

Öğrenebilen ve Adaptif Tavsiye Sistemleri İçin Karşılaştırmalı ve Kapsamlı Bir İnceleme

Anıl UTKU¹, Muhammet Ali AKCAYOL²

^{1,2}Gazi Üniversitesi, Mmf, Bilgisayar Mühendisliği Bölümü, ANKARA

(Alınış / Received: 01.12.2016, Kabul / Accepted: 26.12.2017, Online Yayınlanma / Published Online: 29.12.2017)

Anahtar Kelimeler
Adaptif Kümeleme,
Kişiselleştirilmiş Öneri,
Öğrenebilen Tavsiye
Sistemleri,
Tavsiye Sistemleri

Öz: Web'in dinamik ve heterojen yapısı sebebiyle, kullanıcıların büyük miktardaki veriler arasından tercih yapmaları giderek zorlaşmaktadır. Bu sebeple, kullanıcıların modellenmesi ve kişiselleştirilmiş bilgilere erişim önemli bir hale gelmektedir. Tavsiye sistemleri, kullanıcılara kişiselleştirilmiş öneriler sunarak, en uygun ve verimli hizmetlerin sunulmasını hedefleyen sistemler olarak ön plâna çıkmaktadır. Geleneksel tavsiye sistemleri kullanıcılarına statik yaklaşımlar ile öneri sunmakta ve zamanla değişen kullanıcı tercihlerini öneri sunma stratejilerine dâhil etmemektedir. Bu çalışmada, değişen kullanıcı tercihlerine göre öneri sunma yaklaşımlarını adaptif olarak geliştiren ve kullanıcı tercihlerini öğrenebilen tavsiye sistemleri üzerine kapsamlı inceleme ve karşılaştırma sunulmuştur.

A Comparative and Comprehensive Review for Learning and Adaptive Recommendation Systems

Keywords
Adaptive Clustering,
Personalized
Recommendations,
Learnable Recommender
Systems,
Recommendation Systems

Abstract: Due to the dynamic and heterogeneous nature of Web, it becomes increasingly difficult for users to choose between large amounts of data. For this reason, modeling of users and accessing customized information are becoming important. Recommendation systems aiming provide most appropriate and efficient services by offering customized recommendations to users. Traditional recommendation systems offer users static suggestions and do not include time-varying users' preferences in their suggestion strategies. In this study, a comprehensive investigation and comparison of the recommendation systems, which adaptively create proposals for changing user preferences and learn users' preferences, has been presented.

anilutku@gazi.edu.tr

1. Giriş

Tavsiye sistemleri, kullanıcıların birbirleri ve sistemde bulunan öğeler ile yaptıkları etkileşimlere göre kullanıcıların ilgilenebilecekleri öğeleri tahmin ederek, belirli kullanıcılar için en uygun ürün veya hizmetleri tavsiye olarak sunmayı hedefleyen programlar olarak tanımlanabilmektedir [1]. Temel hedef, büyük miktardaki verilerin içinden kişiselleştirilmiş hizmetlerin çıkarılması ile aşırı bilgi yüklemesi sorunlarıyla başa çıkmaktır. Tavsiye sistemlerinin en önemli özelliği, bir kullanıcı için kişiselleştirilmiş öneriler oluştururken diğer kullanıcıların davranışlarını analiz ederek kullanıcı tercihlerine yönelik tahminler üretmesidir [2]. Tavsiye sistemleri, kullanıcıların Web'de gezinirken daha önce yapmış oldukları tercihlerle göre öneriler sunmaktadır. Öneri sunma işlemi, kullanıcıların geçmişteki davranışlarına göre kullanıcı profilleri oluşturularak yapılmaktadır. Tavsiye sistemleri yaygın olarak e-ticaret platformlarında kullanılıyor olsa da etki alanları giderek yaygınlaşmaktadır [3]. Tavsiye sistemleri temel olarak işbirlikçi filtreleme, içerik tabanlı filtreleme ve hibrit yöntemler kullanılarak oluşturulabilmektedir.

İşbirlikçi filtreleme yöntemi, kullanıcı tercihleri arasındaki benzerlikleri temel alarak öneriler üretmektedir [4]. İşbirlikçi filtreleme süreci benzer tercihlerde bulunan kullanıcıların belirlenmesi ve bu kullanıcıların öğeler için

buldukları değerlendirmelere göre yeni kullanıcılara henüz görmedikleri öğelerin öneri olarak sunulması şeklinde işlemektedir. İçerik tabanlı filtreleme yöntemi kullanıcıların ilgilenebilecekleri öğeleri tahmin etmek için öğe içeriklerindeki bilgileri kullanmaktadır [5]. Hibrit yöntemler ise işbirlikçi filtreleme ve içerik tabanlı filtreleme yöntemlerinin dezavantajlarını ortadan kaldırmak için bu yaklaşımların birleştirilmesi şeklinde uygulanmaktadır.

Tavsiye sistemlerinde en yaygın kullanılan teknik işbirlikçi filtreleme yöntemidir. İşbirlikçi filtreleme yönteminin etkinliği, mevcut kullanıcıya benzer kullanıcıların belirlenmesi için kullanılacak algoritmaya bağlıdır [6]. Çeşitli veri madenciliği yöntemleri ve bilgiye erişim yöntemleri bu amaç için kullanılmaktadır. Tavsiye sistemlerinin değişen kullanıcı ihtiyaçlarına uyum sağlaması gelişmekte olan bir konudur. Sürekli değişen ve gelişen Web ortamında, bir öneri mekanizması yoluyla ilgili içerikleri doğru zamanlamada sunmak en önemli faktörlerden biridir. Tavsiye sistemlerinde kullanılan çeşitli model tabanlı yöntemlerle yüksek tahmin performansı elde etmek mümkündür. Ancak bu tür model tabanlı yöntemlerin dezavantajı ise uzun eğitim süreçleri gerektirmesidir. Ayrıca model tabanlı yöntemlerin statik yapıları sebebiyle değişen kullanıcı değerlendirmelerine göre adaptif olarak kullanıcı profillerinin güncellenmesi gerekmektedir [7].

Tavsiye sistemi teknolojilerinin gelişmesiyle birlikte farklı uygulama alanları için sistemler geliştirilmiştir. Geliştirilen tavsiye sistemi uygulamalarının çoğu farklı öneri sunma yaklaşımlarının avantajlarını ele alındığı hibrit sistemleri kullanmaktadır. Kullanılan hibrit sistemler, statik yaklaşımlar ile geliştirildikleri için çalışma zamanında ve kullanıcı davranışlarına göre stratejilerini değiştirememektedir. Kullanıcı davranışları ve tercihleri değişiklik gösterebileceği için tavsiye sistemlerinin kullanıcı profillerini güncellemesi ve çalışma zamanında dinamik bir şekilde öneri sunabilmesi gerekmektedir [8].

1.1. Literatürdeki Çalışmalar

Tavsiye sistemlerine yönelik son zamanlarda yapılan çalışmalarda, araştırmacılar içerik tabanlı filtreleme ve işbirlikçi filtreleme tekniklerini kullanarak veri madenciliği yöntemleri ile kullanıcı tercihlerini analiz edip kişiselleştirilmiş bilgi sağlama sistemlerine yönelik çalışmalar yürütmektedirler [2]. Veri madenciliği yöntemlerinden olan kümeleme yaklaşımı tavsiye sistemlerinde yaygın bir şekilde kullanılmaktadır. Kümeleme algoritmaları, belirlenen değişkenlere göre benzer özellikteki nesnelere kümelerin oluşturulması ve farklı özellikteki nesnelere oluşturduğu kümelerin arasındaki farkın maksimum yapılmasını sağlamaktadır [1].

Choi ve Kim tarafından 2014 yılında yapılan çalışmada, tekrarlayan satın alma modeline göre uygun ürünleri kullanıcılara sunan bir tavsiye sistemi tasarlanmıştır. Sistemde öneri kıstası olarak kullanıcı başına her bir ürün için satın almadaki yinleme sayısı kullanılmıştır. Sistem, kullanıcı tabanlı filtreleme, ürün tabanlı filtreleme ve birliktelik kuralları ile aynı anda satın alınan ürünlerin analizleri kullanılarak gerçekleştirilmiştir. Bir buçuk yıl boyunca bir şirketin satış verileri kullanılarak, sunulan önerilerin performansı analiz edilmiştir. Kullanıcı tabanlı işbirlikçi filtreleme yöntemine göre ürün tabanlı işbirlikçi filtreleme yönteminden daha iyi sonuçlar elde edilmiştir [9].

Tejeda-Lorente ve ark. tarafından 2014 yılında yapılan çalışmada, tavsiye sistemlerinin kullanıcı ya da ürün özelliklerine dayalı öneriler sunması, ürünlerin kalitelerini öneri sunma aşamasına katmaması sebebiyle bu sorunu aşmak için kalite tabanlı yeni bir tavsiye sistemi geliştirilmiştir. Geliştirilen sistem, ürünlerin kullanıcılar için ilgililiklerini kalite algısını kullanarak ortaya çıkarmaktadır. Çalışmada, işbirlikçi filtreleme ve içerik tabanlı filtreleme yöntemleri kullanılarak hibrit bir yapı sunulmuştur. Geliştirilen sistem, bulanık dilsel yaklaşımlar kullanılarak üniversite dijital kütüphanesi üzerinde test edilmiştir [10].

Amini ve ark. tarafından 2014 yılında yapılan çalışmada, işbirlikçi filtreleme ve içerik tabanlı filtreleme yaklaşımlarının zayıflıklarını çözmek ve müşteri odaklı olarak kullanıcı tercihlerine uygun öneriler sunmak için hibrit bir film tavsiye sistemi geliştirilmiştir. İçerik tabanlı veriler, ürünlerin özellikleri ve açıklamaları hakkında bilgi sunmaktadır. İçerik tabanlı filtreleme yöntemleri aktif kullanıcı ve bu bilgiler arasında modelleme yapmak için kullanılmaktadır. İşbirlikçi filtreleme yöntemleri ise kullanıcı yorumları ve değerlendirmeleri arasında ilişki kurmak için kullanılmaktadır. Geliştirilen sistemde farklı giriş bilgileri için algoritmanın davranışının değiştirilmesi amacıyla monolitik hibritleştirme kullanılmıştır. Sistemde mevcut filmlerin özellikleri K-Means algoritması kullanılarak modellenmiştir. Kullanıcı-ürün modellemelerini gerçekleştirmek için Spiking Neural Network, Multi-Layer Perceptron Neural Network (MLP), Karar ağacı ve Naive Bayes sınıflandırıcıları kullanılmıştır [11].

Christidis ve Mentzas tarafından 2013 yılında yapılan çalışmada, elektronik ürün satışı yapan çevrimiçi mağazalar için bir tavsiye sistemi geliştirilmiştir. Geliştirilen sistemde kullanıcıların ürünleri incelemeleri sırasında öneriler sunmak ve potansiyel satıcıları desteklemek amacıyla markette satılabilecek öğeler ile ilgili

öneriler ve açıklamalar sunulmaktadır. Çalışmada, e-ticaret platformlarında bulunan yapılandırılmamış ve gizli bilgileri destekleyecek yenilikçi bir sistem önerisi mevcuttur. Çalışmada kullanılan yöntemde ilk olarak kosinüs benzerliği kullanılarak kategorilerine göre ürünler arası benzerlikler hesaplanmıştır. İkinci adımda ise ürünlerin kategori başlıkları ve ürün açıklamalarında geçen kelimeler arasındaki benzerlikler kosinüs benzerliği kullanılarak hesaplanmıştır [12].

Zhang ve ark. tarafından 2013 yılında yapılan çalışmada, bulanık kümeleme teknikleri ile kullanıcı tabanlı ve ürün tabanlı filtreleme teknikleri birleştirilerek mobil ürün ve hizmet önerisi sunan hibrit bir öneri yaklaşımı geliştirilmiştir. Tavsiye sistemlerinde yaşanan seyreklik sorunlarıyla başa çıkmak, tahmin doğruluğunu arttırmak, müşteri verilerindeki belirsizlikleri ortadan kaldırmak hedeflenmiştir. Kullanıcı ürün matrislerini oluşturmak için ürün tabanlı işbirlikçi filtreleme yöntemi kullanılmıştır ve bu matrise bağlı olarak kullanıcı tabanlı işbirlikçi filtreleme yöntemleri ile öneriler oluşturulmuştur. Oluşturulan kullanıcı-ürün matrisi ile seyreklik sorununu çözmek hedeflenmiştir. Kullanıcı tercihlerini tanımlayan dilsel değişkenler ve belirsiz bilgileri kullanarak öneriler oluşturmak için bulanık kümeleme teknikleri kullanılmıştır. Geliştirilen yöntem, Fuzzy-based Telecom Product Recommender System (FTCP RS) yazılımı üzerine uygulanmıştır. Analiz sonuçları, önerilen yaklaşım uygulandıktan sonra FTCP RS uygulamasının kullanıcılara sunduğu önerilerin daha etkin sonuçlar verdiğini göstermiştir [13].

Levandovski ve ark. tarafından 2012 yılında yapılan çalışmada, konum tabanlı olarak kullanıcı değerlendirmelerine dayalı LARS sistemi geliştirilmiştir. Geleneksel tavsiye sistemleri, kullanıcıların konumsal özelliklerini dikkate almazken önerilen sistem kullanıcıların konum bilgilerine göre öneriler sunan bir yaklaşım kullanmaktadır. LARS sistemi, önerilerini üç tip konum tabanlı değerlendirme kullanarak tek bir sistem altında birleştirerek sunmaktadır. Bu değerlendirmeler kullanıcı, konum, değerlendirme puanı ve ürün dörtlüsü ile sağlanmaktadır. İlk değerlendirme türü konum bilgisi bilinen ancak ürün bilgisi bilinmeyen değerlendirmelerdir. Örneğin, evde kitap değerlendirmesinde bulunan kullanıcılar. İkincisi konumun belli olmadığı değerlendirmelerdir. Örneğin, konumu belli olmayan bir restoran için kullanıcı değerlendirmeleri. Üçüncüsü ise konum ve ürün bilgilerinin mevcut olduğu değerlendirmelerdir. Bu değerlendirmeler kullanıcı, kullanıcı konumu, değerlendirme, ürün ve ürün konumu beşlisi ile tanımlanmaktadır. Örneğin, konumu bilinen bir restoran için konumu belli olan kullanıcı değerlendirmeleri. Konum tabanlı kullanıcı ve ürün bilgileri, içerik tabanlı filtreleme yöntemleri kullanılarak sistem tasarımı gerçekleştirilmiştir. Foursquare sosyal ağı ve MovieLens film öneri sisteminin verileri kullanılarak yapılan analiz sonuçları, önerilen sistemin yaklaşık iki kat daha başarılı öneriler sunduğunu göstermiştir [14].

Bostandjiev ve ark. tarafından 2012 yılında yapılan çalışmada, Wikipedia, Facebook ve Twitter gibi birden fazla sosyal ve semantik web kaynaklarından elde edilen bilgiler ile işbirlikçi filtreleme yöntemlerini kullanarak öneri tahminleri üreten interaktif bir hibrit tavsiye sistemi sunulmuştur. Geliştirilen sistemde, geleneksel tavsiye sistemlerinden farklı olarak öneri sürecini açıklamak ve son kullanıcıların tercihlerini ortaya çıkarmak için interaktif bir kullanıcı arayüzü sunulmuştur. Önerilerin kalitesinin belirlenmesi için interaktif ve etkileşimli olmayan hibrit stratejiler ile sosyal ve semantik web API'leri kullanan yeni sistemin karşılaştırma sonuçlarına dair değerlendirmeler sunulmuştur [15].

Desrosiers ve Karypis tarafından 2011 yılında yapılan çalışmada, sadelikleri, verimlilikleri ile doğru ve kişiselleştirilmiş tavsiyeler sunmaları nedeniyle popülerliklerini koruyan işbirlikçi filtreleme yaklaşımları arasında bulunan komşuluklara dayalı yöntemlerin, ürün tavsiyelerinde karşılaştıkları sorunlara çözüm üretmek için komşuluk tabanlı yöntemlerin kapsamlı bir araştırması sunulmuştur. Bu tür yöntemlerin başlıca özelliklerinin yanı sıra avantajları açıklanmıştır. Son olarak, kullanıcılar hakkındaki bilgi eksikliği sorunları ve genellikle büyük ticari tavsiye sistemlerinde gözlemlenen sınırlı kapsam sorunları tartışılmış ve bu sorunların üstesinden gelmek için çözümler sunulmuştur. Boyut indirgeme yöntemlerinin tavsiye sistemlerinde yaşanan seyreklik ve kapsam sorunlarını ortadan kaldırdığı görülmüştür [16].

Zheng ve Li tarafından 2011 yılında yapılan çalışmada, kullanıcı tercihlerini tahmin etmek ve etkili bir kaynak öneri modeli oluşturmak için etiket ve zaman bilgilerinin önem ve etkinliklerini ortaya çıkaracak bir tavsiye sistemi geliştirilmiştir. Yapılan çalışmada, kullanıcı değerlendirmelerini elde edebilmek için çevrimiçi sosyal sistemlerdeki etiketleme ve zaman bilgileri kullanılarak bir tavsiye modeli geliştirilmiştir. Kullanıcıların sosyal platformlar üzerinde geçmişte yapmış oldukları etiketlemeler ve zamana bağlı olarak değişen kullanıcı etiketleri kullanılarak kaynak önerileri sunulmuştur. Çalışmada, sosyal etiketleme imkânı sağlayan platformlarda kişiselleştirilmiş öneriler sunmak için zaman ve etiket bilgileri, işbirlikçi filtreleme yöntemlerine eklenerek daha iyi performans sonuçları elde etmek amaçlanmıştır [17].

Geleneksel tavsiye sistemleri alanında yapılan çalışmalar kullandıkları yöntemler ve uygulama alanları açısından Tablo 1'de ÖZlenmiştir.

Tablo 1. Geleneksel tavsiye sistemleri alanında yapılan çalışmalar

Yazar	Kullanılan yöntem	Uygulama alanı	Referans
Choi ve Kim, (2014)	Hibrit (kullanıcı tabanlı filtreleme, ürün tabanlı filtreleme ve birliktelik kuralları)	E-ticaret	[9]
Tejeda-Lorente ve ark. (2014)	Hibrit (işbirlikçi filtreleme ve içerik tabanlı filtreleme)	E-kaynak	[10]
Amini ve ark. (2014)	Hibrit (işbirlikçi filtreleme ve içerik tabanlı filtreleme)	E-kaynak	[11]
Santos ve ark. (2014)	Bilgi tabanlı yöntemler	E-öğrenme	[25]
Christidis ve Mentzas (2013)	Hibrit (içerik tabanlı filtreleme ve ilişkisel veritabanları)	E-ticaret	[12]
Zhang ve ark. (2013)	Hibrit (bulanık küme teknikleri, kullanıcı tabanlı ve ürün tabanlı filtreleme)	E-ticaret	[13]
Lucas ve ark. (2013)	Hibrit (işbirlikçi filtreleme ve içerik tabanlı filtreleme)	E-turizm	[27]
Zhang ve ark. (2013)	Hibrit (ürün tabanlı işbirlikçi filtreleme, kullanıcı tabanlı işbirlikçi filtreleme ve bulanık kümeleme)	E-iş	[24]
Nguyen ve ark. (2013)	Hibrit (içerik tabanlı filtreleme, semantik içerikler)	E-kaynak	[28]
Levandovski ve ark. (2012)	Hibrit (içerik tabanlı filtreleme, konum bilgileri)	E-kaynak	[14]
Bostandjiev ve ark. (2012)	Hibrit (işbirlikçi filtreleme, semantik bilgiler)	E-kaynak	[15]
Desrosiers ve Karypis (2011)	İşbirlikçi filtreleme	E-kaynak	[16]
Tan ve ark. (2011)	Hibrit (içerik tabanlı filtreleme, sosyal ağ bilgileri)	E-ticaret	[22]

Geleneksel tavsiye sistemleri kullanıcıların ürünler ya da hizmetler ile ilgili geçmişte yapmış oldukları değerlendirmelere dayalı olarak öneriler sunmaktadır. Kullanıcı tercihlerinin sabit olacağı varsayımına dayalı olarak statik yöntemler kullanılmaktadır. Tablo 1’de görüldüğü gibi yaygın olarak işbirlikçi filtreleme, içerik tabanlı filtreleme ve bu yöntemlerinin dezavantajlarını ortadan kaldırmaya yönelik geliştirilmiş hibrit yöntemler mevcuttur. Yapılan çalışmalarda klasik tavsiye sunma algoritmaları ile kullanıcıların komum bilgileri, sosyal ağ etiketlemeleri ve semantik bilgiler kullanılarak geliştirilen sistemler hibrit bir yapıya kavuşturulmuştur. Tavsiye sistemlerinin yaşadığı soğuk başlangıç, ölçeklenebilirlik ve seyreklik gibi sorunların üstesinden gelmek için kullanılan ek kullanıcı ve ürün bilgileri ile daha verimli ve kişiselleştirilmiş öneriler sunmak hedeflenmektedir.

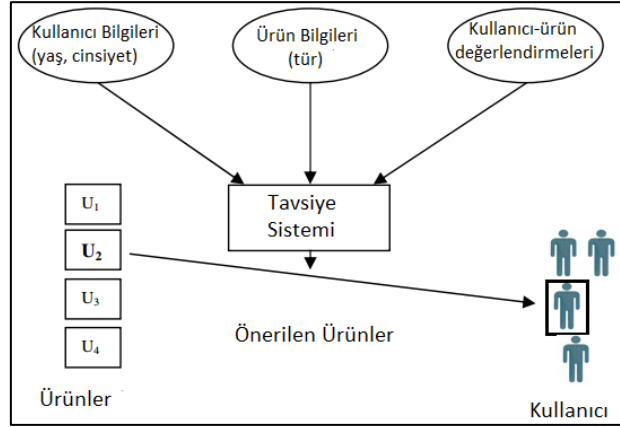
2. Tavsiye Sistemleri

Web teknolojilerinin gelişmesi ve Web üzerinde bulunan bilgi miktarının artışı sebebiyle insanların verecekleri kararların öneriler ile desteklenmesi önemli bir konu haline gelmektedir. Web ortamında kullanıcılara bu desteği onlar gibi düşünen diğer kullanıcıların yapmış oldukları seçimlere göre vermek iyi bir strateji olabilmektedir. Tavsiye sistemleri kullanıcılara artan bilgi yığını içinden en faydalı olanların seçilmesi ve bilgiye erişimi kolaylaştırma konularında destek sağlamaktadır [1, 18].

Tavsiye sistemleri, internet teknolojilerinin gelişmesi ve yaygınlaşmasıyla birlikte hayatımızın çoğu alanında karşımıza çıkan sistemler haline gelmiştir. Web sitelerinde karşımıza çıkan öneri reklamları ve çevrimiçi alışveriş sitelerinde sunulan ürün önerileri, tavsiye sistemlerine örnek olarak verilebilir. Tavsiye sistemleri, aşırı bilgi yüklemesi sorunlarıyla başa çıkabilmeleri sebebiyle son zamanlarda önemli bir çalışma alanı haline gelmiştir [19].

Tavsiye sistemleri öncelikli olarak sunulacak öneriler hakkında deneyimi olmayan kullanıcılara yöneliktir. amazon.com gibi popüler çevrimiçi mağazalar, bu bağlamda kullanıcılarına kişiselleştirilmiş öneriler sunmaktadır. Öneriler kişiselleştirilmiş olduğundan, kullanıcılar veya kullanıcı grupları farklı öneriler alabilmektedir. Dergi veya gazeteler ise genellikle daha basit bir şekilde güncel olaylarla ilgili kişisel olmayan öneriler sunabilmektedir. Bazı durumlarda faydalı ve etkili olabilmelerine rağmen, kişiselleştirilmiş olmayan sistemler tavsiye sistemleri araştırmalarında ele alınmamaktadırlar. En basit haliyle, kişiselleştirilmiş öneriler, öğelerin sıralanmış listeleri olarak sunulmaktadır. Bu sıralama yapılırken, tavsiye sistemleri en uygun ürünleri kullanıcının tercihlerine ve kısıtlamalarına dayalı olarak tahmin etmeye çalışır. Bu tahminler, tavsiye sistemlerinin kullanıcılardan aldığı oylama değerlerinden ya da kullanıcıların davranışlarının yorumlanması yoluyla elde edilmektedir.

Genel olarak her tavsiye sistemi, ürün önerileri üretmek için Şekil 1’de görüldüğü gibi belirli süreçler izlemektedir. Öneri sunma yaklaşımları, tavsiye sistemlerinin kullandıkları bilgi kaynağına göre sınıflandırılabilir. Bilginin üç olası kaynağı tavsiye işlemi için girdi olarak kabul edilebilir. Mevcut kaynaklar kullanıcı verileri (demografik özellikler), öge verileri (anahtar kelimeler, ürün kategorileri) ve kullanıcı-ürün değerlendirmeleri olabilmektedir [20].



Şekil 1. Öneri sunma süreci

2.1. Tavsiye sistemlerinin kullanım alanları

Tavsiye sistemleri, çok büyük miktarlardaki veriler arasından kullanıcıların ilgilerini çekebilecek faydalı ve kullanışlı öğeleri kullanıcılarına öneri olarak sunmayı hedeflemektedir. Tavsiye sistemleri e-ticaret, e-iş, e-öğrenme, e-turizm ve e-kaynak servisleri gibi birçok alanda kullanılabilir. [21].

A) E- ticaret Sistemleri

Son zamanlarda, bireysel müşterilerine rehberlik etmek amacıyla birçok e-ticaret sistemi geliştirilmiştir. E-ticaret sistemleri kullanıcılardan, ürünleri ile ilgili yaygın olarak puanlama ölçekleri yardımıyla geribildirimler almaktadır. Örnek olarak, iTunes kullanıcılarından satın aldıkları müzik parçaları ya da albümler için 1 ile 5 arasında bir puan ile değerlendirmelerini almaktadır. Bu değerlendirme verileri ise sonradan kullanıcılara tavsiyelerde bulunmak için kullanılabilir. [1].

E-ticaret sistemlerinde kullanıcı-ürün ilişkilerini kurabilmek için kullanılan diğer bir yöntem ise etiketlemedir. Örnek olarak MovieLens Web sitesi, kullanıcılarından filmler hakkında kısa bir şekilde görüş ve yorumda bulunmalarını beklemektedir. Amazon ve eBay gibi büyük ticaret siteleri de müşterilerine satın alma işlemlerinde yardımcı olabilmek için tavsiye sistemleri kullanmaktadır. Bu gibi Web sitelerinde kullanıcıların demografik özelliklerinden ya da geçmişteki satın alma davranışlarından yararlanılmaktadır [21].

Tan ve ark. tarafından 2011 yılında yapılan çalışmada, sosyal medya bilgileri ve müziklerin akustik tabanlı içerik bilgileri kullanılarak bir müzik tavsiye sistemi geliştirilmiştir. Müzik parçaları ile kullanıcılar arasındaki ilişkileri modelleyebilmek için hipergraf yapısı kullanılmıştır. Klasik graflarda her bir kenar ile iki öge arasında bağlantı kurulabilirken önerilen yöntemde öge kümeleri arasında bağlantı kurmak hedeflenmiştir [22].

B) E- iş Sistemleri

E-iş sistemleri, bireysel olarak müşteri odaklı çalışan sistemler (B2C) ve iş kullanıcılarına yönelik ürün ve hizmetleri öneri olarak sunmayı hedefleyen sistemler (B2B) olarak ayrılabilir. E-iş sistemleri, mevcut iş yapma yöntemlerini daha hızlı ve verimli bir şekilde sürdürebilmek için tavsiye sistemlerini kullanmaktadır. İş ortaklarına ya da kullanıcılarına hizmetleri ve ürünleri ile ilgili haberler sunma, ürün kıyaslamaları yapma ve tüketicilere ürün ve hizmet önerileri sunmak hedeflenmektedir [23].

Zhang ve ark. tarafından 2013 yılında yapılan çalışmada, bulanık mantık tabanlı bir telekom ürünleri tavsiye sistemi geliştirilmiştir. Geliştirilen sistem ile müşterilere hizmet planı ve paket halinde öneriler sunulmakta ve aynı zamanda sunulan öneriler ile ilgili açıklamalarda bulunmaktadır. özellikle müşteri verilerindeki

belirsizlikleri gidermek için ürün tabanlı işbirlikçi filtreleme yöntemi, kullanıcı tabanlı işbirlikçi filtreleme yöntemi ve bulanık kümeleme yöntemleri kullanılarak hibrit bir sistem geliştirilmiştir [24].

C) E- öğrenme Sistemleri

Geleneksel e-öğrenme sistemleri temeline dayalı olarak geliştirilen e-öğrenme tavsiye sistemleri, 2000'li yılların başından beri eğitim kurumları için giderek popüler hale gelmiştir. Bu sistemler genellikle öğrencilerin ilgilerini çeken dersler, konu ve öğrenme materyallerini seçmek ve sınıf ortamında çalışma ve çevrimiçi tartışma ortamı oluşturma gibi açılardan öğrencilere yardımcı olmayı amaçlamaktadır [1].

Santos ve ark. tarafından 2014 yılında yapılan çalışmada, Web tabanlı eğitim sistemleri için kişiselleştirilmiş destek sağlamak amacıyla kullanıcı odaklı bir e-öğrenme tavsiye sistemi geliştirilmiştir. Geliştirilen sistem, e-öğrenme döngüsü içerisinde alan uzmanlarının destekleriyle öğrenci ihtiyaçları göz önünde bulundurularak tasarlanmıştır. Öğrenci ihtiyaçları, yaş ve sınıf durumu gibi veriler, bilgi tabanlı yöntemler vasıtasıyla kişiselleştirilmiş öneriler oluşturmak için kullanılmıştır [25].

D) E- turizm Sistemleri

E- turizm sistemleri, artan tatil ve turizm seçenekleri arasında kullanıcılara en uygun önerileri sunmayı hedeflemektedir. Bu alanda yapılmış tavsiye sistemleri ulaşım, restoran, konaklama ve gezilecek yerler gibi alanlara yönelik gerçekleştirilmiştir. Bu sistemler kullanıcıların demografik özelliklerine, geçmiş tercihlerine ve zamansal değişkenlere bağlı olarak öneriler sunmaktadır [26].

Lucas ve ark. tarafından 2013 yılında yapılan çalışmada, Portekiz'in Oporto şehrini ziyaret etmek isteyen turistler için kişiselleştirilmiş tur planları sunulmasını hedefleyen bir gezi planlama tavsiye sistemi geliştirilmiştir. Tavsiye sistemlerinde yaşanan ölçeklenebilirlik, seyreklik ve yeni kullanıcı ve ürün gibi sorunların üstesinden gelmek için hibrit bir sistem geliştirilmiştir. Önerilen yaklaşım işbirlikçi filtreleme ve içerik tabanlı filtreleme yöntemlerinin kümeleme algoritmaları, ilişkisel sınıflandırma algoritmaları ve bulanık mantık ile birleştirilmesi ile elde edilmiştir [27].

E) E- kaynak Sistemleri

E-kaynak sistemleri film, müzik, video, Web sayfası ya da kullanıcılar tarafından yüklenen belge ve içeriklerin öneri olarak sunulduğu sistemlerdir. E-kaynak tavsiye sistemleri, diğer kullanıcılar tarafından paylaşılan içeriklerin, ilgililik durumlarına göre kullanıcılara öneri olarak sunulması temeline dayanmaktadır [1].

Nguyen ve ark. tarafından 2013 yılında yapılan çalışmada, Web sitelerinin alan ve Web kullanım bilgilerini semantik geliştirme yöntemleri yoluyla bütünleştirerek daha iyi Web sayfası önerileri sunmak için yeni bir yöntem sunulmuştur. Geliştirilen sistemde, alan bilgisini temsil etmek için ontoloji yapısı kullanılmıştır. Ayrıca alan bilgisini ve Web kullanım bilgisini entegre etmek için kavramsal tahmin modeli geliştirilmiştir. Önerilen yöntem, Web kullanım madenciliğinden elde edilen sonuçlar ile karşılaştırılmış ve daha yüksek performans elde edildiği görülmüştür [28].

2.2. Tavsiye sistemlerinde kullanılan yöntemler

Çevrimiçi mağazaların büyümesiyle birlikte kullanıcılara ürünlere daha kolay erişim ve ürünler hakkında daha fazla bilgi sahibi olma imkânı sunulmaktadır. Ayrıca bu gelişimin tüketici alışkanlıklarının belirlenmesinde de önemli bir etkisi olmaktadır. Günümüzde en etkin çözümlerden biri, tüketicilere ürün önerilerinin otomatik ve kişiselleştirilmiş olarak sunulduğu tavsiye sistemleridir [16].

Tavsiye sistemlerinde temel sorun, kullanıcıların geçmiş bilgilerine dayanarak yeni ve özgün önerilerin sunulabilmesidir. Tavsiye sistemlerinin kendi temel fonksiyonlarını uygulayabilmeleri ve kullanıcılar için yararlı öğelerin belirlenmesi için önerilecek öğelerin sistem tarafından tahmin edilmesi gerekmektedir. Bunu yapmak için sistemin bazı ürünlerin kullanılabilirliğini tahmin etmesi ya da en azından bazı ürünlerin kullanılabilirliğini karşılaştırıyor olması gereklidir. Daha sonra, bu karşılaştırmalara dayalı olarak hangi ürünlerin tavsiye edileceğine karar verilmektedir [29]. Tavsiye sistemlerinin tahmin aşamasını göstermek için basit, kişisel olmayan ve sadece en popüler şarkıları tavsiye eden bir sistem örnek olarak verilirse, bu yaklaşımın kullanılabilirliği için temel gerçeklik, birçok kullanıcı tarafından beğenilen bir ögenin aynı zamanda diğer kullanıcılar tarafından da beğenilebileceğidir [16].

Tavsiye sistemleri çalışmalarında kullanılan en genel çerçeve Şekil 2’de gösterilmiştir. Bilinen kullanıcı tercihleri, n kullanıcıları ve m öğeleri ifade edecek şekilde her bir hücredeki $r_{u,i}$ değeri, u kullanıcısının i öğesi üzerindeki değerlendirme sonucunu göstermektedir. Bu kullanıcı değerlendirme matrisi, çoğu kullanıcı tüm öğeleri değerlendirmede için seyrek. Tavsiye sisteminin temel görevi, değerlendirilmemiş ürünlere kullanıcılar tarafından verilecek puanların tahmin edilmesidir. Genel olarak kullanıcılar, diğer kullanıcıların yapmış oldukları değerlendirme sonuçlarını görmezler ve yüksek değerlendirme puanına sahip ürünleri öneri olarak alırlar. Ele alınan kullanıcı aktif kullanıcı olarak adlandırılmaktadır [30].


		Ürünler					
		1	2	..	i	..	m
Kullanıcılar	1	5	3		1	2	
	2		2				4
	...			5			
	u	3	4		2	1	
	...					4	
n			3	2			
		3	5		?	1	

Şekil 2. Her bir hücredeki $r_{u,i}$, u kullanıcısının, i ürününe karşılık gelen kullanıcı değerlendirme matrisi

Tavsiye sistemleri, öneri sunma aşamasında kullandıkları bilgilere göre işbirlikçi filtreleme yöntemi, içerik tabanlı filtreleme yöntemi, bağlama bağımlı yöntemler, demografik özelliklere dayalı yöntemler, bilgi tabanlı yöntemler, sosyal ağ tabanlı yöntemler ve hibrit yöntemler olarak kategorize edilebilmektedir.

A) İşbirlikçi Filtreleme Yöntemi

Tavsiye sistemlerinde en popüler ve yaygın olarak uygulanan bir teknik olarak kabul edilen işbirlikçi filtreleme yaklaşımı, aktif kullanıcıya benzer niteliklere sahip diğer kullanıcıların geçmişte beğenmiş oldukları öğelerin öneri olarak sunulması temeline dayanmaktadır. Kullanıcı beğenileri arasındaki benzerlik, geçmişte yapmış oldukları değerlendirmelere göre hesaplanır. Örnek olarak Şekil 3’te görüldüğü gibi beğendikleri ürünler benzer olan X ve Y kullanıcıları için, X kullanıcısına Y kullanıcısının beğendiği D ürünü öneri olarak sunulabilir [20].




Şekil 3. İşbirlikçi filtreleme yöntemi

İşbirlikçi filtreleme yöntemleri kullanıcıların birbirleri ve ürünler ile olan etkileşimlerini değerlendirme ve etiketleme gibi yollar ile doğrudan elde edebilirken indirme, okuma, tıklama ve indirme gibi eylemler ile dolaylı olarak elde edebilmektedir. Kullanıcı tabanlı işbirlikçi filtreleme yöntemleri, örtüşen kullanıcı etkileşimlerinden ve aynı öğeler için yapılmış benzer değerlendirmeleri kullanarak oluşturduğu kullanıcı profillerine göre öneriler sunmaktadır. Öğe tabanlı işbirlikçi filtreleme yöntemleri ise kullanıcıların yapmış oldukları seçimlere dayalı olarak bir öğe kümesi belirlemekte ve kullanıcıların ilgisini çekebilecek benzer ürünleri öneri olarak sunmaktadır [31].

İşbirlikçi filtreleme yaklaşımı ürünler ile ilgili bilgilerle ilgilenmemektedir. Bu stratejinin avantajı ise ürünler hakkındaki bilgilerin sisteme girilmesinin ya da muhafaza edilmesinin gerekli olmayışıdır. İşbirlikçi filtreleme yaklaşımı, içerik tabanlı filtreleme yaklaşımının yaşadığı otomatik bilgi işleme zorlukları neticesinde geliştirilmiştir. İşbirlikçi filtrelemenin diğer yaklaşımlarından farkı, verilerin analiz edilmesi yerine değerlendirmeye alınmasıdır. Bilgiler, bu sayede kullanıcıların görüşlerine dayalı olarak kategorize edilir. Buna ek olarak işbirlikçi filtreleme yöntemi, mevcut kullanıcıya benzer diğer kullanıcıların tercihlerinin tavsiye olarak sunulmasını sağlamaktadır. Sisteme dâhil olan bütün kullanıcılar, yapmış oldukları seçimlerle işbirlikçi filtreleme yaklaşımının tavsiye sunma sürecine katkıda bulunmaktadır. Sunulacak öneriler, diğer kullanıcılar tarafından ürünlere verilen puanların, aktif kullanıcının vermiş olduğu puanlarla eşleştirilmesiyle üretilmektedir [16].

B) İçerik Tabanlı Filtreleme Yöntemi

İşbirlikçi filtreleme yaklaşımları, doğrudan kullanıcıların ürünler ile ilgili yapmış oldukları değerlendirme sonuçlarını kullanmaktadır. Kullanıcılara, onların kişisel özelliklerini belirleyerek, ilgi alanlarına göre ürünler öneri olarak sunulabilmektedir. İçerik tabanlı filtreleme yaklaşımları, ürünler ve kullanıcıların tercihleri hakkında ek bilgiler gerektiriyor olsa da, büyük bir kullanıcı topluluğu ya da değerlendirme puanlarının bulunduğu bir veritabanı gerektirmez [5]. Şekil 4'te görüldüğü gibi bir film tavsiye sisteminde kullanıcıların izlemiş oldukları filmlerden çıkarımlar yaparak, kullanıcının hangi film türleriyle ilgili olduğu bilgisi elde edilerek öneriler sunulabilmektedir [20].



Şekil 4. İçerik tabanlı filtreleme yöntemi

İçerik tabanlı filtreleme yaklaşımları, kullanıcılar tarafından değerlendirilen belgelerin veya öğelerin analizlerini yaparak kullanıcılar ile ilgili bir profil elde eder. Elde edilen profil, kullanıcı ilgilerinin bir örneği olarak kabul edilir. Tavsiye sunma süreci temelde, içerik niteliklerinin kullanıcı profili ile eşleştirilmesinden oluşur. Kullanıcı profilleri, kullanıcı tercihlerini yansıtmalarının yanı sıra bilgiye erişim işlemi için de büyük avantajlar sağlar. Örnek olarak kullanıcıların ilgilenmediği Web sayfalarının gösterilmemesi ya da arama sonuçlarında filtreleme kullanılması işlemlerinde yararlanılabilmektedir [16].

İçerik tabanlı filtreleme yöntemleri kullanıcıların öğeler ile ilgili yaptıkları değerlendirmeleri kullanıcılar ile eşleştirmektedir. İçerik tabanlı filtreleme yöntemleri önerilerini bireysel olarak kullanıcı ve öğe bazında sağlamakta, diğer kullanıcıların değerlendirmelerini göz ardı etmektedir. Hibrit yöntemler ise içerik tabanlı filtreleme ve işbirlikçi filtreleme yöntemlerinin eksi yönleriyle başa çıkmak ve performansı arttırmak için bu yöntemlerin avantajlı yönlerini kullanmaktadır.


C) Bağlama Bağımlı Yöntemler

Bağlam kavramı Dey tarafından 2001 yılında yapılan çalışmada, bir varlığın durumunu karakterize etmek için kullanılan herhangi bir bilgi olarak tanımlanmaktadır [32]. Varlık bir kişi, bir yer ya da kullanıcıların uygulamalarla ve birbirleriyle olan etkileşimleri olabilmektedir. Bağlam kavramı yer, zaman, kullanıcı aktivitesi, fiziksel koşullar ve sosyal ilişkiler gibi nitelikleri kapsamaktadır [20].

Tavsiye sistemleri alanında yapılan çalışmalar tavsiye sürecine bağlamsal bilgilerin eklenmesine yönelmektedir. Geleneksel tavsiye sistemleri basit kullanıcı modelleri ile kullanıcı profilleri oluştururken bağlama dayalı tavsiye sistemleri sunulan önerilerin kalitesini artırmak için ek bilgiler kullanmaktadır. Bağlama dayalı tavsiye sistemleri bu niteliklerden biri veya daha fazlasını kullanarak sunulacak önerilerin performansını arttırmayı hedeflemektedir. Örnek olarak işbirlikçi filtreleme yönteminin kullanıldığı bir film tavsiye sistemi, kullanıcıları film değerlendirmeleri ve filmler kümesinin bir vektörü olarak belirlerken bağlama dayalı tavsiye sistemleri kullanıcılara daha uygun öneriler sunabilmek için kullanıcıların zaman ve konum gibi bilgilerini de kullanmaktadır [33]. Bağlama dayalı tavsiye sistemlerinde kullanılacak bilgiler direk olarak kullanıcılardan alınabileceği gibi dolaylı olarak ortam üzerinden de elde edilebilir (örneğin konum ya da cihaz bilgisi). Ayrıca bağlamsal bilgiler kullanıcı etkileşimlerinin analiz edilmesi yoluyla da elde edilebilmektedir.

D) Demografik Özelliklere Dayalı Yöntemler

Kullanıcıların, kolay bir şekilde kalıplaşmış özellikler ya da kullanıcı kümelerinin özellikleri yardımıyla modellenmesi temeline dayanmaktadır. Kullanıcı topluluklarında sık görülen özellikler ve kullanıcı özelliklerinden oluşturulan bilgi bankaları kullanılmaktadır. Yeni bir kullanıcı sisteme dâhil olduğunda, belirli kalıplaşmış özellikleri sergiliyorsa o kullanıcı benzer kalıplara sahip diğer kullanıcıların sınıfına atanacaktır. Demografik özelliklere dayalı tavsiye sistemleri, kullanıcılarına öneri sunma aşamasında Şekil 5'de görüldüğü gibi kullanıcı bilgilerini ve görüşlerini kullanmaktadır.



Şekil 5. Demografik özelliklere dayalı yöntemler

Demografik özelliklere dayalı yöntemler, belirli bir demografik gruptaki kullanıcıların benzer beğenilere sahip olacağı ve benzer tercihler yapacağı varsayımına dayanmaktadır. Bu öneri sunma yaklaşımının avantajı, işbirlikçi filtreleme ve içerik tabanlı filtreleme teknikleri için gerekli olan kullanıcı değerlendirme geçmişini gerektirmiyor olmasıdır. Dezavantajı ise güvenlik ve gizlilik konuları açısından bakıldığında kullanıcı verilerinin toplanmasıdır [20].

E) Bilgi Tabanlı Yöntemler

Kullanıcı tercihlerinin, ihtiyaçları doğrultusunda şekilleneceği temeli üzerine kurulmuş yöntemlerdir. Örnek olarak kullanıcıların satın alacakları bir arabada bekledikleri özelliklerin neler olduğu belirlenmekte ve konfor, düşük yakıt tüketimi gibi beklentilere uygun ürünler öneri olarak sunulacaktır. Kullanıcı tercihleri ve mevcut ürün, hizmet veya içerikler arasındaki ilişkileri belirlemek amacıyla kullanıcı profil modelleri oluşturulmaktadır [1, 4].

F) Sosyal Ağ Tabanlı Yöntemler

Sosyal ağ analizi, son zamanlarda Web tabanlı sistemlerde sosyal ağ araçlarının kullanılmasının bir sonucu olarak tavsiye sistemleri için de kullanışlı bir yöntem haline gelmiştir. Tavsiye sistemleri kullanıcı deneyimlerini geliştirmek için kullanıcıların birbirleriyle sosyal etkileşimler kurabilecekleri ortamlar oluşturmaktadır. Elde edilen bu veriler, özellikle işbirlikçi filtreleme yöntemlerinde yaşanan seyreklik gibi sorunların üstesinden gelmek için kullanılabilir [1, 17].

G) Hibrit Yöntemler

Hibrit yöntemler, yüksek performans elde etmek ve geleneksel tavsiye sistemi yöntemlerinin dezavantajların üstesinden gelmek için iki veya daha fazla yöntemin iyi özelliklerini bir araya getiren tekniklerdir. Popüler hibrit yöntemler, işbirlikçi filtreleme ve içerik tabanlı filtreleme yöntemleri kullanılarak sezgisel olarak oluşturulmaktadır [16].

Tavsiye sistemlerinde kullanılan algoritmalar farklı uygulama alanlarında kullanılıyor ve geçerli kabul ediliyor olmasına rağmen çözümlenmesi gereken temel bazı problemlere sahiptir:

- Yeni kullanıcı ve ürünler için kullanılabilir herhangi bir mevcut değerlendirme olmadığı için soğuk başlangıç sorunları yaşanmaktadır.
- Son kullanıcılara sunulan önerilerin arka planındaki mantığını açıklamak zordur. Tavsiye sunma algoritmasının karmaşıklığı, algoritmanın kavranmasını zorlaştırmakta ve başarısız olarak sunulan önerilerde güven problemlerine yol açmaktadır. Bu karmaşıklık ise bağlama dayalı öneri algoritmalarında çeşitli bağlam bilgilerinin birlikte kullanılmasından ileri gelmektedir. Tavsiye sistemlerinin kara kutu yapıları kullanıcıların interaktif ve iteratif bir şekilde öneri sunma sürecine katkıda bulunmalarını engellemektedir
- Bağlamsal bilgiler özellikle, mobil cihazlarda bulunan sensörlerden elde edilen veriler kullanılarak zenginleştirilebilir. Bu şekilde daha yüksek etkileşim kapasitesine sahip tavsiye sistemleri geliştirilebilir. Ancak bu durumda veri ve kullanıcı gizliliği konuları ön plana çıkmaktadır[1].

3. Öğrenebilen ve Adaptif Tavsiye Sistemleri

Kullanıcılara öneriler sunmak için çeşitli tavsiye sistemi algoritmaları önerilmiş olsa da tavsiye sistemlerinin verimli bir şekilde çalışması için çözülmesi gereken bazı zorluklar hala mevcuttur. Tavsiye sistemleri yeni kullanıcılar ve yeni ürünler gibi durumlarda herhangi bir belirtici bulunmadığı için soğuk başlangıç sorunu yaşamaktadır [3]. Ayrıca tavsiye sistemleri kullanıcıya öneri sunma mantıkları ya da gerekçeleri ile ilgili herhangi bir bilgi sunmadıkları için birer kara kutu olarak görülmektedir. Bu durum tavsiye sistemleri tarafından önerilen sonuçların kavranmasını engellemekte ve önerilerin başarısız olduğu durumlarda güven sorunlarına yol açabilmektedir [34]. Ayrıca bu yaklaşım geribildirim için kullanıcılara izin vermemektedir. Kullanıcıların değişen ilgi alanlarını tahmin etmek zor bir iş olduğu için süreci yönlendirebilecek farklı yaklaşımların geliştirilmesi

gerekmektedir. Bu yaklaşımlar, artan ürün çeşitliliği ve tavsiye edilen sonuçların yeniliği gibi yüksek riskli uygulamaların sorunlarını çözme konusunda ve değişen kullanıcı tercihlerine adaptif bir şekilde uyum sağlama konularında umut verici olmaktadır [35].

Tavsiye sistemleri, kullanıcıların etkileşimlerine göre elde ettiği bilgileri kullanarak öneriler sunan sistemlerdir. Tavsiye sistemlerinde öğrenme ve adaptiflik kavramı ise birbirlerinden bağımsız parametreler ve kullanıcı etkileşimlerine göre öneriler sunabilme yeteneğini ifade etmektedir. Adaptif tavsiye sistemleri, kullanıcıların etki alanındaki değişimleri direkt ya da dolaylı olarak kayıt edebilen ve sundukları önerileri güncelleyebilen sistemlerdir [34].

İnsan psikolojisi açısından bakıldığında, gerçek hayatta kullanıcıların birbirlerine sunduğu önerileri sunabilecek tavsiye sistemlerinin geliştirilebilmesi için kullanıcı dinamiklerinin dikkate alınması gerekmektedir. İnsan zihni oldukça karmaşık ve yorumlaması zor bir yapıya sahip olduğundan tavsiye sistemlerine çeşitli kişilik özelliklerini açığa çıkaracak özelliklerin adapte edilmesi gerekmektedir. Sunulan önerilerin gerçek hayattaki öneriler kadar gerçekçi olabilmesi için şeffaflık ve güvenilirlik gibi psikolojik faktörlerin göz ardı edilmemesi gerekmektedir [36].

Kullanıcı etkileşimlerinin bulunduğu sistemlerde nihai hedef kullanıcı memnuniyetidir. Kullanıcı ara yüzlerinden, kullanıcılar ile ilgili elde edilen bilgi miktarındaki artış kullanıcı modellemesini oldukça kolaylaştırmaktadır. Örnek olarak, kullanıcılara doğrudan basit bir ara yüz ile ürünler ile ilgili değerlendirmelerini soran sistemlerde, değerlendirmede bulunan kullanıcı sayısı oldukça düşüktür. Kullanıcı etkileşimlerini dinamik bir şekilde elde eden modern sistemlerde ise kullanıcıların Web sayfası üzerindeki tıklama bilgileri, inceledikleri sayfalar gibi dolaylı yoldan elde edilen kullanıcı verileri ile sistem deneyimi artırılmaktadır. Tavsiye sistemlerinde kullanıcı memnuniyetini etkileyen diğer bir faktör ise sunulan önerilerin doğruluğudur. Sunulan önerilerin doğruluğu, her bir kullanıcı için kullanıcı ihtiyaçlarını ve beklentilerini karşılayabilecek çözümlerin sağlanmasıdır. Öneri doğruluğu, verimli bir algoritma ve zenginleştirilmiş veriler üzerinden sağlanmaktadır [1].

Adaptif tavsiye sistemleri, sistem tarafında kullanıcı etkileşimleri sonucu meydana gelen içerik değişimlerini kaydetmekte, güncellemeler ve değişiklikler yapmaktadır. Bu tür değişiklikler kullanıcılara sunulan önerileri ve sistemin uygulanabilirliğini etkilemektedir. Ancak tavsiye sistemlerinin uygulanabilirliklerini kullanıcıların yanı sıra öneri olarak sunulacak öğelerin bağlamı, çeşitliliği ve yeniliği gibi kavramlar doğrudan etkilemektedir [37].

3.1. Adaptif ve öğrenilebilen tavsiye sistemlerinde kullanılan parametreler

Klasik tavsiye sistemlerinde kullanılan işbirlikçi filtreleme, içerik tabanlı filtreleme ve hibrit yöntemler, temel olarak farklı kullanıcıların farklı ürünler ile ilgili beğeni derecelerini tahmin etme temeline dayanmaktadır. İçerik tabanlı filtreleme yöntemleri, kullanıcıların daha önce değerlendirmede bulunduğu öğeleri temel alarak kullanıcı profilleri oluşturmaktadır [7]. Bu yöntemin dezavantajı ise sunulan önerilerin, kullanıcıların daha önce beğendiği öğelere benzer öğeler ile sınırlı kalmasıdır. İşbirlikçi filtreleme yöntemi kullanıcıların öğeler ile ilgili geçmiş değerlendirmelerinden yola çıkarak benzer zevklere sahip kullanıcıların tercihlerini öneri olarak sunmaktadır. Hibrit yöntemler ile işbirlikçi filtreleme ve içerik tabanlı filtreleme yöntemlerinin avantajlı yönlerini farklı stratejiler altında birleştirerek öneri kalitesini yükseltmek amaçlanmaktadır [6].

Geleneksel tavsiye sistemlerinde kullanılan bu yaklaşımlar içerik bilgisine ve zamana göre kullanıcı modellerini güncelleştiremedikleri için farklı türde öneriler sunma konusunda eksik kalmaktadır. Ayrıca geleneksel yöntemler, kullanıcıların ilgi alanlarının belirli süreler boyunca değişmeyeceği varsayımı üzerine inşa edildikleri için mevcut kullanıcı verileri ve kullanılan algoritma ile sınırlı kalmaktadır. Ancak bu varsayım, hızla gelişen Web ortamı ve yüksek tempolu hayat içerisinde geçersiz olmaktadır. Geleneksel tavsiye sistemleri, kullanıcı tercihlerindeki değişime ayak uyduramadığı için dinamik parametrelerin öneri sunma sürecine dâhil edilmesi gerekmektedir. Bu parametreler ise zamansal bağlam, yenilik, farklılık, çeşitlilik, dinamik ortam ve zamansal karakteristiklerdir [35].

A) Zamansal değişimler

Zamansal değişimler, tavsiye sistemi kullanıcılarının ürünler ile ilgili tercihlerinin zaman içerisinde değişiklik göstermesini ifade etmektedir. Kullanıcıların ürün algıları ve mevcut ürünlerin popüleriteleri yeni seçimlerin ortaya çıkmasına neden olmaktadır [38]. Benzer şekilde müşteri eğilimleri, daha önce görmüş oldukları ürünleri yeniden inceleme yönünde de gelişebilmektedir. Bu sebepten zamansal dinamiklerin modellenmesi tavsiye sistemleri tarafından sunulan önerilerin doğruluk oranını arttırmak için ve genel müşteri tercihi profillerinin

geliştirilmesi için esastır. Ancak zamansal değişimler, birden fazla kullanıcı ve ürünün kesiştiği platformlarda çeşitli zorluklar ortaya çıkarmaktadır. Değişen kullanıcı dinamikleri birbirini etkilemekte ve birbirleriyle ilişkili veriler üzerinde meydana gelen değişiklikler kullanıcı profillerinin güncellenmesini zorunlu kılmaktadır [8].

B) Gerçek zaman dinamikleri

Gelişen Web teknolojileri sayesinde kurumlar ve organizasyonlar, kullanıcılarına birden çok dijital içeriği doğrudan sunabilmektedir. Ancak kurum ve organizasyonların karşılaştıkları en büyük zorluk içeriklerin eksikliğinden ziyade uygun kullanıcıları tespit ederek sunulacak önerileri optimize etmektedir. Kişiselleştirilmiş önerilerin, müşteri memnuniyetini arttırmak ve kullanıcı bağlılığını arttırmak için tüm kullanıcıların ortak olarak ilgilerini çekebilecek bir yaklaşım ile sunulması gerekmektedir. Kişiselleştirilmiş öneriler ile site kullanıcıları hakkında bilgi toplamak, mevcut içerikleri yönetmek, kullanıcı davranışlarını ve etkileşimlerini analiz etmek ve kullanıcılara doğru içerikleri sunmak hedeflenmektedir [39]. Ancak bu durum örnek olarak haber önerisi sunan sistemlerde, hızla değişen içerikler ve değişen yeni kullanıcılar sebebiyle soğuk başlangıç sorunlarının yaşanmasına neden olmaktadır.

Çeşitli hibrit tavsiye sistemleri ve adaptif tavsiye sistemleri gerçek zaman dinamiklerinden kaynaklı bu sorunları aşmak için geliştirilmiştir. İşbirlikçi filtreleme yöntemlerinin yeni kullanıcılar ve öğeler için yaşadığı soğuk başlangıç sorunları, içerik tabanlı filtreleme yöntemlerinin birlikte kullanımları ile ya da kullanıcı profillerinin adaptif olarak güncellenmesi yoluyla çözümlenebilmektedir. Hibrit yöntemler işbirlikçi filtreleme ve içerik tabanlı yöntemlerin bazı kısıtlamalarını ortan kaldırıyor olsa da dinamik içerikler ve kullanıcı profil modellemesi konularında yetersiz kalmaktadır. Dinamik içerikler yalnızca sisteme yeni öğe eklenmesi ya da silinmesi değil aynı zamanda içerik popülaritesinin kullanıcı etkileşimleri ile zaman içinde değişmesi anlamına gelmektedir. Örnek olarak haber önerisi sunan bir Web sitesine yeni eklenen bir içeriğin haber değeri taşıması, kullanıcıların bu içeriğe zaman içerisinde tıklama oranı ile belirlenmektedir [8].

C) Bağlam

Günler, hava durumu, konum ve mevsimler gibi bağlamsal özellikler, kullanıcı seçimlerini etkileyebilen özelliklerdir. Geleneksel tavsiye sistemleri, öneri sunma aşamasında bağlamsal özellikleri dikkate almayı yalnızca kullanıcı ve öğelere odaklanmaktadır. Ancak örnek olarak film önerisi sunan sistemlerde, sadece kullanıcıları ve öğeleri dikkate almak yeterli olmayıp bağlamsal bilgilerin de öneri sunma sürecine dâhil edilmesi gerekmektedir. Zamansal bağlam kavramı kullanılarak tatil önerisi sunan tavsiye sistemlerinde mevsimden mevsime sunulan öneriler değişiklik göstermektedir. Örnek olarak, kullanıcılar hafta içi günlerde borsa haberlerini okumayı, hafta sonları ise filmler hakkında yapılmış yorumları okumayı tercih edebilir. Bağlam bilgileri pazarlama-tüketici stratejilerinde de sıklıkla kullanılmakta ve tüketici tercihlerinin doğru bir şekilde tahmin edilmesinde ön plana çıkmaktadır [33].

D) Çeşitlilik

Çeşitlilik kavramı, kullanıcılara benzer özelliklere sahip farklı ürünlerin öneri olarak sunulmasını ifade etmektedir. Çeşitlilik bir grup içerisinde bulunan öğelerin birbirlerinden ne kadar farklı olduklarının derecesidir. Tavsiye sistemlerinde bulunan ve öneri olarak sunulan öğelerin çeşitliliği, kullanıcı ilgilerinin belirlenmesinde ve adaptif profil modellemesinde kolaylık sağlamaktadır. Literatürde doğruluk ve öneri çeşitliliği arasındaki dengeyi sağlamaya yönelik yapılmış çalışmalar mevcuttur [8, 40].

E) Yenilik

Geleneksel tavsiye sistemleri genel olarak en çok beğenilen ya da popüler ürünleri öneri olarak sundukları için yeni öğeler arayan kullanıcılar için etkisiz öneriler oluşturabilmektedir. İşbirlikçi filtreleme yöntemleri, içerik tabanlı filtreleme yöntemlerine göre daha az yeni öğe önerisinde bulunmasına rağmen daha yüksek kullanıcı kalitesi algısına sahiptir. Geleneksel tavsiye sistemlerinde yeni eklenen öğeler ile ilgili daha önce yapılmış herhangi bir kullanıcı değerlendirmesi bulunmadığı için bu öğelerin öneri olarak sunulma ihtimali düşük olmaktadır. Adaptif tavsiye sistemlerinde ise yeni eklenen öğelerin içerikleri ile sürekli olarak güncellenen kullanıcı modelleri arasında eşleştirmeler yapılmaktadır. Bu sayede yeni eklenen öğeler ile sunulan önerilerin kalitesini ve çeşitliliğini arttırmak hedeflenmektedir [29].

3.2. Dinamik Kullanıcı Profilleri

Gerçek hayat tavsiye sistemlerinde, kullanıcı değerlendirmelerinde yaşanan değişimlere bağlı olarak kullanıcı profilleri de dinamik olarak değişim göstermektedir. Örnek olarak çevrimiçi müzik hizmeti sunan bir Web sitesi senaryosu düşünüldüğünde, tavsiye sistemi kullanıcılarına geçmişte yapmış oldukları etkileşimlere dayalı olarak beğenilme olasılığı yüksek olan müzikleri öneri olarak sunmaktadır. Sunulan öneriler kullanıcılar tarafından seçilerek değerlendirme yapılabilir ya da yeni öneriler almak için istekte bulunulabilir. Kullanıcı profilleri,

yapılan seçimlere göre dinamik olarak değiştiği için kullanıcı değerlendirmelerinin sisteme entegre edilerek yeni önerilerin sunulması aşamasında kullanılması gerekmektedir. Aksi takdirde sunulacak yeni önerilerin seçilme oranı düşük olacaktır. Çevrimiçi hizmet sunan mağazalar müşterilerinin bağlılığını arttırmak, daha doğru ve ilgili öneriler sunma hedefindedir. Doğruluk oranında yaşanacak % 1'lik bir artış bile kullanıcılara sunulan öneri listesindeki sıralamada büyük bir değişime sebep olmaktadır [41].

Tavsiye sistemleri, kullanıcı davranışları üzerinde etkisi olabilecek faktörlerin yapılarını, değerlerini ve özelliklerini içeren bilgilere sahip olmaktadır. Tavsiye sistemleri, sahip oldukları dinamik kullanıcı özelliklerine göre tamamen hâkim, kısmen hâkim ve hâkim değil olarak üç farklı kategoriye ayrılmaktadır. Dinamik kullanıcı özelliklerine tamamen hâkim olduğu durumlarda bu bilgiler daha verimli öneriler sunabilmek için kullanılmaktadır [42]. Sistemlerin kullanıcılara belirli ürünleri satın almaları için önerdiğinde satın alma zamanı, kullanıcı beklentisi, üretici firma gibi bilgilere sahip olması daha etkili öneriler oluşturmasını sağlayacaktır [43]. Örneğin çevrimiçi alışveriş hizmeti sunan bir mağaza senaryosu düşünüldüğünde, belirli bir kullanıcının yılın hangi sezonlarında ne tür kıyafetlerle ilgilendiği, hangi üreticilerin ürünlerini beğendiği ve ilgilendiği ürünlerin özellikleri (baskılı tişört ya da yakalı tişört gibi) bilindiğinde daha yüksek doğruluğa sahip öneriler oluşturulabilir. Kısmen hâkim olduğu durumlar ise yapısal özellikler hakkında yeterince bilgiye sahip olunmaması durumlarıdır. Örneğin satın alma zamanı, amaç ya da üretici firma gibi bilgiler mevcuttur ancak kullanıcıların ilgilenebilecekleri ürünlerin yapıları hakkında yeterince bilgi mevcut değildir. Herhangi bir dinamik özellik bilgisine sahip olunmadığı durumlarda ise sunulan öneriler, kullanıcılardan ürünler ile ilgili alınan doğrudan geri bildirimlerden yararlanılarak sunulmaktadır [34].

Tavsiye sistemlerinde kullanıcı profillerinin modellenmesinde kullanılan en verimli yaklaşım, kullanıcı etkileşimlerinden çıkarımlar yapmaktır. Kullanıcı davranışlarının gözlemlenmesi ve gözlenen davranışlardan, kullanıcı profilleri hakkında çıkarımlar yapma sürecine dolaylı geribildirim adı verilmektedir. Dolaylı geribildirimler, kullanıcıların dinledikleri müzikler, görüntüledikleri Web sayfaları ve indirdikleri içerikler yoluyla elde edilebilmektedir [3].


Kullanıcı profillerinin öğrenilmesinde kullanılacak diğer bir yöntem ise kullanıcılar ve sistem arasındaki etkileşim sürecinin kimin kontrolünde olduğunun belirlenmesidir. Olası etkileşim teknikleri insan kontrollü, sistem kontrollü ve karma girişim olarak sınıflandırılmaktadır. Tavsiye sistemleri bağlamında insan kontrollü, kullanıcıların yaptıkları seçimler ve görüntüledikleri içerikler gibi kullanıcı temelli işlemleri ifade etmektedir. Sistem kontrollü ise tavsiye sistemlerinin kullanıcılara değerlendirmeleri için bir öneri listesi sunmasını ifade etmektedir. Karma girişimler ise insan kontrolünün ve sistem kontrolünün birlikte kullanılmasını ifade etmektedir. Etkili bir şekilde tasarlanmış sistem kontrollü yapılarda, insan kontrollü yapılara göre kullanıcı tercihleri daha verimli bir şekilde belirlenebilmektedir. Karma girişimler ise büyük ölçekli Web siteleri için kullanılacak önemli bir seçenek olmaktadır. Karma girişimler ile kullanıcıların sistemi ilk kullanımlarında belirledikleri ilgi alanları dışında kalan ürün grupları filtrelenerek, ilgi duyabilecekleri ürünler öneri olarak sunulabilmektedir [45].

Tavsiye sistemlerinde kullanılan öneri sunma teknikleri, model tabanlı yöntemler ve sezgisel yöntemler olarak iki gruba ayrılabilir. Kullanıcı profillerini öğrenme teknikleri de bu gruplandırmaya dayalı olarak model tabanlı yöntemlerde kullanılan çevrimdışı öğrenme yöntemleri ve sezgisel yöntemlerde kullanılan çevrimiçi öğrenme yöntemleri olarak kategorize edilebilir. Tavsiye sistemlerinin büyük bir bölümü kullanıcılarına gerçek zamanlı olarak adaptif öneriler sunmak amacıyla çevrimiçi öğrenme yöntemlerini kullanırlar ve kullanıcı profillerini dinamik olarak güncellerler. Model tabanlı yöntemlerde ise yaygın olarak makine öğrenmesi teknikleri kullanılmaktadır. Kullanıcı modeller sınıflandırıcılar yardımıyla belirlenmiş olan spesifik kullanıcı sınıflarına atanmaktadır. Bu yöntemin dezavantajı ise her bir öge ve kullanıcı çifti için beğenme ve beğenmeme gibi iki adet sınıf etiketinin bulunmasıdır. Kullanıcıların beğendikleri ürünler pozitif sınıfta, beğenmedikleri ürünler ise negatif sınıfta yer almaktadır. Sınıflandırma yöntemlerinin olasılıksal modeller, yapay sinir ağları, karar ağaçları, birliktelik kuralları ve Bayes ağları gibi yöntemler ile birlikte kullanılarak kullanıcı profilleri oluşturulmasında daha etkili sonuçlar elde edilebilmektedir [42].

Çok boyutlu tavsiye sistemlerinde, bağlamsal bilgiler kullanılarak adaptif bir şekilde kişiselleştirilmiş önerilerin sunulabilmesi için kullanılacak öğrenme modelinin statik olmaması ve kullanıcı tercihlerine göre değişebilmesi gerekmektedir. Ayrıca yeni bağlam parametrelerinin tasarlanan model içine kolayca entegre edilebilmesi gereklidir [33].

Lee ve ark. tarafından 2016 yılında yapılan çalışmada, model tabanlı işbirlikçi filtreleme yöntemlerinin büyük miktardaki veriler karşısında yaşadığı seyreklik ve ölçeklenebilirlik sorunlarıyla başa çıkabilmek için küme elemanlarının yeniden konumlandırılmasını temel alan ölçeklenebilir küme tabanlı işbirlikçi filtreleme yöntemi önerilmiştir. Geliştirilen sistemde ölçeklenebilirlik sorunu, ölçeklenebilir küme tabanlı işbirlikçi filtreleme

yöntemi kullanılarak zaman karmaşıklığının komşuluk oluşturma üzerindeki etkisi azaltılarak aşılmaktadır. Ayrıca kullanıcı ve ürün vektörlerinin, aşamalı bir şekilde öğrenmesi sağlanarak seyreklik sorunları aşılmaya çalışılmıştır. Önerilen yöntem Şekil 6'da görüldüğü gibi birbirleriyle etkileşim halinde olan ölçeklenebilir kümeleme, tavsiye sunma, kullanıcı tercihlerinin tahmini ve öğrenme aşamalarından oluşmaktadır.



Şekil 6. Önerilen yöntemin kavramsal birleşimi

Ölçeklenebilir kümeleme aşamasında kullanıcı/ürün özellik vektörlerine dayalı olarak küme modelleri oluşturulmaktadır. Bu aşama kullanıcı/ürün alt kümelerini üretmek için zaman karmaşıklığını azaltmaktadır. özellik vektörleri kullanıcı profil verileri, ürünlerin meta verileri ve kullanıcı değerlendirmelerinden oluşmaktadır. Bu adım soğuk başlangıç sorunu olarak adlandırılan yeni kullanıcı/ürün problemi çözmek için tasarlanmıştır. Tavsiye sunma adımında, aynı kullanıcı alt kümelerinde bulunan kullanıcıların tercihlerine göre top-N eleman öneri olarak sunulmaktadır. Tercih tahmini adımı hibrit bir yöntem ile kullanıcı değerlendirme matrisindeki seyreklik sorunlarını çözmek için kullanıcıların ve ürünlerin kümelerini kullanarak eksik kullanıcı değerlendirmelerinin tahmin edilmesine dayanmaktadır. Tercih tahmini, kullanıcı odaklı tahmin ve ürün odaklı tahmin olmak üzere iki şekilde yapılmaktadır. Tahmin adımında ilk olarak kullanıcı ve ürünler için benzerlik matrisi oluşturulmaktadır. Matrisin her bir bileşeni için kullanıcılar ve ürünler arasında benzerlikler değerlendirme vektörleri kullanılarak kosinüs benzerliği ile hesaplanmaktadır. İkinci adımda ise Eşitlik 1 kullanılarak ağırlıklandırma yapılmaktadır.

$$p_{a,m}(u) = \bar{R}_a + \frac{\sum_{n \in UC_a} (R_{n,m} - \bar{R}_a) u w_{a,n}}{\sum_{n \in UC_a} u w_{a,n}} \quad (1)$$

$$p_{a,m}(i) = \frac{\sum_{i \in CC_m} (R_{a,i} c w_{m,i})}{\sum_{i \in CC_m} c w_{m,i}}$$

UC_a , a kullanıcıyı içeren kullanıcılar kümesi, CC_m ise m ürününü içeren ürünler kümesidir. $u w_{a,n}$ ve $c w_{m,i}$, a ve n kullanıcıları ile m ve i ürünleri arasındaki benzerlikleri ifade etmektedir. \bar{R}_a , a kullanıcısının ortalama değerlendirme puanlarını, $R_{n,m}$, n kullanıcısının m ürünü için yaptığı değerlendirmeyi ve $R_{a,i}$ a kullanıcısının i ürünü için yaptığı değerlendirmeyi ifade etmektedir. $P_{a,m}(u)$ ve $P_{a,m}(i)$ a kullanıcısı ve i ürünü için kullanıcı odaklı ve ürün odaklı tahmin sonuçlarını göstermektedir. Elde edilen tahmin sonuçları Eşitlik 2 ile hibrit bir yapı kullanılarak birleştirilmiştir.

$$p_{a,m}(\text{hybrid}) = a \times p_{a,m}(u) + (1 - a) \times p_{a,m}(i) \quad (2)$$

$$a = \sigma(CC_m) / (\sigma(UC_a) + \sigma(CC_m))$$

$\sigma(UC_a)$ ve $\sigma(CC_m)$, a kullanıcısı ve m ürününü içeren kümelerin standart sapması, $P_{a,m}(\text{hybrid})$ ise a kullanıcısı ve m ürünü için tahmin edilen değerlendirme puanıdır.

Öğrenme adımı ise kullanıcı ve ürünlerin nitel özelliklerinin belirlenmesindeki zorlukları gidermek için kullanıcı ve ürünlerin özellik vektörlerinin kullanılmasını içermektedir. Bu adımda, kullanıcıların değerlendirmede buldukları ürünler ve kullanıcıların özellik vektörleri arasında Eşitlik 3 kullanılarak karşılıklı tamamlayıcı öğrenme gerçekleştirilmektedir.

$$\begin{aligned}\overrightarrow{UV}_a &= R_{a,m} \times CV_m + (1 - R_{a,m}) \times pre\overrightarrow{UV}_a \\ \overrightarrow{CV}_m &= R_{a,m} \times UV_a + (1 - R_{a,m}) \times pre\overrightarrow{CV}_m\end{aligned}\quad (3)$$

\overrightarrow{UV}_a ve \overrightarrow{CV}_m a kullanıcısı ve m ürünü için özellik vektörlerini ifade etmektedir. Öğrenme adımının son aşamasında ise değerlendirmede bulunan kullanıcılar ve kullanıcıların değerlendirdikleri ürünler için yeniden uygun kümeler seçilmektedir. Test sonuçları, önerilen yöntemin ortalama mutlak hata ve yanıt süresini sırasıyla % 50, 79 ve % 48, 25 geliştirdiğini ortaya koymuştur [46].

Chen ve ark. tarafından 2015 yılında yapılan çalışmada, kullanıcılara kişiselleştirilmiş ve adaptif öneriler sunulabilmek için bağlam bilgileri kullanılarak yeni bir model geliştirilmiştir. Sistemde kullanılan bağlam parametreleri XML dosyaları üzerinde yapılandırılmıştır. XML dosyalarında, farklı bağlam türleri ve kapsamı bulunmaktadır. Örneğin, zaman bir bağlam türüdür ve bu tür sabah, öğleden sonra ve gece gibi farklı içerik değerleri alabilmektedir. Bağlam yapılandırma dosyalarında, her bağlam tipi bir XML düğümü olarak ifade edilmekte ve her bir düğüm içerdiği bağlamın kullanılan değerine ait nitelikler içermektedir. Çalışmada, gerçek veri setleri kullanılarak bağlam değerlerinin otomatik bir şekilde kümelendiği dinamik bir yöntem sunulmuştur. Geliştirilen yöntem, benzer bağlam değerlerinin aynı küme içerisinde olacağı sezgisel düşüncesine dayalıdır. Benzer bağlam değerlerini belirleyebilmek için bağlam değerleri birer vektör olarak gösterilmiş ve benzerlikler geçmiş verilere dayalı olarak hesaplanmıştır. Tablo 2’de her bir kullanıcının, benzer bağlamdaki öğeler için yapmış olduğu ortalama değerlendirmeler görülmektedir.

Tablo 2. Bağlam-Öğ Matrisi

	Öğ ₁	...	Öğ _k
Değ ₁	Değerlendirme ₁₁	...	Değerlendirme _{1k}
...
Değ _k	Değerlendirme _{m1}	...	Değerlendirme _{mk}

Örnek olarak [$Değ_1, Öğ_1$] matrisi, 1. bağlam değeri için 1. Öğ ile ilgili yapılmış değerlendirmelerin ortalama değerini ifade etmektedir. Bağlam vektörleri kullanılarak, k-Means ve benzeri geleneksel kümeleme algoritmaları kullanılarak kümeleme işlemi gerçekleştirilmiştir.

Kullanıcılara tavsiye sunma aşamasında bağlam değerlerinin etkilerini belirleyebilmek için bağlam ağırlıklandırma metodu kullanılmıştır. Ağırlık katsayılarının belirlenmesi için kullanıcı değerlendirmelerinden yararlanılmıştır.

$$cof_t = \frac{1}{|C_t|} \sqrt{\frac{\sum_{i \in I, c_t \in C_t} (ric_t - r_i C_t)^2}{\overline{r_i C_t}}}\quad (4)$$

$$\overline{r_i C_t} = \frac{1}{|C_t|} \sum_{i \in I, c_t \in C_t} r_i c_t$$

$|C_t|$ değeri, C_t bağlamının farklı değerlerinin sayısını, r_{iC_t} ise C_t bağlamındaki i öğesi için kullanıcı değerlendirmelerini ifade etmektedir. C_t bağlamı için ağırlık değeri

$$wc_t = \frac{cof_t}{\sum_{t=1}^m cof_t}, \quad cof_t \neq 0, \quad if\ cof_t = 0 \quad wc_t = \frac{1}{m}\quad (5)$$

eşitliği ile hesaplanmaktadır.

Öneri uzayının n boyutlu olduğu ve bir boyut kullanıcılar, diğer boyutun ise öğeler olduğu varsayılarak u kullanıcısı için ağırlıklandırılmış bağlam matrisi:

$$\sum_{j=1}^m weight_{u,j} = 1\quad (6)$$

eşitliği kullanılarak hesaplanmıştır. Her bir kullanıcı için farklı ağırlık değerleri ile bağlam arasında ilişki kurulmuş ve bağlam bilgileri dinamik olarak kümelendirilmiştir [45].

Pereira ve Hruschka tarafından 2015 yılında yapılan çalışmada, soğuk başlangıç sorunlarını çözmek ve kullanıcı modellerini öğrenmek için işbirlikçi filtreleme ve demografik özelliklere dayalı yöntemler kullanılarak hibrit bir tavsiye sistemi geliştirilmiştir. Geliştirilen SCOAL yöntemi ile eş zamanlı kümeleme ve öğrenmeye dayalı olarak, hakkında herhangi bir değerlendirme bilgisine sahip olunmayan yeni kullanıcılar için soğuk başlangıç sorunlarını ortan kaldırmak hedeflenmiştir. Kullanıcı-film değerlendirme matrisindeki satır (kullanıcı) ve sütunların (ürün) nitelikleri kullanılarak bir tahmin modeli geliştirilmiştir. Kullanıcılar arasındaki benzerlikler, dolaylı öğrenme modelleri tarafından yapılan tahminler dikkate alınarak hesaplanmaktadır. SCOAL, satır ve sütunların niteliklerini, tahmin modelinin öğrenme sürecinde kullanıcı ve filmlerin karakteristiklerini açıklamak için kullanılmaktadır. SCOAL, her bir küme içerisinde farklı tahmin modelleri elde edebilmek için veri matrisini kullanıcılar ve filmler olarak bölmektedir. Geliştirilen sistem soğuk başlangıç sorununu çözmek için minimum hatalı kümeleme, ağırlıklandırılmış tahmin ve dinamik sınıflandırma yapılarını içermektedir. Minimum hatalı kümeleme, kullanıcıların doğru kümelere atanabilmesi (r^*) için kullanıcıların yapacağı en az film değerlendirme sayısını kullanmaktadır.

$$r^* = \arg_r \min \left\{ \sum_{n=1}^N (y_{new,n} - \bar{y}_{new,n})^2 \right\} \quad (7)$$

N , kullanıcıların yapmış olduğu değerlendirme sayısıdır. Ağırlıklandırılmış tahmin, sınıflandırıcı yardımıyla her bir satır kümesi için sınıf olasılık dağılımını tahmin etmektedir. Yeni bir kullanıcı hakkında tahminler yapmak için tek bir satır kümesi seçme yerine tüm kümeler kullanılır ve ağırlıklı ortalaması alınarak bireysel tahminler hesaplanmaktadır. Dinamik sınıflandırma işleminde ise her bir film için bir sınıflandırma modeli oluşturulmaktadır. Bu sayede, sınıf olasılıklarını tahmin etmek için kullanılan veri kümesi, yeni kullanıcıların değerlendirmelerinde herhangi bir farklılık olması halinde dinamik olarak güncellenmektedir [42].

Karahodza ve ark. tarafından 2015 yılında yapılan çalışmada, zamanla değişen kullanıcı tercihlerinin kullanıcı tabanlı işbirlikçi filtreleme yöntemleriyle birlikte kullanımına yönelik yeni bir hibrit sistem sunulmuştur. Farklı ürün kategorileri için kullanıcı tercihlerindeki dinamik değişimler incelenmiş ve tahmin doğruluğunu arttırmak için ağırlık fonksiyonu kullanılmıştır. Geliştirilen sistem temel olarak işbirlikçi filtreleme yöntemleri ile birlikte ürün özellikleri kullanılarak hibrit bir yapıya kavuşturulmuştur. Benzer kullanıcıların yapmış oldukları değerlendirmelerin zaman içerisinde benzer değişiklik göstereceği ve benzer kullanıcıların zaman içerisinde benzer ürün kategorilerine eğilim göstereceği varsayımları temel alınarak yakın zamanda yapılan ürün değerlendirmelerinin ağırlıkları daha yüksek tutulmuştur. Kullanıcılar arasındaki benzerliklerin hesaplanması için Eşitlik 8' de görülen klasik kullanıcı tabanlı işbirlikçi filtreleme yöntemlerinde kullanılan Pearson Correlation Coefficient yöntemi kullanılmıştır.

$$P_{a,u} = \frac{\sum_{i=1}^m (r_{a,i} - r_a) \cdot (r_{u,i} - r_u)}{\sqrt{\sum_{i=1}^m (r_{a,i} - r_a)^2 \cdot \sum_{i=1}^m (r_{u,i} - r_u)^2}} \quad (8)$$

$r_{a,i}$ a kullanıcısının i ürünü ile ilgili yaptığı değerlendirmeyi, $r_{u,i}$ u kullanıcısının i ürünü ile ilgili yaptığı değerlendirmeyi, r_a , a kullanıcısının yaptığı değerlendirmelerin ortalamasını, r_u ise u kullanıcısının değerlendirmelerinin ortalamasını ve m toplam ürün sayısını ifade etmek üzere a ve u kullanıcıları arasındaki benzerlik Eşitlik 8'de görüldüğü gibi hesaplanmıştır. Benzer kullanıcıların zaman içerisinde tercihlerinin benzer değişiklikler göstereceği varsayımına dayanarak, tahmin fonksiyonu:

$$P_{a,u}(i) = \sum_{j=1}^k a_j \cdot P_{a,u}(C_j) \quad (9)$$

a ve u kullanıcıları için, i ürününün ait olduğu kategoriye dayalı olarak modellenmiştir. C_j ürün kategorilerini ifade etmektedir. Klasik işbirlikçi filtreleme yöntemlerinde kullanılan tahmin fonksiyonuna, ürün içerikleri dâhil edilerek;

$$P_{a,i} = r_a + \frac{\sum_{u=1}^n (r_{u,j} - r_u) \cdot P_{a,u}(i)}{\sum_{u=1}^n P_{a,u}(i)} \quad (10)$$

eşitliği elde edilmiştir. Yakın zamanda yapılmış olan değerlendirmelerin ağırlığını daha yüksek tutabilmek için benzer kullanıcıların son zamanlarda yapmış olduğu değerlendirmelerin, aktif a kullanıcısının gelecekteki tercihlerini daha yüksek oranda yansıtacağı varsayımı kullanılmıştır. Bu amaç doğrultusunda yakın kullanıcıların değerlendirmeleri zamana bağımlı bir ağırlık fonksiyonu ile tahmin aşamasında kullanılmıştır.

$$P_{a,i} = r_a + \frac{\sum_{u=1}^n (r_{u,j} - r_u) \cdot P_{a,u}(i) \cdot W(t(r_{u,i}))}{\sum_{u=1}^n P_{a,u}(i)} \quad (11)$$

eşitliğinde $W(t(r_{u,i}))$ ifadesi zamana bağımlı ağırlık fonksiyonunu ifade etmektedir. Bu fonksiyon τ_0 tavsiye zamanı ile u kullanıcısının i ürününü değerlendirdiği zaman arasındaki farka göre hesaplanmaktadır. Ağırlık fonksiyonu:

$$W(t(r_{u,i})) = \exp\left[-(1/\lambda) \cdot (\tau_0 - t(r_{u,j}))\right] \quad (12)$$

Kullanılan ağırlık fonksiyonu $[0, 1]$ aralığında değer almakta ve yakın kullanıcıların değerlendirme zamanına göre monotonik olarak azalmaktadır. Geliştirilen sistemin performansını analiz etmek için ortalama mutlak hata ve ortalama karesel hataların karekökü metrikleri kullanılmış ve işbirlikçi filtreleme yöntemine göre daha başarılı sonuçlar elde edilmiştir [47].

Hong ve ark. tarafından 2014 yılında yapılan çalışmada, işbirlikçi filtreleme yöntemleri için adaptif kümeleme yaklaşımına dayalı yeni bir yöntem sunulmuştur. Çalışmada işbirlikçi filtreleme yöntemlerinde yaşanan seyreklik ve ölçeklenebilirlik sorunları üzerine odaklanılmıştır. Seyreklik sorunu, sistemdeki artan öge sayısı ile birlikte kullanıcı komşuluklarını hesaplamak için gereken puanlanmış öge sayısı oranının düşmesi sonucu ortaya çıkmaktadır. Ölçeklenebilirlik sorunu ise veri setlerindeki büyük veriler üzerinde mevcut algoritmaların performansını değerlendirme aşamasında yaşanmaktadır. Seyreklik ve ölçeklenebilirlik sorunlarının giderilmesi için geliştirilen yöntem dört bölümden oluşmaktadır. Birinci bölüm kullanıcıların ve öğelerin karakteristiklerine göre kümelenmesi ve her bir kümelemede tercihlerin hesaplanmasıdır. İkinci bölüm kullanıcı tercihleri ve kümeler kullanılarak önerilerin oluşturulmasıdır. Üçüncü bölüm kümelemeye bağlı olarak kullanıcı tercihlerinin tahmin edilmesidir. Dördüncü bölüm ise kullanıcı geribildirimlerinin kullanıcı ve özellik vektörlerine yansıtılmasıdır.

Geliştirilen adaptif kümeleme algoritması ise üç adımdan oluşmaktadır. İlk adımda kullanıcı ve öğelerin meta verilerine dayalı olarak kümeleme işlemi yapılmaktadır. Kümeleme için Expectation-Maximization algoritması kullanılmıştır. Maksimum olasılıkların belirlenmesi için ise Gaussian-Bayesian olasılık modeli ve kullanıcı değerlendirme puanları kullanılmıştır. İkinci adımda her bir kullanıcı için öge kümelerine bağlı olarak hesaplamalar yapılmaktadır.

$$CP_{i,j} = \sum_I \sum_n^{N_{u_i, c_i}} W_{Uc_i, u_1} W_{cc_j, c_n} R_{u_1 c_n} \quad (13)$$

eşitliğinde W_{u_i, u_1} , u_1 kullanıcısının Uc_i kümesinde olma olasılığını ifade etmektedir. W_{cc_j, c_n} , c_n ögesinin Cc_j kümesine ait olma olasılığını ifade etmektedir. $R_{u_1 c_n}$ ise u_1 kullanıcısının, c_n ögesi ile ilgili yapmış olduğu değerlendirme puanını ve $CP_{i,j}$ ise i kullanıcısının j öge kümesinden yaptığı tercihleri ifade etmektedir. Üçüncü adım ise kullanıcı-öge tercih tahminlerinin oluşturulmasıdır.

$$P(c_j | u_i)(predicted) = P(Uc_i | u_i)P(IC_m | i_j)CP_{i,m}R_{i,j} \quad (14)$$

eşitliğinde Uc_i , i kullanıcısının ait olduğu kümeyi, IC_m ise j ögesinin ait olduğu kümeyi ifade etmektedir. $P(Uc_i | u_i)$ i kullanıcısının Uc_i kümesine ait olma olasılığını, $P(IC_m | i_j)$ j ögesinin IC_m kümesine ait olma olasılığını, $CP_{i,m}$ Uc_i kümesi ile IC_m kümesi arasındaki küme tercihlerini ve $R_{i,j}$ ise i kullanıcısının j öge üzerinde

yapmış olduğu değerlendirme puanını göstermektedir. $P(c_j | u_i)$ (*predicted*) ise tahmin edilen i . kullanıcının j . öge ile ilgili yapacağı değerlendirme sonucunu göstermektedir.

Geliştirilen sistemde bulunan öğrenme modülü, kullanıcı ve öge vektörlerinin karakteristiklerine göre kullanıcı tercihlerinin öğrenilmesini sağlamaktadır. $F_{a,m}$ a kullanıcısının m ürünü ile ilgili vermiş olduğu geribildirimleri göstermektedir. $\partial(F_a)$ ise a kullanıcısının geribildirimlerinin ortalamasını, $\overline{UV_a} \overline{CV_m}$ ise her bir a kullanıcısı ve m ögesi için karakteristik vektörleri ifade etmektedir. Öğrenme modeli,

$$\text{Pr } eR_{a,m} = \frac{F_{a,m} - \overline{F_a}}{\partial(F_a)} \quad (15)$$

eşitliği her bir kullanıcı için farklı olan kullanıcı geribildirimlerinin normalize edilmesini sağlamaktadır. Çalışmanın sonuçlarının doğrulanması için sonuçlar aynı ortamlarda farklı yöntemler ile karşılaştırılmıştır. Sonuçlar, önerilen yöntemin yanıt süresinin diğer yöntemler ile karşılaştırıldığında ortalama % 48.25, sunulan tavsiyelerin doğruluğu açısından ise % 50.79 daha yüksek olduğunu göstermiştir [48].

Rana ve Jain tarafından 2014 yılında yapılan çalışmada, zaman içerisinde değişen kullanıcı tercihleri için evrimsel kümeleme yöntemine dayalı dinamik bir tavsiye sistemi geliştirilmiştir. Geliştirilen kümeleme algoritması zaman içinde değişen kullanıcı tercihlerine göre benzer kullanıcılar kümesini dinamik olarak değiştirmektedir. Geliştirilen yöntem komşulukların hesaplanması ve komşuluklara göre kullanıcılara öneri olarak sunulacak ürünler için tahmin oluşturma aşamalarından oluşmaktadır. Komşulukların hesaplanması, kullanıcı ve ürün kümelerinin belirlenmesini ifade etmektedir. k kullanıcı kümelerinin sayısı belirlendikten sonra evrimsel kümeleme işlemi gerçekleştirilmiştir. Kullanıcı kümelerinden elde edilen $\{c_1, c_2, \dots, c_k\}$ sendroidleri m boyutunda ve ürünleri temsil eden vektörlerdir.

$c_i = (R_{ci,a1}, R_{ci,a2}, \dots, R_{ci,am})$ olmak üzere $R_{ci,aj}$, c_i cendroid vektöründeki a_j ürününün kullanıcılar tarafından verilen ortalama değerlendirme puanını göstermektedir. Belirli bir kullanıcı için komşulukları hesaplamak için Pearsons Correlation Coefficient yöntemi kullanılmıştır. Her bir kullanıcı ürün ikilisi (u_t, a_t) için değerlendirme puanı tahmini R_{u_t, a_t} için ilk olarak Pearsons Correlation Coefficient yöntemi ile yakın kullanıcılar belirlenmiştir. I kümesi, aktif kullanıcı ile birlikte aynı ürünleri değerlendiren kullanıcıların ($1, \dots, i$) kümesi olmak üzere;

$$S_{u_t, ci} = \frac{\sum_{a \in I} (R_{u_t, a} - RA_{u_t}) (R_{ci, a} - RA_{ci})}{\sqrt{\sum_{a \in I} ((R_{u_t, a} - RA_{u_t})^2 (R_{ci, a} - RA_{ci})^2)}} \quad (16)$$

eşitliği kullanılarak yakın kullanıcılar belirlenmiştir.

- (1) $R_{u_t, a}$, (u_t, a_t) kullanıcı ve ürün çifti için tahmin edilen değerlendirme puanı,
 - (2) RA_{u_t} , u kullanıcısının t zaman içindeki ortalama değerlendirme puanını,
 - (3) $R_{ci, a}$, c_i centroid vektörü için tahmin puanlarını,
 - (4) RA_{ci} ise c_i centroid vektörü için ortalama değerlendirme puanlarını göstermektedir.
- İkinci adımda ise ağırlıklandırma kullanılarak tahminler hesaplanmıştır.

$$R_{u_t, at} = RA_{u_t} + \frac{\sum_{i=1}^k (R_{ci, at} - RA_{ci}) S_{u_t, ci} \cdot f_{ui}^a(t)}{\sum_{i=1}^l S_{u_t, ci} \cdot f_{ui}^a(t)} \quad (17)$$

eşitliğinde $S_{u_t, ci}$, ilk adımda hesaplanan değer k ise kümelerin (komşuların) sayısıdır [49].

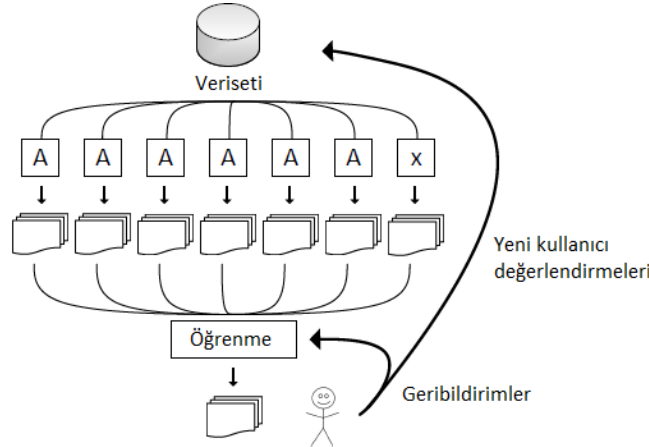
Bharath ve ark. tarafından 2014 yılında yapılan çalışmada, dinamik olarak değişen kullanıcı özellikleri ve özellik çıkarımına dayalı yeni bir tavsiye sistemi sunulmuştur. Çalışmada soğuk başlangıç sorununu çözmek için kullanıcılar yaş gruplarına göre sınıflandırılmıştır. özellik çıkarma yöntemleri kullanıcı profillerinin ve ürünlerinin içeriklerinin belirlenmesi için kullanılmıştır. Kullanıcılara e-posta yoluyla öneriler sunmak için, yaş, kullanıcı ilgisi ve benzer kullanıcıların seçimleri temel alınmaktadır ve bu sayede soğuk başlangıç sorunlarının üstesinden gelmek hedeflenmektedir. Kullanıcı tercihleri ve ürünlerin popülariteleri zaman içinde değiştiği için yapılmış olan kullanıcı değerlendirmeleri, değerlendirme zamanına göre ağırlıklandırılmıştır. Değişim durumunu belirleyebilmek için örnek seçimi, zaman fonksiyonu ve topluluk öğrenme yöntemleri kullanılmıştır. Zaman

serisi analizi ile daha eski değerlendirmelerin öngörü özelliklerine etkisinin daha düşük olması gerektiği için ağırlık değeri daha düşük tutulmuştur. Kullanıcı ilgilerini farklı aşamalarda belirleyebilmek için yapılan değerlendirme kümeleri ikinci bir R_s altkümüne bölünmüştür. Elde edilen altkümelerin büyüklüğü çoklu bölümlenme yöntemleri ile analiz edilmiş ve analiz sonuçları ile veri yoğunlukları elde edilmiştir. Elde edilen bu özellikler ile lineer ve öğrenilebilir bir yöntem geliştirilmiştir. $R_{j,k}$, u_j kullanıcısının i_k ürünü ile ilgili $T_{j,k}$ zamanda yapmış olduğu değerlendirmeyi ifade etmek üzere geliştirilen adaptif lineer model Eşitlik 18' deki gibi formüle edilmektedir. $\alpha \geq 0, \beta \geq 0$ olmak üzere;

$$R_{j,k} = \sum_s \sum_d (\alpha_{s,d} + \beta(\#R_s^d)) b_{u_j}(s) b_{i_k}(s) fea_{s,d} \quad (18)$$

eşitliği ile dinamik bir şekilde öneriler sunabilmek için kullanıcıların yaşı, dinamik özellik çıkarımı, değerlendirmelerin ağırlıkları gibi parametreler göz önüne alınmıştır. Kullanıcıların yaş bilgileri ve dinamik özellik çıkarımı, aynı yaş grubundan benzer kullanıcıların seçimlerinin sorgulanması için kullanılmış ve yeni kullanıcılar için soğuk başlangıç sorunu çözülmüştür. Kullanıcı tercihlerinin zaman içerisinde değişiklik gösterdiği düşünülerek değerlendirme puanları eski ve yeni ayrı ayrı yapılarak ağırlıklandırılmıştır [50].

Dooms tarafından 2013 yılında yapılan çalışmada, dinamik öğrenme stratejilerini, gerçek zamanlı kullanıcı geribildirimleri ile birleştirerek kullanıcı tercihlerindeki dinamikleri öğrenilebilir hibrit bir sistem geliştirilmiştir. Geliştirilen sistem Şekil 7'de görüldüğü gibi paralel olarak kullanıcı geribildirimlerini ve değerlendirmelerini işleyen bir öğrenme modülünden oluşmaktadır.



Şekil 7. Geliştirilen dinamik öğrenme sistemi

Sistem, dinamik olarak birçok algoritma tarafından yapılan tahminleri ve gerçek zamanlı olarak elde ettiği kullanıcı geribildirimlerini öğrenme aşamasında birleştirmektedir. α kullanılan algoritmalar, γ her bir α algoritmasının ağırlık faktörü ve g her bir α algoritmasının tahmin değerini göstermek üzere, u kullanıcısı ve i öğesi için tahmin değeri Eşitlik 19 kullanılarak hesaplanmıştır.

$$g(u, i) = \gamma \alpha_1(u) * g_{\alpha_1}(u, i) + \dots + \gamma \alpha_n(u) * g_{\alpha_n}(u, i) \quad (19)$$

$f(\gamma(u))$ amaç fonksiyonu ile algoritmaların ağırlıkları optimize edilmiştir. Amaç fonksiyonu ile tavsiye sistemlerinin değerlendirilmesinde kullanılan metriklerden karesel hataların karekökü değerini minimize ederek hassasiyet (precision) ve duyarlılık (recall) parametrelerinin maksimize edilmesi hedeflenmiştir [35].

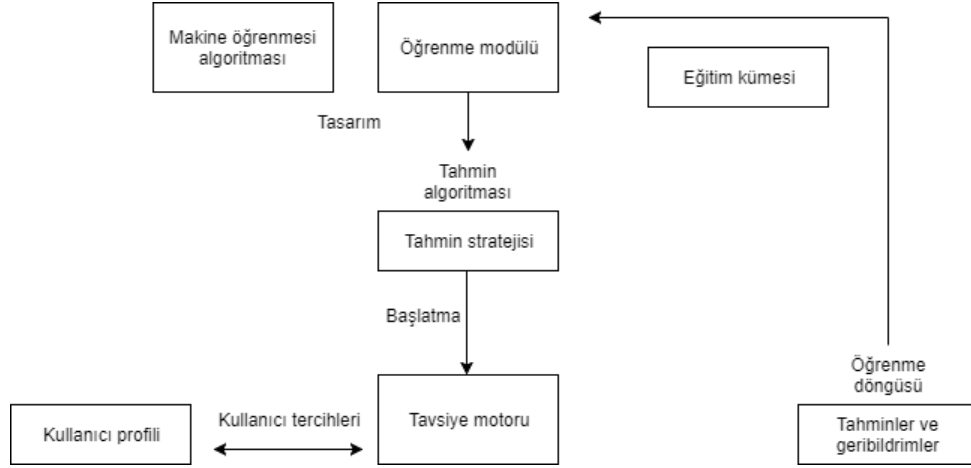
Aksel ve Birtürk tarafından 2010 yılında yapılan çalışmada, tahmin tekniklerinin performansını arttırmak için adaptif tahmin stratejilerinin uygulamanın çalışma zamanına dâhil edildiği hibrit bir tavsiye sistemi geliştirilmiştir. Geliştirilen yöntem, hangi durumlarda hangi tahmin algoritmasının kullanılması gerektiğini belirleyen ve bir denetimli öğrenme modülü ile öğrenilebilir adaptif tahmin stratejisi yaklaşımını kullanmaktadır.

Çalışmada farklı tahmin stratejileri geliştirebilmek için Duine yapısı kullanılmıştır. Duine, kullanıcılarına kendi tahmin stratejilerini geliştirme olanağı sağlayan açık kaynak kodlu bir yazılımdır. Geliştirilen AdaRec sisteminde kullanıcıların ve ürünlerin özelliklerini analiz ederek öğrenmek için makine öğrenmesi teknikleri kullanılmıştır. Sistem başlangıçta belirli bir tahmin stratejisi kullanmaktadır. Kullanıcı geribildirimleri, kullanıcı ve öğe

çiftlerinin durumu (yeni kullanıcı, yeni ürün gibi) ve mevcut içeriklere göre hangi algoritmanın (işbirlikçi filtreleme, içerik tabanlı filtreleme gibi) kullanılacağına adaptif olarak karar verilmektedir.

Tahmin stratejileri oluşturulurken MovieLens veritabanındaki özellik-değer kombinasyonları kullanılmıştır. özellik değer kombinasyonları, herhangi bir öğenin tıklanma sayısı, herhangi bir öğeyi tıklayan benzer kullanıcıların sayısı, benzerlik ölçümlerine göre elde edilen benzer öğelerin sayısı, kullanıcıların tıkladığı öğelerin kategorileri (film için korku, komedi, dram gibi) ve kullanıcıların tıkladığı öğelerin konularındır. Bu özellik değer kombinasyonları karar ağaçları kullanılarak top N Deviation, User Average, Social Filtering, CBR, Main Genre LMS, Sub Genre LMS ve Information Filtering tahmin stratejilerinin belirlenmesinde kullanılmaktadır.

Geliştirilen AdaRec sistemi, Şekil 8'de görüldüğü gibi temel olarak tavsiye motoru ve öğrenme modülü bileşenlerinden oluşmaktadır.



Şekil 8. AdaRec sisteminin mimarisi

Tavsiye sistemleri kullanıcıların geçmiş değerlendirmelerine bağlı olarak, uygun ürün ve hizmetlerin sunulmasını hedeflemektedir. Tavsiye sistemlerinde adaptiflik kavramı ise bir veya birden fazla parametre kullanılarak tasarlanmış, bağımsız ve gelişebilen sistemleri ifade etmektedir. Kullanıcı tercihlerindeki değişimleri depolayarak kullanıcılardan gerek doğrudan gerekse dolaylı olarak alınan geribildirimler ile kullanıcı profillerini öğrenerek öneri listelerini güncelleyebilen sistemler adaptif ve öğrenilebilir sistemlerdir. Tavsiye sistemlerinde kullanıcı dinamiklerine uyum sağlamak ve değişen kullanıcı tercihlerine göre önerilerin sunulması, önerilerin kalitesi ve doğruluğu açısından önemlidir.

Tablo 3. Adaptif ve öğrenilebilir tavsiye sistemleri ile ilgili yapılmış çalışmalar

Yazar	Kullanılan yöntem	İyileştirilen yöntem	Referans
Lee ve ark. (2016)	Ölçeklenebilir kümeleme	İşbirlikçi filtreleme yöntemi	[46]
Chen ve ark. (2015)	Ağırlıklandırılmış bağlam matrisi	Bağlama bağımlı yöntemler	[45]
Pereira ve Hruschka (2015)	Eş zamanlı kümeleme ve öğrenme	İşbirlikçi filtreleme yöntemi	[42]
Karahodza ve ark. (2015)	Zamana bağlı kullanıcı değerlendirmeleri	İşbirlikçi filtreleme yöntemi	[47]
Hong ve ark. (2014)	Adaptif kümeleme	İşbirlikçi filtreleme yöntemi	[48]
Rana ve Jain (2014)	Evrimsel kümeleme	İşbirlikçi filtreleme yöntemi	[49]
Bharath ve ark. (2014)	özellik çıkarımı, değerlendirme puanı ağırlıklandırma	İşbirlikçi filtreleme yöntemi	[50]
Dooms (2013)	Dinamik öğrenme	İşbirlikçi filtreleme yöntemi	[35]
Aksel ve Birtürk (2010)	Adaptif tahmin	İşbirlikçi filtreleme, içerik tabanlı filtreleme	[51]

Klasik tavsiye sistemi yaklaşımları üzerinden geliştirilen yeni yöntemler Tablo 3'te görülmektedir. İncelenen çalışmalar, zamana bağlı olarak değişen kullanıcı tercihleri ve ürün popülaritelerine göre adaptif olarak sundukları öneri listelerini güncellemektedir. Komşuluk kümelerinin adaptif bir şekilde yeniden düzenlenmesi, kullanıcı değerlendirmelerinin ağırlıklandırılması, kullanıcı dinamiklerinin öğrenilmesi gibi yöntemler kullanılarak kullanıcı tercihlerindeki değişimin öneri sunma sürecine dâhil edilmesi hedeflenmiştir. Klasik tavsiye sunma algoritmaları ile birlikte makine öğrenmesi ve yapay zekâ teknikleri kullanılarak adaptif öğrenme

modelleri oluşturulabilmektedir. Dinamik olarak kullanıcı ve ürün özelliklerinin öğrenildiği öğrenme modülü, adaptif olarak tahmin stratejisinin geliştirilebildiği tahmin modülü ve komşuluk kümelerinin dinamik olarak güncellenebildiği kümeleme yöntemleri ile oluşturulan hibrit sistemlerde sunulan önerilerin kalitesi ve doğruluk oranı klasik yöntemlere göre daha yüksek olacaktır.

4. Tartışma ve Sonuç

Tavsiye sistemleri, büyük miktarlardaki veriler arasından kullanıcıların kendileri için faydalı olabilecek ürünleri seçmelerine yardımcı olmayı hedefleyen sistemlerdir. Tavsiye sistemlerinde, işbirlikçi filtreleme, içerik tabanlı filtreleme ve demografik filtreleme gibi farklı yöntemler kullanılmaktadır. Bu yöntemlerin çoğu ise öneri sunma aşamasında statik yaklaşımlar kullanılmaktadır. Gerçek dünya uygulamalarında kullanılan geleneksel tavsiye sistemleri ürünler ve kullanıcılar arasındaki ikili ilişkilere dayanmaktadır. Kullanıcılardan ürünler ile ilgili doğrudan ya da dolaylı olarak alınan geribildirimler vasıtasıyla kullanıcı profilleri oluşturulmakta ve geçmişte yapmış oldukları seçimler temel alınarak öneriler sunulmaktadır. Kullanıcı tercihlerinin zaman içinde değişmeyeceği varsayımına dayanılmaktadır. Ancak kullanıcıların sistem ve birbirleri ile olan etkileşimlerinin, öneri olacak sunulacak ürünlerin içeriklerinin ve bağlamlarının sürece dâhil edilmesi gerekmektedir.

Bu çalışmada kullanıcı tercihlerindeki dinamik değişimlere göre mevcut kullanıcı profil modellerinin güncellenmesi ve kullanıcı tercihlerinin öğrenilmesi temeline dayanan tavsiye sistemleri incelenmiştir. Değişen dinamiklere göre kullanıcı profil modellerinin öğrenilmesi, klasik işbirlikçi filtreleme yöntemlerinde kullanılan yakın kullanıcılar kümesinin adaptif bir şekilde güncellenmesi ve tahmin stratejilerinin dinamik olarak güncellenmesine dayalı hibrit yöntemlerin daha yüksek başarı oranları elde ettiği ortaya konulmuştur. İncelenen çalışmalar, klasik yöntemler ile birlikte veri madenciliği, makine öğrenmesi ve yapay zekâ teknikleri kullanılarak hibritleştirilmiştir. İncelenen tavsiye sistemlerinin, geleneksel sistemlerin yaşadığı seyreklik, ölçeklenebilirlik ve soğuk başlangıç gibi sorunları büyük ölçüde ortadan kaldırdığı ve sunulan önerilerin daha yüksek doğruluk oranına sahip olduğu görülmüştür.

Kaynakça

- [1] Lu, J., Wu, D., Mao, M., Wang, W., and Zhang, G. 2015. Recommender system application developments: a survey. *Decision Support Systems*, 74, pp. 12-32.
- [2] Park, D. H., Kim, H. K., Choi, Y. and Kim, J. K. 2012. A literature review and classification of recommender systems research. *Expert systems with applications*, 39(11), 10059–10072.
- [3] Bobadilla, J., Ortega, F., Hernando, A. and Gutiérrez, A. 2013. Recommender systems survey. *Knowledge-based systems*, 46, pp. 109–132.
- [4] Hernando, A., Bobadilla, J., and Ortega, F. 2016. A non negative matrix factorization for collaborative filtering recommender systems based on a Bayesian probabilistic model. *Knowledge-Based Systems*. 97, pp. 188-202.
- [5] Wu, M. L., Chang, C. H., and Liu, R. Z. 2014. Integrating content-based filtering with collaborative filtering using co-clustering with augmented matrices. *Expert Systems with Applications*, 41(6), pp. 2754-2761.
- [6] Porcel, C., Tejada-Lorente, A., Martínez, M. A., and Herrera-Viedma, E. 2012. A hybrid recommender system for the selective dissemination of research resources in a technology transfer office. *Information Sciences*, 184(1), pp. 1-19.
- [7] Beel, J., Langer, S., Genzmehr, M., Gipp, B., Breiting, C., & Nürnberger, A. 2013. Research paper recommender system evaluation: a quantitative literature survey. In *Proceedings of the International Workshop on Reproducibility and Replication in Recommender Systems Evaluation*. pp. 15-22.
- [8] Anaya, A. R., Luque, M., and Peinado, M. 2016. A visual recommender tool in a collaborative learning experience. *Expert Systems with Applications*, 45, pp. 248-259.
- [9] Choi, Y. K. and Kim, S. K. 2014. An auxiliary recommendation system for repetitively purchasing items in e-commerce. *Big data and smart computing (BIGCOMP)*, 39(11), pp. 10059–10072.
- [10] Tejada-Lorente, A., Porcel, C., Peis, E., Sanz, R., and Herrera-Viedma, E. 2014. A quality based recommender system to disseminate information in a university digital library. *Information Sciences*, 261, 52-69.
- [11] Amini, M., Nasiri, M., and Afzali, M. 2014. Proposing a New Hybrid Approach in Movie Recommender System. *International Journal of Computer Science and Information Security*, 12(8), 4-45.
- [12] Christidis, K., and Mentzas, G. 2013. A topic-based recommender system for electronic marketplace platforms. *Expert Systems with Applications*, 40(11), pp. 4370-4379.
- [13] Zhang, Z., Lin, H., Liu, K., Wu, D., Zhang, G. and Lu, J. (2013) A hybrid fuzzy-based personalized recommender system for telecom products/services, *Information Sciences*. 235, 117–129.
- [14] Levandoski, J. J., Sarwat, M., Eldawy, A., and Mokbel, M. F. 2012. Lars: A location-aware recommender system. In *Data Engineering (ICDE), 2012 IEEE 28th International Conference on*. pp. 450-461.
- [15] Bostandjiev, S., O'Donovan, J., and Höllerer, T. 2012. TasteWeights: a visual interactive hybrid recommender system. In *Proceedings of the sixth ACM conference on Recommender systems*. pp. 35-42.

- [16] Desrosiers, C. and Karypis, G. 2011. A Comprehensive Survey of Neighborhood-based Recommendation Methods. *Recommender systems handbook*. İngiltere Springer. 107-144.
- [17] Zheng, N., and Li, Q. 2011. A recommender system based on tag and time information for social tagging systems. *Expert Systems with Applications*, 38(4), pp. 4575-4587.
- [18] Shuib, N. L. M., Baiti, N., Normadhi, A. B., Alias, L. F. H. B. M., and Binti, N. S. 2015. Collaborative Recommender System: A Review. In *International Conference On Advances In Computing, Electronics, And Electrical Technology*. Pp.126-130.
- [19] Almazro, D., Shahatah, G., Abdulkarim, L., Kherees, M., Martinez, R., and Nzoukou, W. 2010. A survey paper on recommender systems. arXiv preprint arXiv:1006.5278.
- [20] Prasad, R. V. V. S. V., and Kumari, V. V. 2012. A categorical review of recommender systems. *International Journal of Distributed and Parallel Systems*, 3(5), 73.
- [21] Beel, J., Gipp, B., Langer, S., and Breitingner, C. 2015. Research-paper recommender systems: a literature survey. *International Journal on Digital Libraries*, pp. 1-34.
- [22] Tan, S., Bu, J., Chen, C., and He, X. 2011. Using rich social media information for music recommendation via hypergraph model. In *Social media modeling and computing*. pp. 213-237.
- [23] Panniello, U. 2014. How to use recommender systems in e-business domains. *Webology*, 11(2), pp 1-23.
- [24] Zhang, Z., Lin, H., Liu, K., Wu, D., Zhang, G., and Lu, J. 2013. A hybrid fuzzy-based personalized recommender system for telecom products/services. *Information Sciences*, 235, pp. 117-129.
- [25] Santos, O. C., Boticario, J. G., and Pérez-Marín, D. 2014. Extending web-based educational systems with personalised support through user centred designed recommendations along the e-learning life cycle. *Science of Computer Programming*, 88, pp. 92-109.
- [26] Yang, W. S., & Hwang, S. Y. 2013. iTravel: A recommender system in mobile peer-to-peer environment. *Journal of Systems and Software*, 86(1), pp. 12-20.
- [27] Lucas, J. P., Luz, N., Moreno, M. N., Anacleto, R., Figueiredo, A. A., & Martins, C. 2013. A hybrid recommendation approach for a tourism system. *Expert Systems with Applications*, 40(9), pp. 3532-3550.
- [28] Nguyen, T. T. S., Lu, H. Y., and Lu, J. 2014. Web-page recommendation based on web usage and domain knowledge. *Knowledge and Data Engineering, IEEE Transactions on*, 26(10), pp. 2574-2587.
- [29] Lü, L., Medo, M., Yeung, C. H., Zhang, Y. C. and Zhou, T. 2012. Recommender systems. *Physics reports*, 519(1). pp. 1-49.
- [30] Extrand, M. D. and Riedl, J. T. 2010. Collaborative filtering recommender systems. *Foundations and trends in human-computer interaction*, 4(2). pp. 81-173.
- [31] Burke, R. 2010. Evaluating the dynamic properties of recommendation algorithms. In *Proceedings of the fourth ACM conference on Recommender systems*. pp. 225-228.
- [32] Dey, A. K. 2001. Understanding and using context. *Personal and ubiquitous computing*. 5(1), pp. 4-7.
- [33] Chen, B., Yu, P., Cao, C., Xu, F., and Lu, J. 2015. ConRec: a Software Framework for Context-aware Recommendation based on Dynamic and Personalized Context. 2015 IEEE 39th Computer Software and Applications Conference (COMPSAC). 2. pp. 816-821.
- [34] Rashid, A. M., Karypis, G., and Riedl, J. 2008. Learning preferences of new users in recommender systems: an information theoretic approach. *ACM SIGKDD Explorations Newsletter*, 10(2), pp. 90-100.
- [35] Dooms, S. 2013. Dynamic generation of personalized hybrid recommender systems. In *Proceedings of the 7th ACM conference on Recommender systems*. pp. 443-446.
- [36] Buder, J., and Schwind, C. 2012. Learning with personalized recommender systems: A psychological view. *Computers in Human Behavior*, 28(1), pp. 207-216.
- [37] Ryu, S., Han, K. H., Jang, H., and Eom, Y. I. 2010. User adaptive recommendation model by using user clustering based on decision tree. 2010 IEEE 10th International Conference in Computer and Information Technology (CIT). pp. 1346-1351.
- [38] Lathia, N., Hailes, S., Capra, L., and Amatriain, X. 2010. Temporal diversity in recommender systems. In *Proceedings of the 33rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. pp. 210-217.
- [39] Bendoly, E. 2013. Real-time feedback and booking behavior in the hospitality industry: Moderating the balance between imperfect judgment and imperfect prescription. *Journal of Operations Management*. 31(1), pp. 62-71.
- [40] Nguyen, T. T., Hui, P. M., Harper, F. M., Terveen, L., and Konstan, J. A. 2014. Exploring the filter bubble: the effect of using recommender systems on content diversity. In *Proceedings of the 23rd international conference on World wide web*. pp. 677-686.
- [41] Rana, C., and Jain, S. K. 2015. A study of the dynamic features of recommender systems. *Artificial Intelligence Review*, 43(1), pp. 141-153.
- [42] Pereira, A. L. V., and Hruschka, E. R. 2015. Simultaneous co-clustering and learning to address the cold start problem in recommender systems. *Knowledge-Based Systems*, 82, pp. 11-19.
- [43] Chang, N. 2012. A Dynamic Prediction Model for Recommender Systems based on Doubly Structural Network. *International Journal of Engineering Innovation and Management*, 2. pp. 1-8.

- [44] He, C., Parra, D., and Verbert, K. 2016. Interactive recommender systems: A survey of the state of the art and future research challenges and opportunities. *Expert Systems with Applications*. 56, pp. 9-27.
- [45] Chen, L., Chen, G., and Wang, F. 2015. Recommender systems based on user reviews: the state of the art. *User Modeling and User-Adapted Interaction*,25(2), pp. 99-154.
- [46] Lee, O. J., Hong, M. S., Jung, J. J., Shin, J., and Kim, P. 2016. Adaptive Collaborative Filtering Based on Scalable Clustering for Big Recommender Systems. *Acta Polytechnica Hungarica*, 13(2). pp. 179-194.
- [47] Karahodza, B., Donko, D., and Supic, H. 2015. Temporal dynamics of changes in group user's preferences in recommender systems. *IEEE Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 2015 38th International Convention on. pp. 1262-1266.
- [48] Hong, M. S., Lee, O. J., and Jung, J. 2014. Adaptive Clustering for Scalable Collaborative Filtering in Recommender Systems. *The 3rd International Conference on Smart Media and Applications*. pp. 31-34.
- [49] Rana, C., and Jain, S. K. 2014. An evolutionary clustering algorithm based on temporal features for dynamic recommender systems. *Swarm and Evolutionary Computation*. 14. pp. 21-30.
- [50] Bharath, R., Thanigaivel, K., Alfahath, A. and Prasanth, T. 2014. Feature Extraction Based Dynamic Recommendation for Analogous Users. *International Journal of Computer Science and Information Technologies*. 5 (2), 1358-1362.
- [51] Aksel, F, and Birtürk, A. 2010. An adaptive hybrid recommender system that learns domain dynamics. *International Workshop on Handling Concept Drift in Adaptive Information Systems: Importance, Challenges and Solutions (HaCDAIS-2010)* at the European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases.