



Tavsiye Sistemleri Literatürünün Bibliyometrik Analizi

Bibliometric Analysis of Recommender Systems Literature

Can İlhan^{1*} 
Emrah Önder¹ 

¹ İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Sayısal Yöntemler, İstanbul, Türkiye, canilkhan@gmail.com, emrah@istanbul.edu.tr

*Sorumlu Yazar/Corresponding Author



Geliş Tarihi/Received: 01.05.2024
Kabul Tarihi/Accepted: 11.11.2024
Yayımlanma Tarihi/ Available Online: 23.12.2024

Öz: Bu çalışma, tavsiye sistemleri literatürünün son beş yılda gerçekleştirilen bibliyometrik analizini içermektedir. Web of Science (WoS) veri tabanından elde edilen veriler kullanılarak, bu alanın gelişimi ve dönemeç noktaları detaylı bir şekilde incelenmiştir. Tavsiye sistemleri, kullanıcı verilerini kullanarak kişiselleştirilmiş içerik ve ürün önerileri sunan teknolojilerdir ve bu sistemler, internetin ve dijital işlemlerin yaygınlaşmasıyla birlikte önem kazanmıştır. Kullanıcılar tarafından verilen doğrudan geri bildirimler veya göz izleme teknolojisi gibi yöntemlerle elde edilen zengin veriler, kullanıcı tercihlerinin analiz edilmesi ve ihtiyaçlara uygun önerilerin sunulması için kullanılmaktadır. Araştırma, GroupLens çalışması gibi önemli adımları ele alarak, işbirlikçi filtreleme ve içerik tabanlı filtreleme gibi temel yaklaşımların gelişimine ışık tutmaktadır. Bu sistemler, Google ve Facebook gibi platformlar tarafından kullanıcı etkileşimlerini analiz edip, gelecekteki tercihleri tahmin etmek amacıyla kullanılmaktadır. Bibliyometrik analiz, VOSviewer aracılığıyla yapılan görselleştirmelerle desteklenmiş olup, tavsiye sistemleri literatüründe sıkça karşılaşılan terimlerin ve bu terimler arasındaki ilişkilerin detaylı bir haritasını sunmaktadır. Çalışma, bu alanda araştırma yapacak olanlara rehberlik edecek şekilde tasarlanmıştır ve tavsiye sistemlerinin bilimsel etkisinin arttığını göstermektedir. Bibliyometrik analiz, bilimsel yayınların niceliksel bir değerlendirmesini sağlayarak, bu yayınların bilimsel etki ve kalitesini objektif bir şekilde ölçmüştür. Analiz sonuçları, tavsiye sistemleri alanındaki akademik çalışmaların ve atıfların zaman içindeki artışını göstermektedir ve bu artış, alandaki ilginin ve etkinin giderek arttığını işaret etmektedir. Bu tür bir analiz, gelecekte bu konu üzerine çalışacak araştırmacılara yol gösterici olabilir ve tavsiye sistemlerinin daha da geliştirilmesi için temel oluşturabilir. Sonuç olarak, bu çalışma, tavsiye sistemleri literatürünün kapsamlı bir analizini sunmakta ve araştırma alanındaki bilimsel ilerlemeleri daha derinlemesine inceleme imkanı sağlamaktadır.

Anahtar Kelimeler: Tavsiye Sistemleri, Bibliyometrik Analiz, Atıf Analizi, Vosviewer

Abstract: This study includes a bibliometric analysis of the literature on recommendation systems conducted over the past five years. Utilizing data obtained from the Web of Science (WoS) database, this research meticulously examines this field's development and turning points. Recommendation systems, which offer personalized content and product suggestions using user data, have gained significance with the widespread adoption of the internet and digital transactions. Rich data gathered through direct user feedback or methods such as eye-tracking technology are used to analyze user preferences and provide suitable recommendations. The research addresses significant milestones such as the GroupLens study, shedding light on the development of fundamental approaches like collaborative filtering and content-based filtering. Platforms like Google and Facebook employ these systems to analyze user interactions and predict future preferences. The bibliometric analysis, supported by visualizations created with VOSviewer, presents a detailed map of the frequently encountered terms in the recommendation systems literature and the relationships between these terms. Designed to guide those researching in this area, the study demonstrates the increasing scientific impact of recommendation systems. Bibliometric analysis provides a quantitative assessment of scientific publications, objectively measuring their scientific impact and quality. The analysis results show an increase over time in academic studies and citations within the field of recommendation systems, indicating a growing interest and influence in the area. Such an analysis can serve as a guide for future researchers on this topic and lay the groundwork for further development of recommendation systems. In conclusion, this work offers a comprehensive analysis of the recommendation systems literature, allowing for a deeper examination of scientific advancements in the research field.

Keywords: Recommender Systems, Bibliometric Analysis, Citation Analysis, Vosviewer

Extended Abstract

Introduction

Recommendation systems are technologies that provide personalized content and product suggestions using user data. These systems facilitate decision-making processes by prioritizing options that best suit users' needs and preferences. The development of recommendation systems has accelerated with the widespread use of the internet and digital transactions.

This study includes a bibliometric analysis of the literature on recommendation systems. Using the Web of Science (WoS) database, significant studies and authors in this field over the past five years have been compiled. The research addresses major milestones in the development of recommendation systems from their inception, providing descriptive statistical data about publications, authors, journals, and institutions.

The increasing use of the Web has heightened the significance of recommendation systems that provide content and product suggestions based on user preferences. User feedback data, collected through various methods, is utilized in recommendation systems. Users can provide direct feedback through likes or dislikes, while methods such as eye-tracking technology share preferences implicitly through richer and more detailed data. Recommendation systems analyze this data to offer suggestions that meet user needs.

A literature review is an essential tool for understanding the evolution of recommendation systems and the foundational work in this area. This information can guide the development and implementation of systems.

Literature Research

Recommendation systems play a supportive role in users' decision-making processes, helping them make the best choices with information derived from large datasets. A significant step in the evolution of these systems was the GroupLens study published by Resnick and colleagues in 1994, which aimed to solve the problem of information overload in large communication networks like Usenet through collaborative filtering. Collaborative filtering offers personalized content suggestions based on users' past preferences or the behavior of similar users.

The fundamental algorithms and methodologies of these systems have led the development of subsequent recommendation systems and adopted evaluating user similarities as a basic approach. Moreover, identifying that user participation can enhance recommendation quality has marked a significant advancement in this field.

Different application areas of recommendation systems have been adopted by platforms such as Google and Facebook. These systems are designed to analyze user interactions and predict future preferences. Elaine Rich's 1979 study introduced the idea of using stereotypes to create user models, laying the groundwork for systems that provide content recommendations for individual users. Recommendation systems employ two primary approaches: content-based filtering and collaborative filtering, both of which are widely used in modern information retrieval systems. Additionally, more comprehensive recommendation system models use contextual data such as time, location, or other qualitative attributes. These systems predict future preferences based on users' past interactions and interests. Correlations between interests play a critical role in enhancing the accuracy of recommendation systems.

Methodology

The methodology section discusses how systematic reviews improve the research process through a scientific, repeatable, and transparent approach. The importance of this approach has grown due to

rapid advancements in data production and knowledge extraction, necessitating the adoption of interdisciplinary approaches.

Bibliometric analysis supports the systematic nature of literature reviews by providing an objective and quantitative evaluation of scientific publications. This analysis measures the scientific quality and impact of works while also performing performance analysis using numerical values such as citation counts and publication numbers. Additionally, methods like science mapping are used to examine the structure and evolution of research areas. Detailed reviews using advanced visualization tools and fundamental applications of bibliometric analysis assess developments in knowledge accumulation and facilitate the organization of information in thematic areas.

The data collection process aims to comprehensively review academic studies on recommendation systems. Only the Web of Science was used during the data search process, specifically including the Science Citation Index Expanded and Social Sciences Citation Index. The research expanded with the keywords "recommendation system*" and "recommender system*," excluding other document types and focusing solely on peer-reviewed journal articles.

Evaluation

The study presents a comprehensive assessment of academic publications in the field of recommendation systems. A search conducted using the Web of Science database initially reached 10,209 studies, and a detailed statistical analysis of these studies was performed. Publications from the last five years (2020-2024) were specifically examined, evaluated separately through the SCI-EXPANDED and SSCI indices. The collected data show an increase in publication and citation numbers over time, particularly becoming pronounced after 2020. In total, 9,627 articles and 92,428 citations were analyzed, achieving a high H-Index. These findings demonstrate the expanding academic impact of the field of recommendation systems and the frequent referencing of research.

VOSviewer is software used for the visualization and analysis of large data sets in scientific literature. This tool is specifically designed to examine networks of co-authorship, citations, and keywords. Its capability to present complex data sets as understandable and interactive network maps aids in visualizing the flow of information and interactions in science and technology fields, helping to discover interdisciplinary connections and new research areas. An analysis conducted using VOSviewer visualized the frequently encountered terms in the field of recommendation systems over the last five years and the relationships between these terms as a network map. This visualization clearly displays the frequency of terms and their connections, making the main topics and trends in the research area comprehensible.

Conclusion

This study examines over 10,000 works on recommendation systems through bibliometric analysis methods, covering literature from 1980 to the present. A rigorous filtering process using references from the WoS database resulted in a detailed analysis of 5,452 articles from the last five years. Important authors, articles, institutions, and countries were examined, and the results were formatted for network analysis. The visualization of the articles highlighted current trends and significant topics for future research. This study serves as a comprehensive guide for researchers exploring the field, though the analysis could be expanded to include other databases and detailed using more specialized network analysis software like Gephi. This expanded approach could create a more comprehensive citation network, allowing for deeper examination through network analysis methods.

1. Giriş

Elektronik ve ticari işlemler için bir ortam olarak Web'in kullanımının artması, tavsiye sistemlerinin önem kazanmasında da teşvik edici olmuştur. Web kullanıcılarına beğendikleri ve beğenmedikleri şeyler

hakkında geri bildirim sağlamak konusunda kolaylık sağlar (Aggarwal, 2016) Örneğin, Web üzerinde kullanıcılar beğendikleri şarkı için beğeni simgesi işaretlerken (örneğin artı simgesi) beğenmeme için beğenmemeyi belirten bir simge (örneğin eksi işareti simgesi) benzeri bir geri bildirim metodolojisi kullanabilirler. Bu şekilde toplanan bir veri, öneri algoritmalarının kişiselleştirilmiş müzik önerilerini geliştirmesine yardımcı olabilecek basit bir yöntem olabilir. Diğer geri bildirim biçimleri o kadar kolay izlenilebilir değilse de onların da Web yardımıyla toplanması kolaydır. Örneğin, göz izleme teknolojisi kullanılarak elde edilen veriler, kullanıcıların ilgisini çeken ancak herhangi bir etkileşimde bulunmadıkları öğeleri belirlemede bir onay mekanizması işlevi görebilir. Bu tür bir teknoloji sadece tıklama verilerine dayanarak yapılan tahminlerden daha zengin ve detaylı bir geri bildirim kaynağı sunmaktadır (De Leon-Martinez vd., 2023) .

Tavsiye sistemleri, kullanıcıların girdi olarak sunduğu tavsiyeleri toplayıp ihtiyaç duyan kişilere yönlendiren bir araçtır. Başarılı bir tavsiye sistemi, değerlendirmeleri toplar ve iyi eşleşmeler yaparak ihtiyaç duyulan seçimi yapmak da kullanıcıya yardımcı olur (Resnick & Varian, 1997).

Tavsiye sistemleri, her kullanıcının bir öğeye veya ürüne bir tercih değeri verdiği kullanıcılar ve öğeler olmak üzere iki varlıkla ilgilenir (Roy & Dutta, 2022) . Tavsiyenin sağlandığı varlık kullanıcı ve tavsiye edilen ürün de bir öğe olarak tanımlanır. Bu nedenle, tavsiye analizi kullanıcılar ve öğeler arasındaki önceki etkileşime dayanır, çünkü geçmiş ilgi alanları ve eğilimler genellikle gelecekteki seçimlerin iyi göstergeleridir (Aggarwal, 2016). Ayrıca kullanıcıların ilgi duyduğu öğeler arasında da korelasyon olabilir: Spora ilgi duyan bir kullanıcı spor ile ilgili podcast ya da canlı yayınlanan maçları izlemeyi de tercih edebilir. Bu nedenle öğe grupları arasındaki korelasyonları da göz önünde bulundurmak tavsiye sisteminin doğruluğunu artıracaktır.

Bu tahminleri yapmak için detaylı inceleme yapmak gereklidir. Tavsiye sistemlerinin pek çok farklı türü bulunmaktadır. İşbirlikçi filtreleme, içerik tabanlı sistemler gibi temel örneklerin yanı sıra zamansal bilgi, dış bilgi, konum bilgisi, sosyal bilgi veya ağ bilgisi gibi bağlamsal veriler kapsamlı analiz yapan modellerde kullanılabilir (Fayyaz vd., 2020).

Detaylı bir literatür araştırmasının başlıca iki faydası bulunmaktadır: Birincisi kaynaklara bakarak tavsiye sistemlerinin kökenlerini ve alandaki önemli adımları anlaşılır bir şekilde tanımayı mümkün kılar. İkincisi ise bu alanda yayın yapan yazarları, alandaki önemli eserleri ve bu eserlerin yayınlanacağı mecraları analiz etmeyi sağlar. Bunun sonucunda tavsiye sistemlerinin gelişimi ve bu gelişimin yönü hakkında ipuçları elde etmek ya da öngörülerde bulunmak kolaylaşacaktır.

2. Literatür Araştırması

Tavsiye sistemleri karar verme problemini çözmek için hazır bulunan verilerle seçenekleri önceliklendirmeye ve olası seçeneklerin sayısını daraltarak en uygun seçimi yapmaya yardımcı olan bir uygulamalar bütünüdür.

Tavsiye sistemlerinin gelişiminde en önemli dönüm noktası Resnick, Iacovou ve arkadaşları tarafından 1994 yılında yayınlanan, kullanıcılarının birbirleriyle etkileşimini kullanarak kişiselleştirilmiş içerik önerileri sağlayan GroupLens, isimli çalışmalarıdır (Resnick vd., 1994) Çalışmanın temel çıkış noktası, 1970'lerin ikinci yarısında Duke Üniversitesi tarafından oluşturulan Usenet iletişim sistemi olmuştur. Usenet, coğrafi sınırları aşarak benzer ilgi alanlarına sahip insanları bir araya getiren ve bilgi paylaşımı, tartışma ve fikir alışverişi için geniş bir platform sunan bir dağıtık ağ sistemidir. Ancak zamanla, büyük miktarda içeriğin üretilmesi ve yayılması, bilgi aşırı yüklenmesi ve düşük sinyal-gürültü oranı gibi sorunlara yol açmıştır. Bu sorunları çözmek amacıyla GroupLens, Usenet'in var olan altyapısını ve geniş kullanıcı tabanını kullanarak, işbirlikçi filtreleme yaklaşımını benimsemiş ve böylece kullanıcıların ilgilerine en uygun içerikleri daha kolay bir şekilde bulmalarını sağlayan yenilikçi bir sistem geliştirmiştir (Resnick vd., 1994).

Günümüzde tavsiye sistemlerinde en fazla kullanılan yöntemlerden olan işbirlikçi filtreleme (collaborative filtering) kavramını ilk olarak tanımlayan ve uygulayan çalışma da bu önemli makalede yer almaktadır. İşbirlikçi filtreleme, kullanıcıların geçmişteki tercihlerine bakarak veya benzer kullanıcıların tercihlerine dayanarak kullanıcılar için özelleştirilmiş içerik önerileri sağlamaktadır. Modern sosyal medya, e-ticaret ve internet uygulamalarında yaygın olarak kullanılan ve bilgi aşırı yüklenmesi problemini çözmek için bir yöntem sunan bu temel kavramın ilk çıkış noktası yukarıda bahsedilen çalışmadır.

Sözü edilen makalede tanıtılan algoritmalar ve metodolojiler, daha sonraki birçok tavsiye sisteminin de temelini oluşturmuştur. Kullanıcıların birbirleriyle olan benzerliklerinin değerlendirilmesi ve bu benzerliklerin tahminler yapmak için kullanılması, modern tavsiye sistemlerinin çekirdeğini oluşturan bir prensiptir. Bu çalışma ayrıca, tavsiye sistemlerinin yalnızca e-ticaret veya belirli ürün önerileriyle sınırlı olmadığını bilgiye dayalı her ortamda, kullanıcıların ilgisini çekebilecek içerikleri bulmalarına yardımcı olabileceklerini göstermesi açısından da önemlidir.

Ayrıca, kullanıcıların sistem üzerinde aktif rol oynamasının, öneri kalitesini artırabileceğini göstererek, kullanıcılar tarafından yapılan değerlendirmelerin, sistemin daha doğru işlemlerini sağlayacağını göstermiştir. Bu nedenlerle, GroupLens makalesi ve tanıttığı sistem, tavsiye sistemlerinin gelişiminde kritik bir dönüm noktasıdır ve bu alandaki araştırmaların ve uygulamaların ilerlemesinde temel bir kaynak olarak kabul edilir.

Bir tavsiye sistemi, kullanıcılara anlamlı öneriler vermek için tasarlanır. Bu öneriler sistemin amacına bağlıdır: Google insanlara onlar için önemli haberleri önerirken Facebook insanlara arkadaşları tavsiye eder. Tavsiye Sistemleri, bilgi erişim sistemlerinin bir alt sınıfıdır ve kullanıcıların sistemle geçmiş etkileşimlerini analiz ederek gelecekteki tercihlerini tahmin etmek için tasarlanmıştır (Papneja vd., 2021).

Tavsiye sistemlerinin oluşumuna zemin hazırlayan ve neredeyse 30 yıla yayılan önemli çalışmalar arasında Elaine Rich'in "Cognitive Science" dergisinde 1979 yılında yayımlanan "User Modeling via Stereotypes" başlıklı makalesi yer alır (Rich, 1979). Makale, az miktarda bilgiye dayanarak bireysel kullanıcı modelleri oluşturmak için stereotiplerin faydalı bir mekanizma olduğunu belirtir. Grundy adlı bir sistem tanıtılır; bu sistem, kullanıcılarının modellerini stereotipler yardımıyla oluşturur ve bu modelleri kullanarak insanların ilgisini çekebilecek romanlar önerir. Makale, stereotiplerin doğru kullanılması durumunda, Grundy'nin kullanıcı modellerinin performansını yönlendirmede etkili olduğunu gösteren analizler sunmaktadır (Rich, 1979)

Diğer önemli öncülleri arasında, enformasyon filtreleme ve edinimi (Belkin & Croft, 1992) yakınsama (approximation) ve tercih (preference) teorilerine dayanarak, tercih verileri yardımıyla örnekleri sıralayan bir tercih yaklaşımı geliştirilmesi (Cohen vd., 1999) bulunmaktadır.

Tavsiye sistemlerinde kullanılan iki temel yaklaşım, işbirlikçi filtreleme ve içerik tabanlı filtreleme (content-based filtering) yöntemidir (Felfernig vd., 2014).

İşbirlikçi filtrelemenin ilk örneği Xerox Palo Alto Araştırma Merkezi'nde geliştirilen Tapestry adlı sistemdir. Bu deneysel sistemi, kullanıcılar elektronik belgeleri filtrelemek, dosyalamak ve göz atmak için kullanabilirler (Goldberg vd., 1992).

Öncülleri arasında kütüphane kataloglama sistemleri sayılabilecek içerik tabanlı sistemler ise enformasyon erişimindeki gelişmelere paralel olarak özellikle 20. yüzyılın ikinci yarısından sonra hızla gelişmiştir. Özellikle bilgisayar teknolojilerindeki hızlı ilerleme sonrasında enformasyona erişim şeklinde yıkıcı bir dönüşüm yaşanmıştır (Sanderson & Croft, 2012).

3. Metodoloji

Sistemik inceleme, araştırma sürecini bilimsel, tekrar edilebilir ve şeffaf bir şekilde iyileştiren bir yaklaşıma sahiptir (EBSE Technical Report, 2007).

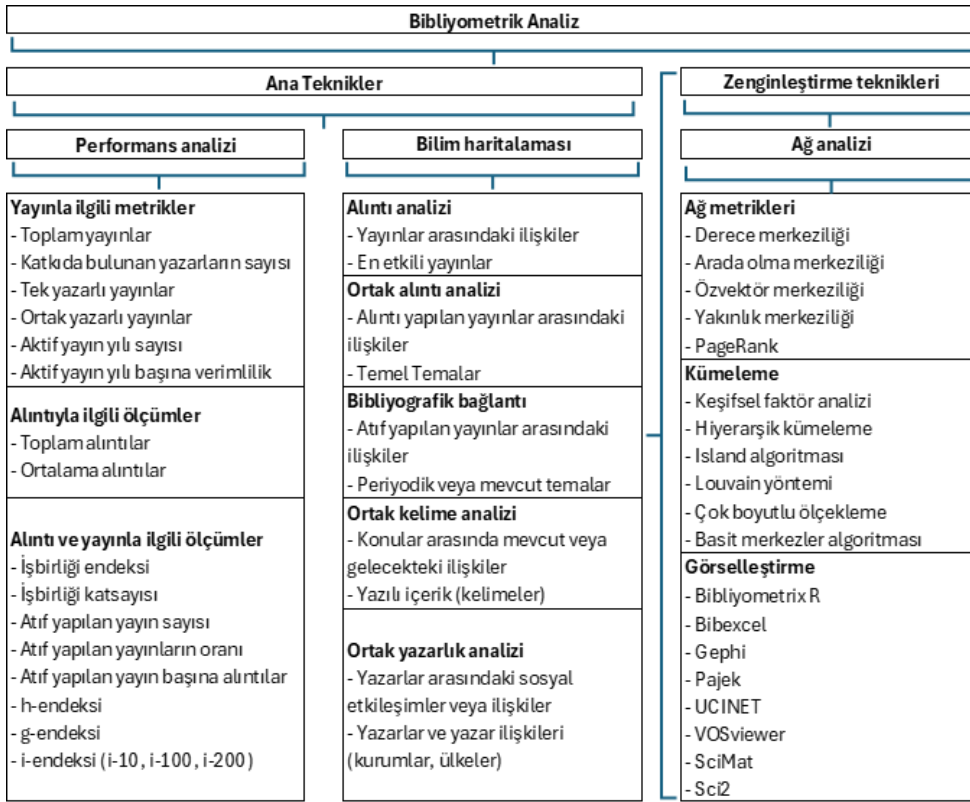
3.1. Bibliyometrik analiz

Son yıllarda tüm disiplin alanlarında çok hızlı veri üretme ve bilgi çıkarımı yeteneği ortaya çıkmıştır. Parça parça hızla ilerleyen bu çalışmalarını takip edebilmek için disiplinler arası yaklaşımlar benimsenmelidir. Bu nedenle, genel bir tanımla önceki araştırmaları toplamanın ve sentezlemenin sistemik bir yolu olan literatür taramasına duyulan ihtiyaç yüksek düzeydedir (Snyder, 2019)

Bibliyometrik analiz, bibliyografik materyali objektif, niceliksel bir perspektiften inceleyen, bir tematik alandaki bilgilerin düzenlenmesi için faydalı olan aynı zamanda belirli bir konudaki bilgi birikimindeki gelişmeleri değerlendiren, eserlerin ve kaynakların bilimsel kalitesini ve etkisini ölçmeyi hedefleyen bir bilimsel yayın analizi biçimidir (Albort-Morant & Ribeiro-Soriano, 2016).

Şekil 1

Bibliyometrik Analiz



Kaynak: (Donthu vd., 2021)

Atıf sayıları, yayın sayıları benzeri sayısal değerlerle ölçülebilecek performans analizi ve araştırma alanının yapısını ve evrimini incelemek üzere kullanılan bilim haritalaması iki temel uygulamasıdır (Ding & Yang, 2022; Donthu vd., 2021). Bibliyometrik analizde hem bu iki temel kategoriden toplanan verilerden yararlanmak, hem de ağ analizi yöntemlerinden yararlanılarak gelişmiş görselleştirme araçlarını kullanarak detaylı inceleme yapmak mümkündür. Şekil 1'de bibliyometrik analizde kullanılan başlıca yöntemler gösterilmektedir.

3.2. Veri ve arama yöntemi

Çalışmanın bu kısmında, tavsiye sistemleri alanındaki akademik çalışmaların kapsamlı bir şekilde incelenmesi hedeflenmektedir. Arama süreci, Web of Science veri tabanının Science Citation Index Expanded (SCI-EXPANDED) ve Social Sciences Citation Index (SSCI) indeksleri üzerinden

yürütülmüştür. Bu indeksler, multidisipliner bir bakış açısıyla, bilim ve sosyal bilimler alanlarında etkili ve yüksek kaliteli yayınları içermektedir. Araştırma konusunun hem teknolojik hem de sosyal bilimler perspektifinden önem arz etmesi nedeniyle, bu iki indeksin seçimi yapılmıştır.

Çalışmada WOS kullanılarak 10.209 çalışma elde edilmiştir. Arama sadece WOS veri tabanı ile sınırlandırılmıştır. Bunun başlıca sebebi hem veri seti büyüklüğünün fazla olması hem de WOS'da tüm verilerin (Full Data seçeneği yardımıyla) kapsamlı bir şekilde VosViewer'a aktarılabilmesidir. Gelecek çalışmalarda, Scopus, GoogleScholar ya da benzer veri tabanları eklenerek, varsa çakışan makaleler elenerek daha büyük bir seti oluşturulabilir.

Araştırmanın kapsamı, "recommendation system*" ve "recommender system*" anahtar kelimeleri aracılığıyla, başlık (TI), özet (AB) ve anahtar kelimeler (AK) alanlarında genişletilmiştir. Bu terimler, alanın terminolojisinde yaygın olarak kullanılan iki farklı ifadeyi temsil etmektedir. Bu çift yönlü arama yaklaşımı, ilgili tüm çalışmaları kapsayıcı bir biçimde ele almayı ve böylece araştırma kapsamını genişletmeyi amaçlamaktadır.

Arama sınırlamaları olarak, yalnızca makale türündeki dokümanlar hedef alınmıştır. Bu sayede, konferans bildirileri, kitap bölümleri gibi, hakem değerlendirme sürecinden geçmiş çalışmalara odaklanılmıştır.

4. Değerlendirme

4.1. Tanımlayıcı istatistik

Yapılan aramada, başlangıçta, Tablo 1'de de görülebileceği gibi toplam 10.209 çalışmaya erişilmiştir. Ancak görselleştirme kısıtlarından dolayı SCI-EXPANDED ve SSCI olarak iki sonuç alınarak ayrı ayrı incelenmiştir. Daha sonra son beş yıl (2020-2024) içerisinde listelenen çalışmalara bakılmıştır.

Tablo 1

Wos Da "Recommendation System" ve "Recommender System*" Arama Kelimeleri ile Yapılan SCI-Expanded ve SSCI Aramaları ve Sonuç Sayıları*


((TI=("recommendation system*")) OR AB=("recommendation system*")) OR AK=("recommendation system*") OR ((TI=("recommender system*")) OR AB=("recommender system*")) OR AK=("recommender system*") and Article (Document Types) and Science Citation Index Expanded (SCI- EXPANDED) or Social Sciences Citation Index (SSCI) (Web of Science Index)	https://www.webofscience.com/wos/woscc/summar y/8d9d0cbd-13be-442f-91b6-c62588f1376a- ccd9e46d/relevance/1	10.209
((TI=("recommendation system*")) OR AB=("recommendation system*")) OR AK=("recommendation system*") OR ((TI=("recommender system*")) OR AB=("recommender system*")) OR AK=("recommender system*") and Article (Document Types) and Science Citation Index Expanded (SCI- EXPANDED) or Social Sciences Citation Index (SSCI) (Web of Science Index) and Science Citation Index Expanded (SCI-EXPANDED) (Web of Science Index)	https://www.webofscience.com/wos/woscc/summar y/d0de7be9-74ce-4a5b-99b7-332bce086b2c- ccda61c6/relevance/1	9.627
((TI=("recommendation system*")) OR AB=("recommendation system*")) OR AK=("recommendation system*") OR ((TI=("recommender system*")) OR AB=("recommender system*")) OR AK=("recommender system*") and Article (Document Types) and Science Citation Index Expanded (SCI- EXPANDED) or Social Sciences Citation Index (SSCI) (Web of Science Index) and Social Sciences Citation Index (SSCI) (Web of Science Index)	https://www.webofscience.com/wos/woscc/summar y/5e369102-73b0-4307-8d7e-731a3ce58ddb- cce1bc80/relevance/1	1.917

Atıf ve yayınları grafik ile göstermek amacı ile arama SCI-EXPANDED olarak daraltılmıştır ve bunun sonucunda 9.627 adet çalışma ortaya çıkmıştır.

Şekil 2'de akademik yayınların ve alıntılarının zaman içindeki dağılımını gösteren bir grafik bulunmaktadır. Yatay eksen yılları, dikey eksen ise yayın sayısını ve mavi çizgi de alıntı sayısını göstermektedir. 1980'lerden 2020'lere doğru ilerlerken, yayın sayısında istikrarlı bir artış olduğunu gözlemleyebiliriz. Bu artış yöneliminin 2020 devamında zirve noktasına ulaşmış olduğu şekilde görülmektedir.

Şekil 2


Tavsiye Sistemleri Hakkında 1980'den Günümüze Yayınlar ve Atıflar (SCI-Expanded)



Alıntı sayılarını temsil eden mavi çizgide de 2020 yılından sonra alıntı sayısında da büyük bir artış olduğu görülmektedir. Bu da yayın sayısında belirgin bir artışın yanında yayınların etkisinin ve öneminin de arttığını göstermektedir. 9.627 yayın ve 92.428 alıntı ile toplam yayın ve alıntı yapan makale sayısının oldukça yüksek olduğunu, zaman içinde büyük bir ivme kazandığını görmek mümkündür. H-İndeksi için 143 değeri, oldukça yüksek bir etki anlamına gelir. (Fraumann & Mutz, 2020) Ayrıca bir araştırmacının veya yayın setinin etkisini ölçen (kendine atıflar hariç) alıntı sayısının 142.164 olması da alıntılarının önemli bir kısmının yazarların kendi çalışmalarına atıfta bulunmadığını göstermektedir. Bu durum araştırma alanının geniş bir etki yarattığına ve diğer araştırmacılar tarafından sıkça referans alındığına işaret etmektedir.

Şekil 3

Tavsiye Sistemleri Hakkında 1980'den Günümüze Yayınlar ve Atıflar (SSCI)



Tablo 1’de görünen Social Sciences Citation Index (SSCI) kısmında sorgulanan toplam 1.917 makale için de benzer değerlendirmeler söz konusudur. Yayınlar: Grafikteki mor sütunlar, yıllara göre yapılan toplam yayın sayısını göstermektedir. Şekil 3’de 1998’den başlayarak bir artış gözleniyor 2020 ve 2021 yıllarında ise en yüksek seviyeye gelmiş oluyor. Alıntı sayısı da 2010 yılından itibaren hızla yükselerek 2020 yılında zirveye ulaşmıştır. 1.917 yayın ve 34.135 alıntı yapan makale sayısı görülmektedir. 49.102 alıntı ve kendi çalışmalarına yapılan atıf hariç 44.887 alıntı oldukça yüksek bir rakamdır. 91 olan H-İndeksi de yüksek bir değerdir.

4.2. Yayın, yazar, dergi ve kurumlar üzerine analiz

Veri setinin hangi kriterlere göre oluşturulacağı daha sonra oluşturulan veri setinin yazarlar arasındaki çalışmaların ortaklığına, dergi tercihlerine ve yayınları destekleyen kurum ve kuruluşlara göre incelenmesi mümkün ve gereklidir. Aşağıdaki bölümlerde veri setinin seçimi ve bazı temel analizler gösterilmiştir.

4.2.1. Yayınların incelenmesi

WoS (Web of Science) içerisinde "Yüksek atıf alan makale" isminde sonuçları filtrelemek için ayrı bir alan bulunmaktadır. Tüm çalışmalar içerisinde 65 adet makale bulunmaktadır. Bu eşik, farklı alanlarda ve yayın yıllarında değişiklik gösterir, her alanın atıf uygulamalarını ve araştırma çıktısı hacmini yansıtır. Essential Science Indicators (ESI), Web of Science Core Collection’da üst düzey performans gösteren araştırmaları belirlemeye yardımcı bir araçtır. ESI, yayın ve atıf performansına dayanarak yazarları, kurumları, ülkeleri ve dergileri 22 alanda sıralar. Alanlar arasında yayınların hacmi ve gelişim hızı değişiklik gösterebilir (Clarivate Inc., 2024)

Yüksek atıf alan makalelerin toplam sayısı 65 tane ve bu makaleler arasından atıf sayısına göre ilk 10 makale Tablo 2’de gösterilmiştir. 1.855 atıf olarak en üst sıralarda yer alan makale 2013 yılında Bobadilla ve arkadaşları tarafından yayınlanmış "Recommender Systems Survey" adlı makaledir. Bu çalışma, öneri sistemlerinin metodolojileri, algoritmaları ve evrimi hakkında genel bakış sunmaktadır. Öneri sistemlerinin sınıflandırılması, uygulama alanları ve gelecekteki potansiyel yönü detaylı bir şekilde ele alınmıştır. Ayrıca, sosyal filtreleme, içerik bazlı filtreleme, kullanıcı gruplarına önerilerde bulunma ve önerilerin açıklanması gibi konuları kapsar. Öneri sistemlerinin gelecekteki ilerleme eğilimleri, biyo-esinlenmiş yaklaşımlar ve konum tabanlı öneri sistemleri gibi yeni uygulamalara da

değınılır. Başlangıçta demografik, içerik tabanlı ve işbirlikçi filtreleme üzerine kurulu öneri sistemlerinin sosyal ağlardan gelen verileri kullanacağı hatta gelecekte nesnelerin İnterneti ile toplanan verilerin yanında örtük, yerel ve kişisel bilgilerin de öneri sistemlerinde kullanılacağını öngörmektedir (Bobadilla vd., 2013).

Tablo 2

ESI ile Hesaplanan "Yüksek Atıf Alan Makale" İlk 10 Makale

Makale Adı	Atıf Sayısı	Yıl
Recommender systems survey	1855	2013
A survey of deep neural network architectures and their applications	1814	2017
Deep Learning Based Recommender System: A Survey and New Perspectives	1626	2019
Edge Intelligence: Paving the Last Mile of Artificial Intelligence With Edge Computing	902	2019
Recommender system application developments: A survey	864	2015
Artificial intelligence for decision making in the era of Big Data - evolution, challenges and research agenda	706	2019
DeepSurv: personalized treatment recommender system using a Cox proportional hazards deep neural network	611	2018
Heterogeneous Information Network Embedding for Recommendation	600	2019
Fast and Accurate Matrix Completion via Truncated Nuclear Norm Regularization	556	2013
Collaborative Filtering beyond the User-Item Matrix: A Survey of the State of the Art and Future Challenges	528	2014

Diğer makalelerde yapay zekâ ve derin öğrenme uygulamaları ön plana çıkmaktadır. Derin öğrenme yöntemlerinin öneri sistemlerinde kullanımı, Amazon ve Netflix gibi büyük organizasyonlar için özellikle önemlidir. Toplanan büyük veri yardımıyla, kullanıcıların tercihlerine ve davranış örüntülerini kullanarak kişiselleştirilmiş öneriler sunar. Makalelerde bahsedilen derin öğrenme yöntemleri, kullanıcıların hangi kitapları okuyacağı, hangi videoları izleyeceği veya hangi mutfak aletlerini satın alacağı gibi yüksek sayıda ancak daha düşük maddi değerde ürünler konusundaki satın alma kararlarında kullanılmaktadır. Bir başka makale ise hastaların bireysel tedavi tavsiyeleri almasını sağlamayı hedeflemektedir. Geleneksel hayatta kalma modelleri, geniş ölçüde özelliğe veya önceden var olan tıbbi bilgiye ihtiyaç duyarken, önerilen yöntem doğrusal olmayan bu yöntem derin sinir ağlarını kullanmaktadır (Duan vd., 2019; Katzman vd., 2016; Liu vd., 2016; Zhang vd., 2017; Zhou vd., 2019). İki makale de matris faktörizasyon yöntemini kullanmaktadır (Hu vd., 2013; Shi vd., 2017)

Tablo 3’de ise ESI ile hesaplanan atıf sayıları yerine süre kısıtı olmadan toplam atıf sayılarına dayanarak yapılan sıralama gösterilmiştir. Tablo 3’te ağırlıklı olarak tavsiye sistemleri hakkında yapılmış olan inceleme makaleleri bulunmaktadır. Atıf sayısı 6.048 ile en başta tavsiye sistemleri araştırmalarında önemli olan matris faktörizasyon ile ilgili önemli bir makale bulunmaktadır (Koren vd., 2009).

Tablo 3

Yüksek Atıf Alan 10 Makale

Makale Adı	Atıf Sayısı	Yıl
Matrix Factorization Techniques for Recommender Systems	6048	2009
Evaluating Collaborative Filtering Recommender Systems	3161	2004
Hybrid Recommender Systems: Survey and Experiments	2013	2002
Recommender Systems	1858	1997
Recommender Systems Survey	1855	2013
A Survey of Deep Neural Network Architectures and their Applications	1814	2017
What Makes a Helpful Online Review? A Study of Customer Reviews on Amazon.Com	1671	2010
Deep Learning Based Recommender System: A Survey and New Perspectives	1626	2019
Item-Based Top-N Recommendation Algorithms	1301	2004
Edge Intelligence: Paving the Last Mile of Artificial Intelligence with Edge Computing	902	2019

Şekil 4’de bulunan görselleştirmeyi oluşturmak için daha önce seçilen 5.452 çalışma verisi VOSViewer’a aktarılmıştır. Özet ve başlıklar incelendiğinde öne çıkan kelime ve kavramlar görülmektedir.

Bu VOSviewer ağ görselleştirmesi, tavsiye sistemleri literatüründe son beş yıl içinde sıkça karşılaşılan terimleri ve bu terimler arasındaki ilişkileri temsil ediyor. Görselleştirme, terimlerin ne kadar sık anıldığını (boyutlarıyla) ve birbiriyle ne kadar sık ilişkili olduğunu (aralarındaki çizgilerle) gösteriyor.


Bu şekilde, "algorithm", "item", "system", ve "service" gibi terimler oldukça büyük ve merkezi pozisyonda yer almakta, bu da onların tavsiye sistemleri literatüründe merkezi konular olduğunu gösteriyor. Bu terimlerin büyük ve koyu renkte oluşu, araştırma alanında önemli ve sık araştırılan konular olduğuna işaret eder. "Algorithm" terimi özellikle dikkat çekici; bu, algoritmaların tavsiye sistemleri araştırmalarında çok önemli bir yere sahip olduğunu ve muhtemelen çeşitli yöntemlerin ve tekniklerin geliştirilmesine odaklanıldığını gösterir.

"Session", "attention mechanism", ve "graph neural network" gibi terimlerin birbiriyle güçlü ilişkiler içinde olması, bu konseptlerin modern tavsiye sistemleri araştırmalarında bir arada ele alındığını ve üzerinde durulduğunu gösterir. Örneğin, "attention mechanism" terimi, veriye dayalı öğrenme modellerinde kullanıcının ilgisine odaklanan algoritmaları ifade edebilir ve bu mekanizmaların "session"-based tavsiye sistemlerinde nasıl kullanıldığı araştırılıyor olabilir.

Burada geçen terimleri yorumlamak için tavsiye sistemlerinin sınıflandırmasını da incelemek gereklidir. İşbirlikçi filtreleme (Resnick vd., 1994; Sarwar vd., 2001), içerik tabanlı filtreleme (Pazzani & Billsus, 1997) ve hibrit filtreleme (Burke, 2002) en bilinen ve en eski tavsiye sistemleri türleridir ancak son beş yılda yapılan çalışmalar arasında daha çok derin öğrenme tabanlı tavsiye sistemlerine ilişkin terimler yer almaktadır. Derin öğrenme konularına artan ilgi her alanda kendini göstermektedir. Bu ilginin kaynağı derin öğrenmenin doğrusal olmayan ilişkileri inceleme yeteneğinden kaynaklanmaktadır. Tavsiye sistemlerinde derin öğrenme uygulamaları özellikle çizgelerde (graflarda), evrişimli ağlarda oturum tabanlı (session-based) uygulamalarda yoğunlaşmaktadır. (Berg vd., 2017; Mu, 2018; Wang vd., 2019; Wu vd., 2019) Bu durum hem Şekil 4 hem de Şekil 6’da zaman çizelgesinin yakın tarihli terimlerinde gözlenmektedir.

Şekil 5

Tavsiye Sistemleri Sınıflandırması (Duraisamy et al., 2023; Jabbar et al., 2018)




Renk skalası, yayınların zaman içindeki dağılımını gösteriyor. Görseldeki en koyu noktalar, gözlem döneminin başlarında (2020-2021), daha açık renkli noktalar ise daha yakın tarihte (2022-2024) odaklanılan konuları temsil ediyor. Bu dağılım, zaman içindeki araştırma odaklarının nasıl değiştiğini gösterir.

VOSviewer görselleştirmesi, tavsiye sistemleri alanındaki terimlerin ve bu terimlerin birbirleriyle olan ilişkilerinin ağ haritasını göstermektedir. Ağ haritasında, terimler noktalar (veya düğümler) olarak temsil edilmekte ve noktalar arasındaki çizgiler (veya kenarlar), terimlerin literatürde birlikte ne sıklıkla anıldığını gösteren bağlantıları temsil etmektedir. Terimlerin boyutu, onların belirli bir veri seti veya literatür havuzunda ne kadar sık geçtiğini yansıtır; büyük noktalar daha sık geçen terimleri, küçük noktalar daha az geçen terimleri ifade eder.

Şekil 6

Anahtar Kelimelerin Görselleştirilmesi (Bağlantılar-Ortalama Normalleştirme)




Şekil 6'de "recommendation system", "recommender systems", ve "recommender system" terimleri büyük ve merkezi konumda yer alarak, tavsiye sistemleri alanında en çok üzerinde durulan konular olduklarını gösterir. "Machine learning", "deep learning", "data models", ve "predictive models" gibi terimlerin de büyük ve ağır çeşitli yerlerinde yer alması, bu kavramların tavsiye sistemleri araştırmalarında önemli olduğunu ve bu terimlerin birbirleriyle güçlü ilişkiler içinde olduğunu gösterir.

"Collaboration", "feature extraction", "big data", "graph neural networks" gibi terimlerin de ağda görünmesi, bu teknolojilerin ve konseptlerin tavsiye sistemlerinin gelişiminde önemli rol oynadığını gösterir. Bu terimlerin birbirine yakın konumlandırılması, araştırma topluluğunun bu konular arasında güçlü bir bağlantı ve etkileşim gördüğünü ifade eder.

Kenarların renkleri ve kalınlıkları, terimler arasındaki ilişkinin gücünü gösterir. Kalın ve koyu renkli çizgiler, terimlerin birlikte sıkça anıldığını ve güçlü bir ilişki olduğunu belirtirken, ince ve soluk çizgiler daha zayıf ilişkileri temsil eder.

Şekil 7

Ülkeler Arasındaki Bilimsel İşbirliği Ağı



Şekil 7'de bulunan VOSviewer görselleştirmesi, çeşitli ülkeler arasındaki bilimsel işbirliklerinin bir ağ şeklinde göstermektedir. Ağdaki her bir düğüm bir ülkeyi temsil eder. Düğümler arasındaki çizgiler bu ülkelerin bilimsel çalışmalarda ne sıklıkla ortak çalışmalar yaptığını göstermektedir. Çizgilerin kalınlığı ve renk yoğunluğu işbirliğinin gücünü yansıtmaktadır.

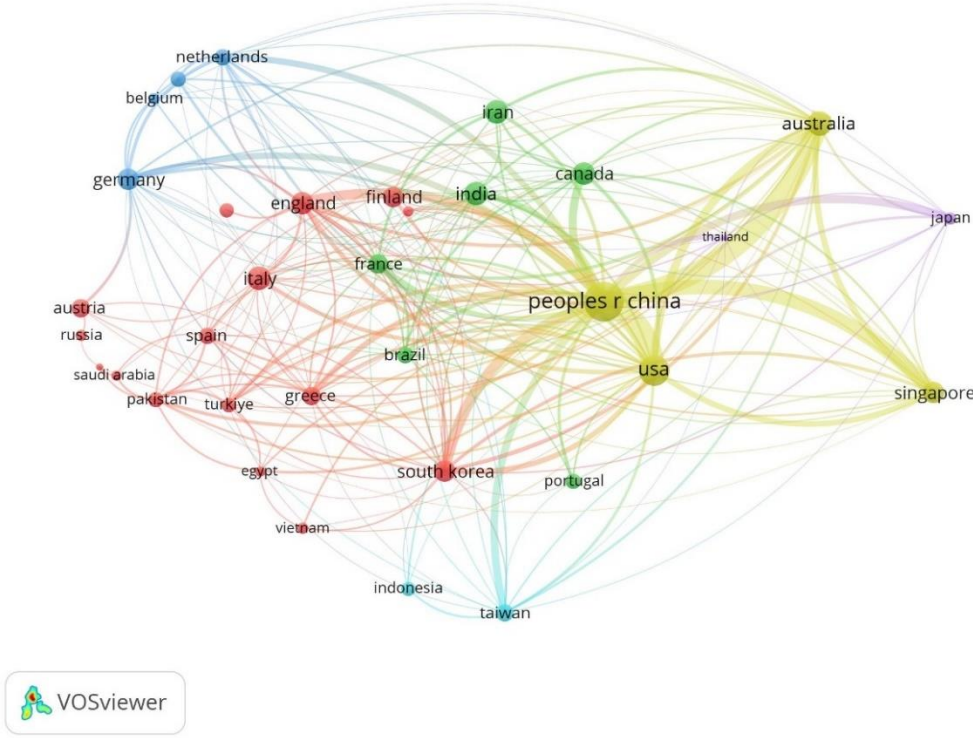
Haritadaki en büyük ve en kalın çizgilere sahip düğümler, en fazla bilimsel işbirliği yapılan ve en çok atıf alan ülkelerdir. Örneğin, "USA" ve "Peoples R China" (Çin Halk Cumhuriyeti) düğümleri oldukça fazla sayıda kalın çizgiye sahiptir, bu da bu ülkelerin global bilim ve araştırma alanında merkezi bir rol oynadığını ve dünyadaki diğer ülkelerle ile yoğun bir ilişki içinde olduğunu gösterir.

Diğer taraftan, daha küçük düğümler ve daha ince çizgiler, daha az atıf ve işbirliği yapan ülkeleri temsil etmektedir. Söz konusu ülkeler bilimsel işbirlikleri ve etkilerinde daha sınırlı olsa yine de global bilim ağının bir parçasıdır.

Bu görselleştirme hazırlanırken ağırlık için "Norm. citations" seçilmiştir. Yani ağırlık olarak her ülkenin aldığı normalleştirilmiş atıf sayılarının kullanılmıştır. Ayrıca gösterilen değerlerin, her ülkenin ortalama normalleştirilmiş skorlarına göre düzenlenmesi sağlanmıştır. Haritanın altındaki renk gradyanı atıf sayılarının durumunu yansıtır. 0,5 ila 2.0 arasında değişen bu değerlendirmede Rusya, İspanya, Mısır, Pakistan, Vietnam, Tayvan ve Türkiye'nin diğer ülkelere nazaran atıf sayılarının çok az olduğu ve etkili yayınlar yapamadıklarını göstermektedir. Ancak, Avusturya, İtalya, İran ve Finlandiya gibi ülkeler normalleştirilmiş atıf ve skor sayılarına bakıldığında oldukça etkilidir.

Şekil 8

Ülkeler Arasındaki Bilimsel İşbirliği Kümeleri



Şekil 8’de farklı renklerle temsil edilen kümelerde bulunan ülkeler arasındaki bilimsel işbirliği kümeleri gösterilmektedir. Her renk bir grubu temsil etmektedir. Bu kümeler, ortak araştırma alanlarına, benzer akademik çıkarılara veya sıkı işbirliklerine dayanır.

Kümeleme, belirli bir bilim ve teknoloji alanında ortak yayınlar yapan ve benzer atıf özelliklerine sahip ülkeler arasında olur. Bu bağlamda:

Kırmızı, yeşil, mavi, açık mavi, mor ve sarı olmak üzere 6 küme bulunmaktadır. Aralarında Türkiye’nin de bulunduğu 16 ülkeden oluşan kırmızı küme en fazla eleman sayısına sahip gruptur. En fazla atıf ve çalışmanın olduğu ülkeler olan Çin ve ABD ise Avustralya ve Singapur ile birlikte sarı kümede yer almaktadır. Bu kümedeki dört ülkede diğer kümelerdeki tüm büyük düğümlerle ilişkilidir. Özellikle ABD ve Çin çok fazla ön plana çıkmaktadır. Mavi kümede bulunan dört Avrupa ülkesi (Almanya, Belçika, İsviçre, Hollanda) bir başka bağımsız araştırma grubunu göstermektedir. Bu küme içindeki ülkeler daha ayrı bir grup oluşturmaktadır. Kendi aralarında güçlü işbirlikleri bulunmaktadır.

Ağdaki düğümlerin boyutları ve bağlantıların kalınlıkları, kümeler arasındaki ve içindeki ilişkilerin gücünü yansıtır. Örneğin, ABD ve Çin düğümleri büyük ve yoğun bağlantılara sahip olduğundan, bu ülkelerin kendi kümelerinde ve diğer kümelerle de önemli bilimsel etkileşimlere sahip olduğunu gösterir.

5. Sonuç

Tavsiye sistemleri 1980’den başlayarak günümüze kadar 10.000’in üzerinde çalışmada incelenmiş önemli bir konudur. Bu çalışma bu önemli miktardaki çalışmayı bibliyometrik analiz kullanarak incelemeyi hedeflemektedir. WoS’da bulunan başlık, özet ve anahtar kelimelerde tavsiye sistemlerini içeren 10.209 makale incelenerek, arama sonuçları son 5 yıla daraltıldı ve kalan 5.452 makale ile bibliyometrik analiz yapıldı. Önemli yazarlar, makaleler, kurumlar ve ülkeler incelenerek ağ analizine uygun hale getirildi.

Bu kadar çok sayıda makaleyi literatürü sadece taramak yerine bu şekilde görselleştirerek var olan eğilimler ve gelecek çalışmalar için önemli konular daha net bir şekilde incelendi. Bu çalışma gelecekte bu konuyu araştıracak yazarlar için bir rehber niteliği taşımaktadır. Ancak birtakım sınırlar ve genişletilebilecek alanlar mevcuttur. Çok kapsamlı olmasına rağmen WoS dışındaki veri tabanları da analize dahil edilebilir ve bu ağ yapısı Gephi benzeri uzman ve odaklanmış ağ analizi yazılımları ile detaylı şekilde incelenebilir. Bu çalışma daha detaylı bir atıf ağına dönüştürülerek ağ analizi yöntemleri kullanılarak genişletilebilir.

Kaynakça

- Aggarwal, C. C. (2016). *Recommender Systems*. <https://doi.org/10.1007/978-3-319-29659-3>
- Albort-Morant, G., & Ribeiro-Soriano, D. (2016). A bibliometric analysis of international impact of business incubators. *Journal of Business Research*, 69(5), 1775–1779. <https://doi.org/10.1016/J.JBUSRES.2015.10.054>
- Belkin, N. J., & Croft, W. B. (1992). Information filtering and Information retrieval: Two Sides of the Same Coin? *Communications of the ACM*, 35(12), 29–38. <https://doi.org/10.1145/138859.138861>
- Berg, R. van den, Kipf, T. N., & Welling, M. (2017). *Graph Convolutional Matrix Completion*. <https://arxiv.org/abs/1706.02263v2>
- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46, 109–132. <https://doi.org/10.1016/j.knosys.2013.03.012>
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modelling and User-Adapted Interaction*, 12(4), 331–370. <https://doi.org/10.1023/A:1021240730564>
- Clarivate Inc., Essential Science Indicators Help. (2024, March 10). *Essential Science Indicators Help*. <https://esi.help.clarivate.com/Content/home.htm>
- Cohen, W. W., Schapire, R. E., & Singer, Y. (1999). Learning to order things. *Journal of Artificial Intelligence Research*, 10.
- De Leon-Martinez, S., Moro, R., & Bielikova, M. (2023). *Eye Tracking as a Source of Implicit Feedback in Recommender Systems: A Preliminary Analysis*. <https://doi.org/10.1145/3588015.3589511>
- Ding, X., & Yang, Z. (2022). Knowledge mapping of platform research: A visual analysis using VOSviewer and CiteSpace. *Electronic Commerce Research*, 22(3), 787–809. <https://doi.org/10.1007/S10660-020-09410-7/TABLES/10>
- Donthu, N., Kumar, S., Mukherjee, D., Pandey, N., & Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research*, 133, 285–296. <https://doi.org/10.1016/J.JBUSRES.2021.04.070>
- Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International Journal of Information Management*, 48, 63–71. <https://doi.org/10.1016/J.IJINFOMGT.2019.01.021>
- Duraisamy, P., Yuvaraj, S., Natarajan, Y., & Niranjani, V. (2023). An overview of different types of recommendations systems-a survey. *2023 International Conference on Innovative Trends in Information Technology, ICITIIT 2023*. <https://doi.org/10.1109/ICITIIT57246.2023.10068631>
- EBSE Technical Report Guidelines for performing Systematic Literature Reviews in Software Engineering*. (2007).
- Fayyaz, Z., Ebrahimian, M., Nawara, D., Ibrahim, A., & Kashef, R. (2020). Recommendation systems: Algorithms, challenges, metrics, and business opportunities. *Appl. Scs*, 10(7748). <https://doi.org/10.3390/app10217748>
- Felfernig, A., Jeran, M., Ninaus, G., Reinfrank, F., Reiterer, S., & Stettinger, M. (2014). Basic approaches in recommendation systems. *Recommendation Systems in Software Engineering*, 15–37. https://doi.org/10.1007/978-3-642-45135-5_2/TABLES/14
- Fraumann, G., & Mutz, R. (2020). The h-index. *Handbook Bibliometrics*, 169–177. <https://doi.org/10.1515/9783110646610-018>

- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to Weave an Information tapestry. *Communications of the ACM*, 35(12), 61–70. <https://doi.org/10.1145/138859.138867>
- Hu, Y., Zhang, D., Ye, J., Li, X., & He, X. (2013). Fast and accurate matrix completion via truncated nuclear norm regularization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(9), 2117–2130. <https://doi.org/10.1109/TPAMI.2012.271>
- Jabbar, M., Javaid, Q., Arif, M., Munir, A., & Javed, A. (2018). An efficient and intelligent recommender system for mobile platform. *Mehran University Research Journal of Engineering and Technology*, 37(4), 463–480. <https://doi.org/10.22581/MUET1982.1804.02>
- Katzman, J., Shaham, U., Bates, J., Cloninger, A., Jiang, T., & Kluger, Y. (2016). DeepSurv: Personalized treatment recommender system using a cox proportional hazards deep neural network. *BMC Medical Research Methodology*, 18(1). <https://doi.org/10.1186/s12874-018-0482-1>
- Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), 30–37. <https://doi.org/10.1109/MC.2009.263>
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2016). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26. <https://doi.org/10.1016/j.neucom.2016.12.038>
- Mu, R. (2018). A survey of recommender systems based on deep learning. *IEEE Access*, 6, 69009–69022. <https://doi.org/10.1109/ACCESS.2018.2880197>
- Papneja, S., Sharma, K., & Khilwani, N. (2021). Content recommendation based on topic modeling. *Advances in Intelligent Systems and Computing*, 1227, 1–10. https://doi.org/10.1007/978-981-15-6876-3_1/FIGURES/2
- Pazzani, M., & Billsus, D. (1997). Learning and revising user profiles: The identification of interesting web sites. *Machine Learning*, 27(3), 313–331. <https://doi.org/10.1023/A:1007369909943/METRICS>
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., & Riedl, J. (1994). GroupLens: An open architecture for collaborative filtering of netnews. *Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work, CSCW 1994*, 175–186. <https://doi.org/10.1145/192844.192905>
- Resnick, P., & Varian, H. R. (1997). Recommender Systems. *Communications of the ACM*, 40(3). <https://doi.org/10.1145/245108.245121>
- Rich, E. (1979). User Modeling via Stereotypes. *Cognitive Science*, 3, 329–354.
- Roy, D., & Dutta, M. (2022). A systematic review and research perspective on recommender systems. *Journal of Big Data*, 9(1), 1–36. <https://doi.org/10.1186/S40537-022-00592-5/FIGURES/6>
- Sanderson, M., & Croft, W. B. (2012). The history of information retrieval research. *Proceedings of the IEEE*, 100, 1444–1451.
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th International Conference on World Wide Web, WWW 2001*, 285–295. <https://doi.org/10.1145/371920.372071/ASSET/CFB8B952-6F16-43A6-8125-16F950D0D3E3/ASSETS/371920.372071.FP.PNG>
- Shi, C., Hu, B., Xin, W., Member, Z., & Yu, P. S. (2017). Heterogeneous Information Network Embedding for Recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 31(2), 357 - 370. <https://doi.org/10.1109/TKDE.2018.2833443>

- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/J.JBUSRES.2019.07.039>
- Wang, X., He, X., Wang, M., Feng, F., & Chua, T.-S. (2019). Neural Graph Collaborative Filtering. *SIGIR 2019 - Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 165–174. <https://doi.org/10.1145/3331184.3331267>
- Wu, S., Tang, Y., Zhu, Y., Wang, L., Xie, X., & Tan, T. (2019). Session-Based Recommendation with Graph Neural Networks. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01), 346–353. <https://doi.org/10.1609/AAAI.V33I01.3301346>
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2017). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1). <https://doi.org/10.1145/3285029>
- Zhou, Z., Chen, X., Li, E., Zeng, L., Luo, K., & Zhang, J. (2019). Edge intelligence: paving the last mile of artificial intelligence with edge computing. *Proceedings of the IEEE*, 107(8), 1738–1762. <https://doi.org/10.1109/JPROC.2019.2918951>

Makale Bilgi Formu

Yazarların Katkıları: Bu makalenin yazımına tüm yazarlar eşit katkıda bulunmuştur. Tüm yazarlar son metni okumuş ve onaylamıştır.

Çıkar Çatışması Bildirimi: Yazarlar tarafından potansiyel çıkar çatışması bildirilmemiştir.

Telif Beyanı: Yazarlar dergide yayınlanan çalışmalarının telif hakkına sahiptirler ve çalışmalarını CC BY-NC 4.0 lisansı altında yayımlanmaktadır.

Destek/Destekleyen Kuruluşlar: Bu araştırma için herhangi bir kamu kuruluşundan, özel veya kâr amacı gütmeyen sektörlerden hibe alınmamıştır.

Etik Onay ve Katılımcı Rızası: Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunmaktadır.

İntihal Beyanı: Bu makale iThenticate tarafından taranmıştır.