındaki ortalama kosinüs benzerliği ile ölçmektedir. Burada düşük ILS değerleri daha yüksek çeşitlilik anlamına gelmektedir. Önerilen algo-

ritmanın ILS@20 skoru (0,05), standart algoritmanın skoruna (0,12) kıyasla -%58'lik bir düşüş göstermiştir. Bu durum, liste içi benzerliğin istatistiksel olarak azaldığını ve algoritmanın sonuç listesini çeşitlendirme hedefini (AS 1) başarıyla gerçekleştirdiğini göstermektedir.

İlgi ve çeşitlilik arasındaki dengeyi kantitatif olarak ölçmek amacıyla, literatürde yaygın olarak kullanılan Alpha-nDCG (α -nDCG) metriği, $\alpha=0.5$ parametresi ile hesaplanmaktadır. Bu metrik hem nDCG ile ölçülen ilgi ve sıralama kalitesini hem de ILS ile ölçülen çeşitliliği (çeşitliliğin tersi olan benzerlik de denebilir) dengeli bir şekilde birleştirmeyi hedeflemektedir (Leelanupab ve diğerleri, 2012). Önerilen algoritma, α -nDCG@20 metriğinde 0,95'lik bir skora ulaşırken, standart algoritma 0,88'de kalmıştır. Yani +%8'lik artış önerilen algoritmanın sağladığı belirgin çeşitlilik avantajının (ILS@20 düşüşü), ilgi ve sıralama kalitesindeki üstünlüğü (nDCG@20 artışı) ile birleşerek, ilgi ile çeşitlilik arasında etkili bir denge kurduğunu göstermektedir (AS 2). Diğer bir deyişle genel kullanıcı deneyimini iyileştirme potansiyeli taşıdığını ortaya koymaktadır.

Tablo 1'de sunulan karşılaştırmalı veriler de daha detaylı olarak önerilen sıralama algoritmasının standart yaklaşıma göre ilgi (Precision@20, R@20), sıralama kalitesi (nDCG@20), çeşitlilik (ILS@20) ve bu faktörlerin dengesi (α -nDCG@20) açılarından tutarlı ve önemli ölçüde daha iyi bir performans sergilediğini net bir şekilde özetlemektedir. Bu sonuçlar bütüncül olarak değerlendirildiğinde, önerilen algoritmanın üç temel avantaj sunduğu söylenebilir: (1) daha yüksek oranda ilgili içerik sunumu (sorguyla ilgi oranının artırılması), (2) ilgili içeriklerin daha üst sıralarda konumlandırılmasıyla iyileştirilmiş sıralama kalitesi ve (3) sıralama içinde daha dengeli ve çeşitli bir içerik barındırma. Bununla birlikte, bu performans metriklerinin, farklı kullanıcı arama senaryolarını (örneğin, belirli bir kaynağı bulmaya yönelik hedefli arama ile bir konuyu keşfetmeye yönelik gezinti amaçlı

arama) ayırt etmeyen genel bir sorgu seti üzerinden hesaplandığını belirtmek önemlidir. Dolayısıyla, algoritmanın başarısı özellikle keşif potansiyelini artırmada belirgin olsa da farklı kullanıcı hedeflerine göre performansının değişebileceği göz önünde bulundurulmalıdır. UMBRELA gibi insandan bağımsız algoritmik puanlama sistemlerinin doğasında bulunan potansiyel sınırlılıklara rağmen, önerilen algoritma ile sıralamada tüm metriklerde gözlemlenen tutarlı iyileştirmeler olmuştur.

Tablo 1. Standart sıralama ve önerilen sıralama performansının metriklere göre karşılaştırması (k=20)

Metrik	Standart Sıralama	Önerilen Sıralama	Fark	Odak Noktası
Precision@20	0,65	0,75	+%15	Sistem tarafından erişilen belgelerin ne kadarının gerçekten ilgili olduğu (Duyarlık)
Recall@20	0,85	0,93	+%9	Tüm ilgili belgelerden ne kadarının sistem tarafından bulunabildiği (Anma)
nDCG@20	0,88	0,95	+%8	Sıralama kalitesi ve ilgi derecesi
ILS@20	0,12	0,05	-%58	Sıralama içi çeşitlilik
α -nDCG@20	0,88	0,95	+%8	İlgi ve çeşitlilik dengesi ($\alpha=0.5$)

Bu bulgular ışığında, önerilen sıralama algoritmasının OPAC bağlamında iki önemli katkı sunduğu söylenebilir. Birincisi, hem ilgili içerikleri daha yüksek bir oranda yakalama (anma artışı) hem de bu içerikleri kullanıcı etkileşimini maksimize edecek şekilde listenin üst sıralarına yerleştirme (nDCG artışı) yeteneği. İkincisi ise, ILS@20 metriğindeki belirgin düşüşe bakarak liste içi benzerliği anlamlı derecede azaltıp kullanıcıların daha geniş bir konu ve tür yelpazesinde kitap keşfetmelerine olanak tanınması. Özellikle büyük ölçekli derlemlerde bu tür çok

boyutlu bir optimizasyon yaklaşımının, uzun vadeli kullanıcı bağlılığı ve memnuniyetini artırmada kritik bir rol oynayacağı öngörülebilir. Çalışmanın gelecek adımları olarak, UMBRELA puanları ile gerçek insan değerlendirmeleri arasındaki uyumun daha kapsamlı bir şekilde analiz edilmesi ve farklı α parametre değerlerinin α -nDCG performansı üzerindeki etkilerinin incelenmesi değerli olacaktır.

4. Tartışma

Bu çalışmada, OPAC'ların geleneksel ilgi sıralaması paradigmasının ötesine geçerek, kullanıcılar için bir keşif platformuna dönüştürülmesi potansiyeli incelenmiştir. Mevcut OPAC algoritmaları, genellikle anahtar kelime eşleşmesi gibi kesin ilgi metriklerine odaklanarak, kullanıcıları dar ve öngörülebilir bilgi koridorlarına hapsedme riski taşımaktadır. Bu çalışma, kullanıcı etkileşim verilerini ve anlamsal modellemeyi entegre ederek, arama sonuçlarında hem ilgiyi koruyan hem de disiplinlerarası çeşitliliği teşvik eden bir denge kurmanın mümkün olduğunu ortaya koymuştur. Bu yaklaşım, web ortamında filtre baloncukları yaratan yapıların, OPAC gibi yapılandırılmış bir akademik ortamda entelektüel keşfi zenginleştiren bir araca dönüştürülebileceği hipotezini doğrulamaktadır.

Elde edilen bulgular, önerilen modelin temel hedeflerine ulaştığını ve literatürdeki temel problemlere yenilikçi çözümler sunduğunu göstermektedir. Model, arama sonuç listesindeki anlamsal çeşitliliği (ILS@20) istatistiksel olarak anlamlı düzeyde artırırken, sıralama kalitesini (nDCG@20, Precision@20) yalnızca korumakla kalmamış, aynı zamanda iyileştirmiştir. Bu durum, ilgi ve çeşitlilik arasında bir ödünleşme olmak zorunda olmadığını, aksine bu iki hedefin eş zamanlı olarak optimize edilebileceğini kanıtlamaktadır (AS 1, AS 2). Özellikle *sosyal ağların gücü* sorgusunda, modelin sonuçları üç farklı tematik küme

(sosyal ağ analizi, karmaşıklık teorisi ve ağ bilimi) etrafında gruplandırması, standart sıralamanın tek boyutlu yaklaşımına kıyasla ne denli zengin bir keşif alanı açtığını göstermektedir (AS 3). LOF algoritması ile tespit edilen niş kaynakların ön plana çıkarılması, Poetz ve Prügl'ün (2010) belirttiği gibi, *analog alanlardaki* uzmanlığa erişimin yenilikçi fikir üretimini tetiklediği savıyla da örtüşmektedir.

Modelin başarısı, bilgi erişim sistemlerinin doğasındaki zorluklara getirdiği yaklaşımla ilişkilidir. Geleneksel sistemlerin *nesnel ilgililik* ölçütlerine dayalı terim eşleşmesinin ötesine geçen bu model, kullanıcıların kolektif davranışlarından elde edilen örtük sinyalleri entegre ederek *öznel ilgililik* kavramına daha dinamik bir yanıt vermektedir. Bu, Zadeh'in (2006) vurguladığı, arama motorlarının yalnızca kelime eşleştirmek yerine anlam ve bağlamdan çıkarım yapma yeteneğine sahip olması gerektiği yönündeki görüşünü destekler niteliktedir. Benzer şekilde, atıf analizinin disiplinlerarası bağlantıları ortaya çıkarmadaki sınırlılıklar göz önüne alındığında, önerilen bu modelin OPA-C'lardaki gizli tematik bağlantıları ve niş kaynakları yüzeye çıkararak geleneksel yöntemlerin eksikliklerini gidermeye yönelik tamamlayıcı bir rol üstlendiği söylenebilir.

Bu çalışmanın metodolojik çerçevesi ve sınırlılıkları, bulguların yorumlanmasında kritik bir rol oynamaktadır. Modelin performans değerlendirmesi için GPT-4 tabanlı UMBRELA aracının kullanılması, büyük dil modellerinin ilgi yargılamasındaki potansiyelini göstermekle birlikte, bu sistemlerin doğasında var olan *halüsinasyon* riski ve *kara kutu* yapısı gibi kısıtlamaları da beraberinde getirmektedir (Bubeck ve diğerleri, 2023; Zhang, 2023). Bu nedenle, bulguların insan yargısıyla yapılacak daha geniş ölçekli testlerle doğrulanması önem arz etmektedir. Çalışmanın en temel sınırlılığı ise, bir kavram kanıtı (proof-of-concept) olarak Amazon kitap veri seti üzerinde çalıştırılmış olmasıdır. Ticari bir platformdaki kullanıcı

motivasyonları ile akademik bir OPAC ortamındaki araştırma odaklı motivasyonlar arasındaki farklılıklar, bulguların doğrudan genellenebilirliğini kısıtlamaktadır. Dolayısıyla, modelin sunduğu potansiyel, gerçek bir akademik bağlamda doğrulanmaya muhtaçtır.

5. Sonuç ve Öneriler

Bu çalışma, Çevrimiçi Kütüphane Kataloglarında (OPAC) yapay öğrenme teknikleri ve kullanıcı etkileşim verilerini bütünleştiren yenilikçi bir sıralama modeli sunarak, ilgi ve çeşitlilik arasında etkin bir denge kurulabileceğini göstermiştir. Geliştirilen model, standart sıralama yaklaşımlarına kıyasla, arama sonuçlarının sıralama kalitesinden ve ilgisinden ödün vermeden liste içi çeşitliliği anlamlı düzeyde artırmıştır. Bu bulgu, OPAC'ların yalnızca bilinen bir kaynağı bulma işlevi gören statik araçlar olmaktan çıkıp, kullanıcıları beklenmedik ve disiplinlerarası keşiflere yönlendiren dinamik platformlara dönüşme potansiyelini ortaya koymaktadır.

Elde edilen sonuçlar ve çalışmanın sınırlılıkları ışığında, gelecekteki araştırmalar için somut adımlar önerilmektedir. Öncelikle modelin kavramsal başarısının pratik geçerliliğe kavuşturulması kritik önem taşımaktadır. Bu doğrultuda, modelin gerçek bir OPAC sistemi üzerinde, lisans öğrencileri ve akademisyenler gibi farklı kullanıcı gruplarıyla test edildiği kapsamlı kullanılabilirlik çalışmaları yürütülmelidir. Böyle bir uyarlama sürecinde model, Amazon'a özgü ticari metrikler yerine, *atıf sayıları* veya *indirilme istatistikleri* gibi akademik ilgi göstergeleriyle yeniden eğitilebilir. Bu adaptasyon, modelin OPAC kullanıcılarının bilgi arama davranışlarıyla bağlamsal olarak uyumlu hale gelmesini sağlayacaktır.

Metodolojik ve teknik geliştirmeler, modelin gelecekteki başarısı için bir diğer önemli araştırma yönünü oluşturmaktadır.

Modelin performansını daha da ileriye taşımak amacıyla, farklı konu modelleme (örneğin, BERTopic), kümeleme ve çeşitlendirme algoritmalarının entegrasyonu araştırılmalıdır. Ayrıca, modelin değerlendirmesinde kullanılan UMBRELA gibi otomatik yöntemlerin güvenilirliği, geniş ölçekli insan yargılarıyla karşılaştırılarak analiz edilebilir. Kullanıcı deneyimini zenginleştirmek adına, model tarafından üretilen tematik kümelerin ve niş kaynakların OPAC arayüzlerinde etkileşimli görselleştirmelerle sunulması, kullanıcıların keşif sürecine aktif katılımını teşvik edebilir.

Sonuç olarak bu çalışma OPAC’larda yapay öğrenme teknikleri ve kullanıcı verilerinden yararlanarak bilgi keşfini zenginleştirme ve kullanıcı deneyimini dönüştürme yönünde önemli bir potansiyel olduğunu göstermektedir. Önerilen model, geleneksel sıralama yöntemlerine değerli bir alternatif sunarak, kütüphane kataloglarının yalnızca bilinen kaynakları bulma işlevinin ötesine geçip, aynı zamanda beklenmedik keşifler ve disiplinlerarası bağlantılar için dinamik ve teşvik edici platformlar haline gelmesine katkıda bulunma potansiyeline sahiptir.

Kaynakça

- Adamic, L. A. ve Huberman, B. A. (2000). Power-law distribution of the world wide web. *Science*, 287(5461), 2115-2115. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=2046e01961a1e799c3def-751010f70f9117bdc1b>
- Akbulut, M. (2016). *Atıf klasiklerinin etkisinin ve ilgililik sıralamalarının pennant diyagramları ile analizi* [Yayımlanmamış yüksek lisans tezi]. Hacettepe Üniversitesi. http://www.mugeakbulut.com/yayinlar/Muge_Akbulut_YL_Tez.pdf
- Akbulut, M. ve Tonta, Y. (2022). İlgi sıralamalarının artırımı olarak geliştirilmesi: Pennant erişimle desteklenen yeni bir yöntem önerisi. *Türk Kütüphaneciliği*, 36(2), 169-203. <https://doi.org/10.24146/tk.1062751>
- Alpert, J. ve Hajaj, N. (2008, 25 Temmuz). We knew the web was big. *The Official Google Blog*. <http://googleblog.blogspot.com/2008/07/we-knew-web-was-big.html>
- Anderson, C. (2006). *The long tail: Why the future of business is selling less for less*. Hyperion.
- Arun, R., Suresh, V., Madhavan, C. V. ve Murthy, M. N. (2010). On finding the natural number of topics with latent dirichlet allocation: Some observations. *Pacific-Asia Conference on Knowledge Discovery and Data Mining* içinde (s. 391-402). Springer. https://doi.org/10.1007/978-3-642-13657-3_43
- Breunig, M. M., Kriegel, H. P., Ng, R. T. ve Sander, J. (2000). LOF: Identifying density-based local outliers. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data* içinde (s. 93-104). ACM. <https://dl.acm.org/doi/pdf/10.1145/342009.335388>
- Bubeck, S., Chandrasekaran, V., Eldan, R., Gehrke, J., Horvitz, E., Kamar, E., Lee, Y. T., Lee, Y., Li, Y., Mirhoseini, A., Narayanan, A., Paraschos, A., Prabhudesai, N., Raffel, C., Rao, R., Ratner, O., Santhanam, A., Shyam, S., Sontag, D.,... Zhang, Y. (2023). *Sparks of Artificial General Intelligence: Early experiments with GPT-4*. arXiv. <https://arxiv.org/abs/2303.12712>
- Buckley, T. (2015). Why do some people believe in conspiracy theories? *Scientific American Mind*, 26(4), 72-72. <https://www.scientificamerican.com/article/why-do-some-people-believe-in-conspiracy-theories/>
- Cao, J., Xia, T., Li, J., Zhang, Y. ve Tang, S. (2009). A density-based method for adaptive LDA model selection. *Neurocomputing*, 72(7-9), 1775-1781. <https://doi.org/10.1016/j.neucom.2008.06.011>

- DataReportal. (2025). *Digital 2025: Global overview report*. <https://datareportal.com/reports/digital-2025-global-overview-report>
- Deveaud, R., SanJuan, E. ve Bellot, P. (2014). Accurate and effective latent concept modeling for ad hoc information retrieval. *Document Numérique*, 17(1), 61–84. <https://doi.org/10.3166/dn.17.1.61-84>
- Dietvorst, B. J., Simmons, J. P. ve Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114–126. <https://papers.ssrn.com/sol3/Delivery.cfm?abstractid=2466040>
- Doğan, M. (2006). *Teknoloji kimin umurunda*. Alfa Yayınları. <https://tinyurl.com/akdaja82>
- Ester, M., Kriegel, H. P., Sander, J. ve Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD'96)* içinde (s. 226–231). AAAI Press. <https://dl.acm.org/doi/10.5555/3001460.3001507>
- Foote, J. (2005). Kooks, obsessives, Sturgeon's law, and the real meaning of search. *IEEE Multimedia*, 12(3), 4–7. <https://ieeexplore.ieee.org/document/1490490>
- Friedman, T. L. (2006). *Dünya düzdür: 21. yüzyılın kısa tarihi* (L. Cinemre, Çev.). Boyner Yayınları.
- Gao, X., Huang, W., Wang, N., Yang, Y. ve Yan, Y. (2016). A Top-N Algorithm-based Personalized Learning Recommendation System for Digital Library. *International Journal of Emerging Technologies in Learning*, 11(11), 55. <https://doi.org/10.3991/ijet.v11i11.6256>
- Griffiths, T. L. ve Steyvers, M. (2004). Finding scientific topics. *Proceedings of the National Academy of Sciences*, 101(1), 5228–5235. <https://doi.org/10.1073/pnas.0307752101>
- Henning, V. ve Gunn, W. (2012, 6 Eylül). Impact factor: Researchers should define the metrics that matter to them. *The Guardian*. <http://www.guardian.co.uk/higher-education-network/blog/2012/sep/06/mendeley-altmetrics-open-access-publishing>
- Horling, B. ve Kulick, M. (2009, 4 Aralık). Personalized search for everyone. *The Official Google Blog*. <http://googleblog.blogspot.com/2009/12/personalized-search-for-everyone.html>

- Hu, J., Zeng, H. J., Li, H., Niu, C. ve Chen, Z. (2007). Demographic prediction based on user's Browse behavior. *Proceedings of the 16th International Conference on World Wide Web (WWW '07)* içinde (s. 151–160). ACM. <https://www.ambuehler.ethz.ch/CDstore/www2007/www2007.org/papers/paper686.pdf>
- Infodocket. (2025, 24 Mart). Journal article: Search engine results and confirmation bias. *Infodocket*. <https://www.infodocket.com/2025/03/24/journal-article-search-engine-results-and-confirmation-bias/>
- Internet Society. (2020). *Impact Report 2020: The internet is a lifeline*. <https://www.internetsociety.org/impact-report/2020/>
- Kumar, N. (2024). Confirmation Bias” and its Significance. *International Journal of Research Publication and Reviews*, 5(7), 2088–2092. <https://ijrpr.com/uploads/V5ISSUE7/IJRPR31483.pdf>
- Leelanupab, T., Zuccon, G. ve M. Jose, J. (2012). A comprehensive analysis of parameter settings for novelty-biased cumulative gain. *Proceedings of the 21st ACM international conference on Information and knowledge management* içinde (ss. 1950–1954). ACM. <https://dl.acm.org/doi/10.1145/2396761.2398550>
- Lorigo, L., Haridasan, M., Brynjarsdóttir, H., Xia, L., Joachims, T., Gay, G. ve Pan, B. (2008). Eye tracking and online search: Lessons learned and challenges ahead. *Journal of the American Society for Information Science and Technology*, 59(7), 1041–1052. <https://doi.org/10.1002/asi.20794>
- McAuley, J. ve Leskovec, J. (2013). Hidden factors and hidden topics: Understanding rating dimensions with review text. *Proceedings of the Seventh ACM Conference on Recommender Systems (RecSys '13)* içinde (s. 179–186). ACM. <https://doi.org/10.1145/2507157.2507163>
- MIT Media Lab. (2017). *FlipFeed: Step into someone else's Twitter feed*. <https://flipfeed.media.mit.edu>
- O'Reilly, T. (2005, 30 Eylül). *What is Web 2.0: Design patterns and business models for the next generation of software*. O'Reilly Media. <http://www.oreillynet.com/pub/a/oreilly/tim/news/2005/09/30/what-is-web-20.html>
- O'Reilly, T. (2007). *What is Web 2.0: Ideas, technologies and implications for education*. O'Reilly Media. <https://21stcenturywalton.pbworks.com/f/What+is+Web+2.0.pdf>

- Pelleg, D. ve Moore, A. W. (2000). X-means: Extending K-means with efficient estimation of the number of clusters. *Proceedings of the Seventeenth International Conference on Machine Learning (ICML '00)* içinde (s. 727-734). Morgan Kaufmann. https://www.researchgate.net/publication/2532744_X-means_Extending_K-means_with_Efficient_Estimation_of_the_Number_of_Clusters
- Poetz, M. K. ve Prügl, R. (2010). Crossing domain-specific boundaries in search of innovation: Exploring the potential of pyramiding. *Journal of Product Innovation Management*, 27(6), 897-914. <https://doi.org/10.1111/j.1540-5885.2010.00759.x>
- Pradeep, R., Thakur, N., Sharifymoghaddam, S., Zhang, E., Nguyen, R., Campos, D., Craswell, N. ve Lin, J. (2024). *Ragnarök: A reusable RAG framework and baselines for TREC 2024 retrieval-augmented generation track*. arXiv. <https://arxiv.org/abs/2406.16828>
- Rowe, A. (2024). *The impact of Artificial Intelligence algorithm bias on political polarization in the state of Georgia* [Yayımlanmamış doktora tezi] Middle Georgia State University. <https://www.proquest.com/dissertations-theses/impact-artificial-intelligence-algorithm-bias-on/doc-view/3102991317/se-2?accountid=142289>
- Seker, S. E. (2015). *Weka ile veri madenciliği*. Bilgisayar Kavramları Yayınları.
- Sergeeva, O. V., Zheltukhina, M. R., Ishmuradova, I. I., Kondakhian, N. A., Erokhova, N. S. ve Zhdanov, S. P. (2025). A meta-analysis of the effectiveness of mobile supported collaborative learning. *Online Journal of Communication and Media Technologies*, 15(1), e202508. <https://www.ojcmt.net/article/a-meta-analysis-of-the-effectiveness-of-mobile-supported-collaborative-learning-15948>
- Shen, T., Li, J., Bouadjene, M. R., Mai, Z. ve Sanner, S. (2022). Towards understanding and mitigating unintended biases in language model-driven conversational recommendation. *Information Processing & Management*, 60(1), 103139. <https://doi.org/10.1016/j.ipm.2022.103139>
- Shirky, C. (2002). *Weblogs and the mass amateurization of publishing*. http://www.shirky.com/writings/herecomeseverybody/weblogs_publishing.html
- Shirky, C. (2008). *Here comes everybody: The power of organizing without organizations*. Penguin Group USA.
- Tang, L. ve Liu, H. (2010). Community detection and mining in social media. *Synthesis Lectures on Data Mining and Knowledge Discovery*, 2(1), 1-137. <https://link.springer.com/book/10.1007/978-3-031-01900-5>

- TED. (2011). *Eli Pariser: Beware online “filter bubbles”* [Video]. https://www.ted.com/talks/eli_pariser_beware_online_filter_bubbles
- TED. (2017). *Zeynep Tüfekçi: İnsanların reklamlara tıklaması için bir distopya yaratıyoruz* [Video]. https://www.ted.com/talks/zeynep_tufekci_we_re_building_a_dystopia_just_to_make_people_click_on_ads?language=tr
- TEDEducation. (2012, 16 Kasım). *Clay Shirky: How social media can make history* [Video]. YouTube. <http://www.youtube.com/watch?v=PzP-0tk6s6w>
- Terragni, S., Harrando, I., Lisena, P., Troncy, R. ve Fersini, E. (2022). One Configuration to Rule Them All? Towards Hyperparameter Transfer in Topic Models using Multi-Objective Bayesian Optimization. arXiv. <https://doi.org/10.48550/arxiv.2202.07631>
- Tonta, Y. (2012). Bilgi sınıflama, bilgi düzenleme ve bilgi erişim. Ö. Külcü, T. Çakmak ve N. Özel (Yay. haz.), *Prof. Dr. K. Gülbün Baydur’a armağan* içinde (s. 155-172). Hacettepe Üniversitesi Bilgi ve Belge Yönetimi Bölümü. <http://yunus.hacettepe.edu.tr/~tonta/yayinlar/tonta-bilgi-siniflama-duzenleme-erisim.pdf>
- Upadhyay, S., Pradeep, R., Thakur, N., Campos, D., Craswell, N., Soboroff, I., ... ve Lin, J. (2024a). *A large-scale study of relevance assessments with large language models: An initial look*. arXiv. <https://arxiv.org/abs/2411.08275>
- Upadhyay, S., Pradeep, R., Thakur, N., Craswell, N. ve Lin, J. (2024b). *UMB-RELA: UMBrela is the (Open-Source Reproduction of the) Bing RElevance Assessor*. arXiv. <https://arxiv.org/abs/2406.06519>
- Weblogs and power laws. (2003, 9 Şubat). *Kottke.org*. <http://kottke.org/03/02/weblogs-and-power-laws>
- Zadeh, L. A. (2006). From search engines to question answering systems—The problems of world knowledge, relevance, deduction and precisiation. B. Goertzel ve C. Pennachin (Yay. haz.), *Capturing intelligence: The epistemology of artificial intelligence* (Vol. 1, s. 163-210) içinde. Elsevier. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=fe0b7c7e23162ca773cc0806de4b1ad538c42754>
- Zhang, Y., Li, Y., Cui, L., Cai, D., Liu, L., Fu, T., Wang, Z., Chen, J. ve Wei, F. (2023). *Siren’s song in the AI ocean: A survey on hallucination in large language models*. arXiv. <https://arxiv.org/abs/2309.01219>
- Ziegler, C. N., McNee, S. M., Konstan, J. A. ve Lausen, G. (2005, Mayıs). *Improving recommendation lists through topic diversification*. Proceedings of the 14th International Conference on World Wide Web (WWW ‘05) (s. 22-32). ACM. <https://doi.org/10.1145/1060745.1060754>