

Kullanıcı Profili ve İşbirlikçi Filtreleme Tabanlı Otel Öneri Sistemi

Hotel Recommendation System Based on User Profiles and Collaborative Filtering

Bekir Berker Türker
Veri Bilimi ve Analitiği Bölümü
Etstur
İstanbul, Türkiye
berker.turker@etstur.com

Resul Tugay
Bilgisayar ve Bilişim Fakültesi
İstanbul Teknik Üniversitesi
İstanbul, Türkiye
tugayr@itu.edu.tr

İpek Kızıl
Bilgisayar Mühendisliği Bölümü
Koç Üniversitesi
İstanbul, Türkiye
ikizil15@ku.edu.tr

Şule Ögüdücü
Bilgisayar ve Bilişim Fakültesi
İstanbul Teknik Üniversitesi
İstanbul, Türkiye
sgunduz@itu.edu.tr

Öz—Günümüzde, çevrimiçi rezervasyon sistemleri sundukları sayısız imkanlarla acentaların yerini almaktadır ve birçok insan gezi planlarını çevrimiçi rezervasyon sistemleri üzerinden yapmaktadır. Ancak insanlar ne zaman, nereye ziyaret edeceğine karar vermek için çok fazla zaman harcamak zorunda kalmaktadır. Ayrıca, çevrimiçi sistemlerdeki bu sayısız olasılıklar, kullanıcıların diğerlerinden daha ilginç teklifleri ayırt etmelerini zorlaştırmakta ve daha cazip teklifler farkedilmeden gidebilmektedir. Bu bağlamda öneri sistemleri, insanların karar verme sürecini kolaylaştırabilecek en iyi sistemlerdir. Geleneksel olarak öneri sistemleri içerik tabanlı ve işbirlikçi filtreleme yaklaşımları kullanarak kullanıcıların en uygun ürün ve hizmetleri bulmalarına yardımcı olur. Bu her iki yöntemin dezavantajları olsa da, her ikisinin birleştirilmesiyle oluşturulacak yeni bir melez sistemle öneri sisteminin kalitesi artırılabilir. Bu çalışmada, müşterilerin gereksinimi olan oteli en uygun şekilde öneren ve onları zaman kaybından kurtaran içerik tabanlı ve işbirlikçi filtreleme yaklaşımlarının birleştirilmesiyle yeni bir melez otel öneri sistemi geliştirilmiştir.

Anahtar Sözcükler—öneri sistemleri, otel önerileri, melez model, işbirlikçi filtreleme, içerik filtreleme.


Abstract—Nowadays, people start to use online reservation systems to plan their vacations since they have vast amount of choices available. Selecting when and where to go from this large-scale options is getting harder. In addition, sometimes consumers can miss the better options due to the wealth of information to be found on the online reservation systems. In this sense, personalized services such as recommender systems play a crucial role in decision making. Two traditional recommendation techniques are content-based and collaborative filtering. While both methods have their advantages, they also have certain disadvantages, some of which can be solved by combining both techniques to improve the quality of the recommendation. The resulting system is known as a hybrid recommender system. This paper presents a new hybrid hotel recommendation system that has been developed by combining content-based and collaborative filtering approaches that recommends customer the hotel they need and save them from time loss.

Keywords—recommendation systems, hotel recommendation, hybrid model, collaborative filtering, content filtering.

I. GİRİŞ VE ÖNCEKİ ÇALIŞMALAR

Teknolojideki gelişmelerle birlikte dünya çapındaki sayısız ürün, restoran, haber, kitap, film, müzik ve oteller artık çevrimiçi sistemler aracılığıyla ulaşılabilir hale gelmiştir. Ancak tüm bu çeşitlilik beraberinde bu seçenekleri gözden geçirerek aradan en uygun olanı seçme zorluğunu da kendisiyle getirmiş ve bu durum sonucunda kişiselleştirilmiş sistemlere diğer bir adıyla öneri sistemlerine ihtiyaç artmıştır. Öneri sistemlerinde amaç kullanıcıların tercihlerini öğrenmek ve onlara ihtiyaçları doğrultusunda önerilerde bulunmaktır. Genel olarak bahsetmek gerekirse, bir öneri sistemi, belirli bir alandaki öğeler (ürünler veya eylemler) hakkında belirli bir aktif kullanıcının ilgisini çekebileceği düşünülen özel öneriler sunmaktadır. Öneri sistemleri, makine öğrenmesi, yaklaşım teorisi ve çeşitli sezgisel yöntemler gibi birçok farklı yaklaşım kullanılarak geliştirilebilir. Kullanılan teknikten bağımsız ve önerilerin nasıl yapıldığına bağlı olarak, öneri sistemleri genellikle [1] aşağıdaki kategorilere ayrılmaktadır: (1) işbirlikçi filtrelemeye dayalı sistemler; kullanıcının zevkine benzer zevkleri olan insan gruplarını belirlemeye çalışan ve ortak beğenilen öğeleri öneren, (2) içerik tabanlı öneri sistemleri; daha önce kullanıcı tarafından tercih edilenlere benzer öğeler önermek için içerik bilgisini kullanan sistemler olmak üzere iki şekilde sınıflandırılabilir.

Genel olarak, işbirlikçi filtrelemeye dayalı öneri sistemleri içerik tabanlı sistemlerden daha iyi performans göstermektedir, ancak başarıları yeterli sayıda ürün değerlendirmesi varlığına dayanmaktadır [2]. Bu tür sistemlerde soğuk başlatma olarak adlandırılan yani yeni bir ürün geldiğinde bu ürün için herhangi bir kayıt bulunmadığından bu ürünü önerememe problemi oluşmaktadır. Bu gibi sorunların çıkma sebebi benzerlik analizinin doğru bir şekilde yapılamamasıdır [3]. Bu durumlarda içeriğe dayalı bir yaklaşımın kullanılması alternatif olarak ortaya çıkmaktadır [4]. Ancak bu sistemlerin de kendi içerisinde sınırlamaları vardır. Örneğin, öğelerin içeriğini temsil etmek için kullanılan öznitelikler ürünü temsil etmek



Şekil 1: Genel sistem mimarisi

için yeterli olmayabilir. Ayrıca, içerik tabanlı yaklaşımlarda çok az değerlendirmesi bulunan kullanıcılara doğru ve çeşitli önerilerde bulunmak zorlaşmaktadır.

Yukarıda saydığımız problemleri çözecek ortak bir yaklaşım işbirlikçi filtreleme (İF) ve içerik tabanlı filtreleme (İTF) sistemleri bir araya getirilerek yeni bir melez sistem oluşturulmasıdır [5]. İki farklı öneri sistemi birleştirilirken ağırlıklı kriter kullanımı (farklı öneri sistemlerinden çıkan skorlar sayısal olarak birleştirilir), anahtarlama mekanizmasının kullanımı (sistem herhangi bir öneri sisteminden önerilecek ürünü/hizmeti seçer ve önerir) şeklinde farklı melezleme teknikleri kullanılarak yapılabilmektedir. Hatta iki öneri sistemi aynı anda kullanılabilir, bunun nasıl olacağının seçimi tamamen öneri sistemini geliştiren kişiye bağlıdır. Melez bir sistemin nasıl oluşturulacağı ve bununla ilgili kriterlerin belirlenmesi melezleme sırasında çözülmesi gereken yaygın sorunlardan biridir.

Öneri sistemleri üzerine literatürde bolca çalışma bulmak mümkündür. Bu çalışmaların nispeten büyük çoğunluğu da müzik [6], [7], film [8]–[10] ve e-ticaret ürünlerinin [11]–[13] kullanıcı etkileşimleri ile öneri oluşturma üzerinedir. Bu sistemleri Spotify, Netflix, Amazon gibi firmalar aktif olarak kullanmakta ve kullanıcıları için önemli ölçüde faydalar sağlamaktadırlar.

Ayrıca, öneri sistemleri için literatür taraması sunan çalışmalar bulunmaktadır. Ricci ve diğerleri, çalışmalarında [14] öneri sistemlerini genel olarak ele almış ve bu alandaki gerekli tanımlama, sınıflandırma, kullanım alanları gibi bilgileri sunmuşlardır. Benzer şekilde ve nispeten yakın zamanda Mu ve diğerleri, derin öğrenme tabanlı öneri sistemlerinin literatür taramasını sunan bir çalışma [15] gerçekleştirmişlerdir. Bu çalışmada, otomatik kodlayıcı, kısıtlı Boltzmann makineleri, özyinelemeli sinirsel ağlar, çekışmeli üretici ağlar gibi sinir ağları yapıları ile mümkün kılınan tekil ve melez öneri sistemleri ele alınmıştır. Bir başka çalışmada [16] Chen ve diğerleri, işbirlikçi filtreleme yöntemi özelinde öneri sistemlerinin literatür taramasını sunmuştur. Bu konuda kullanılan geleneksel yöntemler kısıtları ile birlikte verilmiş ve güncel çözüm yöntemlerinden bahsedilmiştir.

Turizm alanında ise rota, etkinlik, otel gibi önerilerin yapıldığı bir takım çalışmalar mevcuttur. Örneğin, Fang-Ming ve diğerleri çalışmalarında [17], Bayes ağları kullanarak ilgili lokasyonlarda kişiye özel turistik etkinlikler önerileri oluşturmuşlar ve Google haritalar ile entegre etmişlerdir. Benzer şekilde, kullanıcının kısıtlarını ve isteklerini de göz önünde bulundurarak zaman ve masraf açısından en uygun rotayı öneren çalışmalar da mevcuttur [18].

Otel öneri sistemlerinde genel olarak değinilen bir problem de etkileşim verisinin azlığı ve dolayısıyla etkileşim matrisinin oldukça seyrek bir yapıda olmasıdır. Bu durum liter-

atürdeki çoğu çalışmada adreslenmiş ve çözüme yönelik yöntemler önerilmiştir. Saga ve diğerleri, otel önerisi problemi kullanıcıların yalnızca otel tercihleri verisine dayandırarak geçiş ağları ile modellemiştir [19]. Otel tercihlerinin yanı sıra veri temsili zenginleştirmek adına ve seyreklik problemine çözüm olarak misafir görüşlerini de ele alan çalışmalar mevcuttur

[20], [21]. Benzer bir amaç ve soğuk başlatma problemine yönelik olarak Qi ve diğerleri, uçuş tercihleri ile otel tercihleri arasında dönüşüm matrisi kullanarak kullanıcı karakterini zenginleştirdiklerini ifade etmişlerdir [22]. Zhang ve diğerleri ise, çalışmalarında [23] kullanıcının önceki tercihleri ve geçerli zamandaki niyetlerini kullanarak melez bir sistem oluşturmuşlardır.

Bu çalışmada otel öneri sisteminin gerçek hayattaki performansını arttırmak için içerik tabanlı ve işbirlikçi filtrelemeye dayalı iki öneri sistemi bir araya getirilerek melez bir öneri sistemi geliştirilmiştir. Literatürdeki benzer çalışmalardan farklı olarak bu çalışma, içerik tabanlı yöntemde zengin bir otel öznitelik listesinden faydalanmakta ve işbirlikçi filtreleme kısmında etkileşim matrisini misafirlerin tercih miktarları ile oluşturarak kullanıcı-ürün skor matrisine benzetmektedir. Son olarak anahtarlama yöntemi ile iki ayrı sistemi melezleyerek çıktı oluşturmaktadır.

Yapılan çalışmanın detaylarını sunmak için bu makale aşağıdaki şekilde yapılandırılmıştır. Bir sonraki bölüm, geliştirilen otel öneri sistemi ve bu sistem kurulurken kullanılan yaklaşımları detaylı bir şekilde tanıtmaktadır. Önerilen modelin performansı Bölüm III'te değerlendirilmiştir. Son olarak, Bölüm IV sonuçlarımızı genel hatlarıyla özetlemektedir.

II. OTEL ÖNERİ SİSTEMİ

Öneri sistemleri oluşturmak için bir çok yöntem bulunmaktadır. Fakat hepsinin esas amacı her kullanıcı için ürün kümesindeki elemanlara karşılık gelen skor/değerlendirme değerlerini üretmektir. Bu çıktıları üretirken kullanıcıların daha önceden belli ürünler için sağlamış olduğu skor/değerlendirme değerleri kullanılmaktadır. Kullanıcıya özel öneri listesi oluşturulurken ise bu ürünler liste dışında tutulmaktadır. Buradaki amaç müşterinin daha önce etkileşimde bulunmadığı ürünlerden birini önerebilmektir. Sonuç olarak, hesaplanan skor/değerlendirme sonuçları sıralanarak liste başından belli sayıda ürün seçilmekte ve müşteriye sunulmaktadır.

Otel öneri sistemimizde benzer yöntemler takip edilerek iki ayrı koldan iki farklı öneri listesi oluşturularak melez bir öneri listesi elde edilmektedir. Şekil 1'de sistemin genel mimarisi verilmiştir. Burada, üst kolda İTF tabanlı yöntem akışı bulunurken alt kolda ise İF tabanlı yöntem akışı bulunmaktadır ve son olarak tekil çıktılar birleştirilerek melez çıktı

elde edilmektedir. Takip eden başlıklarda ilgili alt sistem ve basamakların detayları verilmiştir.

A. İçerik Tabanlı Filtreleme Yöntemi

İTF yönteminde kullanıcılar temel olarak sahip oldukları veya etkileşime geçtikleri ürünlerin özellikleri ile temsil edilmektedirler. Bu durum kitap satın alan müşteriler için satın alınan kitabın türü, ücreti, sayfa sayısı gibi özellikler olurken film izleyen kullanıcılar için film ile ilgili özellikler olmaktadır. Kullanıcıları kullandıkları ya da satın aldıkları ürünlerin özellikleri ile temsil etmek aslında onların profillerini çıkartmaktır. Şekil 2’de görülen kullanıcı daha önce A ve B ürünleri ile ilişkilendirilmiş ve bu iki ürün kullanıcının profilinin oluşmasını sağlamıştır. Oluşturulan bu profil ışığında, kullanıcının C ürünü ile etkileşiminin olasılığı sorgulanabilmektedir. Bu çalışmada da kullanıcıların profillerini çıkartmak için daha önce gittikleri otellerin özellikleri esas alınmıştır.

Örneğin Tablo I’de kullanıcı 1, A ve B otellerine gitmiş olsun. *Kullanıcı 1*’in gittiği otellerin kapasiteleri sırasıyla 500 ve 700 kişilik, denize olan uzaklıkları 150 ve 50 metre ve bu iki otelde de kahvaltı hizmeti olsun. Dolayısı ile *Kullanıcı 1*’in profili hesaplanırken bu içerik bilgilerinden yararlanılır ve Tablo I’deki ilgili satırların ortalama değerleri alınır. Bu durumda *Kullanıcı 1*’in gittiği otellerin kapasitesi ortalama olarak 600 kişilik, denize uzaklıkları ise 100 metredir. Ayrıca *Kullanıcı 1* gittiği otellerde kahvaltı hizmeti de aramaktadır. Diğer taraftan *Kullanıcı 2* daha az kapasiteli otelleri ve denize daha uzak otelleri seçerek daha farklı bir profil sergilemiştir. Sonuç olarak bu kullanıcıların profilleri Tablo II’deki gibi olur.

Tablo I: Kullanıcı-Otel Bilgileri Örneği

Kullanıcı	Otel	Kapasite	DenizeOlanUzaklık	Kahvaltı
1	A	500	150	1
1	B	700	50	1
2	C	200	500	0
2	D	300	1000	0
2	E	100	1500	1


Kullanıcıların profilleri ile sistemde var olan fakat kullanıcının gitmediği oteller arasında benzerlik hesaplanarak kullanıcıların profiline en yakın N tane otel önerilmiştir. Otel listesi veri ön işleme adımlarından geçirilerek temizlenmiştir. Bu ön işleme adımları, eksik verileri düzeltme (Ör: Otel isimleri), tutarsız verileri kaldırma (Ör: Oda sayısı) gibi işlemlerden oluşmaktadır. Daha sonra otellerin en önemli 11 özelliği Temel Bileşenler Analizi (TBA) yöntemi kullanılarak 220 tane özellik arasından seçilmiştir. Bu özelliklerin hepsi burada listelenemeyeceği için birkaç tanesinden bahsedilmiştir. Bunlar: otelin fiyatı, otelin şehir merkezine olan uzaklığı, otelde otopark olup olmaması vb. TBA yöntemi kullanılarak veri boyutunun azaltılması sayesinde profiller ile oteller arasında benzerlik hesaplaması yapılırken çalışma süresinin kısalması sağlanmıştır.

Tablo II: İTF ile kullanıcıların temsil edilmesi

Kullanıcı	Kapasite	DenizeOlanUzaklık	Kahvaltı
1	600	100	1
2	200	1000	0,33

B. İşbirlikçi Filtreleme Yöntemi

İşbirlikçi filtreleme kişiselleştirilmiş öneri sistemlerinde kullanılan en önemli yaklaşımlardan birisidir. Kullanıcılar



Şekil 2: İçerik tabanlı filtreleme yöntemi

için izole profiller oluşturmak ve bunları ürünler ile ilişkilendirmenin ötesinde kullanıcılar arasında etkileşim de sağlanmaktadır. Bu etkileşim, kullanıcıların seçimlerinde veya oylamalarında birbirine benzerlikleri olarak açıklanabilir. Bir başka deyişle, kullanıcıların tercih benzerlikleri öneri oluşturmak için kullanılmaktadır. Örneğin, Şekil 3’te görüldüğü üzere bir grup kullanıcı (solda) daha önce ürün A ve B ile ilişkilendirilmiş ve sorgu altındaki kullanıcı (sağda) daha önce sadece A ürünü ile ilişkilendirilmiştir. Bu durumda sorgu altındaki kullanıcı için B ürünü ile ilişki ihtimali sorgulanabilir ve yüksek olması beklenmektedir.


İF için birçok teknik bulunmaktadır [24]. Bunlardan birisi de Netflix Price [25] ile öneri sistemleri üzerinde büyük etki yaratmış Matris Ayrıştırma yöntemidir. Bu yöntem, bir doğrusal cebir konusu olarak herhangi bir matrisin iki dikdörtgen matrise ayrıştırılması esasına dayanır ve teknik detayları bir sonraki bölümde verilmiştir.

1) *Matris Ayrıştırma*: Öneri sistemlerinde eğitim için toplanılan kullanıcı değerlendirme skorları ile bir matris oluşturulur ve bu matris problemin doğası gereği oldukça seyrek olur. Matris Ayrıştırma tekniği Tekli Değer Ayrıştırma (TDA) tekniğine oldukça benzemekle beraber, TDA’nın sahip olmadığı eksik matris girdisi toleransına sahip bir alternatiftir. Denklem 1’de görüldüğü üzere oluşturulan büyük ve seyrek matris (r_{mu}) daha küçük ve yoğun iki matrisin (p_m, q_u) çarpımı şeklinde ifade edilmektedir [26].

$$\begin{aligned} r_{mu} &= p_m * q_u, \\ \hat{r}_{mu} &= \hat{p}_m * \hat{q}_u, \end{aligned} \quad (1)$$

Burada r_{mu} müşteri ve ürün ikililerinin değerlendirme skorlarını barındıran matrisi, p_m müşterilerin gizli uzay (latent space) temsil matrisini, q_u ise ürünlerin gizli uzay temsil matrisini ifade etmektedir. Ayrıştırılmış matrisler (p_m, q_u) bir sistem parametresi olan gizli uzay boyutunu (k) paylaşmaktadırlar. Matris boyutları, r, p, q için sırasıyla $m*u, m*k, k*u$ şeklinde tanımlanmaktadır.

Denklem 1’de ifade edilen p, q matrisleri Gradyan İnişi, Değişimli En Küçük Kareler (DEKK) yöntemi gibi teknikler ile çözülebilmektedir. Çoğu öneri sistemi problemlerinde $m * u$ sonucunun göreceli olarak büyük çıkmasından dolayı En Küçük Kareler yöntemi tercih edilmektedir [26], [27]. İki matrisin kestirimi dışbükey olmayan bir problem olduğu için DEKK yöntemi kullanılmaktadır. Değişimli kelimesi, p ve q matrislerinin değişmeli olarak birinin sabit tutulmasını ve diğerine en küçük kareler yönteminin uygulanmasını ifade etmektedir.



Şekil 3: İşbirlikçi filtreleme yöntemi

DEKK yönteminin bilinen maliyet fonksiyonuna ek olarak düzenleme parametresi eklenmektedir. Buradaki amaç aşırı uyumlama probleminin kaçınarak daha genel bir uyumlama ile $\hat{r}_{mu}$ matrisini oluşturmaktır. Denklem 1'de görüldüğü üzere $\hat{r}_{mu}$ matrisi, kestirilen $\hat{p}_m$ ve $\hat{q}_u$ matrislerinin çarpımı ile elde edilmektedir. Böylelikle r_{mu} matrisinde bulunan eksik girdiler doldurularak yoğun $\hat{r}_{mu}$ matrisi elde edilmektedir. Doldurulan girdiler müşteriler için henüz değerlendirilmemiş/kullanılmamış ürünlerin önerisini oluşturmaktadır.

C. Melez Model Oluşturma Tekniği

Tekil öneri sistemlerinin çıktıları melez bir öneri sistemi oluşturmak için kullanılmaktadır. Çıktıların birleştirilmesi için skor ile sıralanmış listeler alınmakta ve aynı sıra indisli ürünler arka arkaya gelecek şekilde yeni bir melez liste oluşturulmaktadır.

$$M^N = A^{N/2} \cup B^{N/2} \quad (2)$$

$$A^{N/2} \cup B^{N/2} = [A_1, B_1, A_2, B_2, \dots, A_{N/2}, B_{N/2}],$$

Denklem 2'de melez listenin oluşturulma biçimi gösterilmiştir. Burada, tekil sistemler A ve B olarak tanımlanmış, melez sistem ise M olarak tanımlanmıştır. Alt indisler sistemlerin sıralı liste elemanı indislerini belirtirken üst indisler listenin kendisini uzunluğuyla beraber ifade etmektedir. Örneğin, A ve B sistem listelerinin ilk 5'er elemanları (A^5 , B^5) alınarak M^{10} listesi (melez sistemin ilk 10'u) oluşturulmaktadır.

III. DENEYLER

A. Veri Seti

Otel öneri sistemi için turizm sektöründen bir şirketin yaklaşık 7 yıl süreli rezervasyon kayıtları kullanılmıştır. Bu kayıtlar anonim olarak oluşturulmuş müşteri kimlik sözcüğü, otel kodu ve tarih olmak üzere 3 kolondan oluşmaktadır. Her bir kayıt bir müşterinin hangi tarihte ve hangi otelde konakladığı bilgisini içermektedir. Kayıt sayısı yaklaşık olarak 4,5 milyondur.

Müşteri bazında akıllı tekilleştirme uygulanmış [28] veri setindeki eşsiz müşteri sayısı yaklaşık olarak 1,5 milyon, eşsiz otel sayısı ise 10 bin civarındadır. Her müşterinin en az 2 rezervasyonu ve dolayısıyla 2 kaydı bulunmaktadır. Müşteriler tamamen anonimleştirilmiş ve müşteriye ait hiç bir ek bilgi kullanılmamıştır. Bunun yanında, otellerin öznitelikleri kullanılmıştır. Basitçe, bu öznitelikler otellerin müşterilerine sundukları imkanları kapsamaktadır. Müşterilerin otelleri seçmesinde rol oynayan bu özniteliklerden bazıları şu şekilde sıralanabilir: açık havuz, spa, evcil hayvan kabul etme.

1) *Eğitim-Test Senaryoları:* Veri seti, eğitim ve test kümelerine ayrılarak deneyler gerçekleştirilmiştir. Sunulan tekil ve melez sistemlerin farklı eğitim-test kümeleri üzerindeki performanslarını karşılaştırmak için 5 senaryoda eğitim-test bölümlendirmesi yapılmıştır.

Tablo III: Senaryoların oluşturulma biçimi

Senaryo	Rez. Sayısı Aralığı	Test Kümesi
1	3-10	Her müşterinin son rezervasyonu
2	2-10	Her müşterinin son rezervasyonu
3	2-10	Senaryo 1'in test kümesi
4	3-5	Her müşterinin son rezervasyonu
5	8-10	Her müşterinin son rezervasyonu

Tablo III'te senaryoların hangi filtrelerden geçirildiği ve test kümesinin hangi kural ile ayrıldığı verilmiştir. Rezervasyon sayısının farklı olduğu senaryolarda farklı performans ölçümleri alınması beklenmiştir. Test kümesi 3. senaryo hariç benzer şekilde her müşterinin son rezervasyonu seçilerek ayrılmıştır. Örneğin, senaryo 1'de, rezervasyon sayısı 3 ile 10 olan müşterilerin verisi alınmış ve her müşterinin son rezervasyonu test kümesine atılmıştır. Dolayısıyla test kümesindeki kayıt sayısı ile eşsiz müşteri sayısı eşittir. Tablo IV'te her senaryo için eğitim ve test kümelerinin sahip olduğu veri boyutları ile ilgili detaylı bilgi verilmiştir. Eşsiz otel sayısı eğitim ve test kümeleri için aynıdır.

Tasarlanan bu senaryolar ile performans karşılaştırmaları yapılarak bir takım vargılara ulaşılması planlanmıştır. Senaryo 1-2 karşılaştırması ile 2 rezervasyonlu müşterilerin etkisi (minimum rezervasyonlu sayıca büyük grup), senaryo 1-3 karşılaştırması ile yalnızca eğitim kümesine katılan 2 rezervasyonlu müşterilerin etkisi incelenmiştir. Senaryo 4-5 karşılaştırması sayesinde de düşük rezervasyonlu grup ile yüksek rezervasyonlu grubun performans farkı incelenmiştir.

Tablo IV: Senaryolara ait veri boyutları

Senaryo	Otel Say.	Eğitim		Test
		Kayıt Say.	Müşteri Say.	Kayıt Say.
1	8.785	2.326.623	693.547	693.547
2	9.216	3.055.646	1.422.570	1.422.570
3	9.927	3.784.669	1.422.570	693.547
4	8.066	1.440.985	552.303	552.303
5	5.647	405.355	52.116	52.116

B. Öneri Sistemlerinin Otel Rezervasyon Verisine Uygulanması

İTF yönteminde kullanıcı profilleri ile oteller arasında benzerlik hesaplanırken iki farklı yöntem kullanılmıştır. İlk yöntemde profiller ile tüm oteller karşılaştırılarak öneri kümesi oluşturulmuştur. İkinci yöntemde ise daha önce [29] çalışmasında da kullanılan kümeleme yöntemi kullanılmıştır. Bu yöntemde, profiller ile önceden k-ortalama algoritması ile kümelenecek oteller kümesinden en yakın merkezdeki oteller arasında benzerlik hesaplaması yapılmıştır. Öncelikle oteller k-ortalama algoritması ile kümelenecek ve her küme içinde barındırdığı otellerin özelliklerinin ortalama değerleri ile temsil edilmişlerdir. Daha sonra kullanıcı profilleri ile bu kümelerin merkezleri karşılaştırılmıştır, son olarak en yakın kümede kullanıcıya en yakın N tane otel önerilmiştir. Benzerlik hesaplaması yapılırken öklid uzaklığı kullanılmıştır.

İF yönteminde müşterilerin otellere gitme sayıları otellere verilen skor olarak kabul edilmiş ve her senaryo için Denklem 1'deki r_{mu} matrisi oluşturulmuştur. Bu matrislere

Bölüm II-B1’de anlatıldığı üzere Matris Ayırıştırma yöntemi uygulanmıştır. Gizli uzay boyutu (k) olarak 20, düzenleştirme parametresi için ise 0.1 seçilmiştir. Elde edilen $\hat{r}_{um}$ matrisinde müşteri (satur) bazında düzleştirme ve sıralama yapılmıştır. Böylelikle her müşteri için önerilen sıralı otel listesi elde edilmiştir.

C. Tekil ve Melez Modellerin Başarımı

İTF ve İF yöntemleri kullanılarak otel rezervasyon verisi ile yapılan deneyler sonucu tekil sistemlerin ve melez sistemin başarımları sırasıyla Tablo V, VI, VII’de verilmiştir. Başarım kriteri olarak duyarlılık seçilmiş ve tablolarda yüzdelik olarak raporlanmıştır.

$$\text{Duyarlılık} = \frac{N'lik\ listedeki\ ilgili\ eleman\ sayısı}{toplam\ ilgili\ eleman\ sayısı} \quad (3)$$

Duyarlılık, öneri sistemleri için Denklem 3’teki gibi tanımlanmaktadır. Kısaca duyarlılık ölçüsü, test kayıtlarının hangi oranda öneri listeleri tarafından içerdiği şeklinde hesaplanmaktadır. Başarımlar İlk5, İlk10, İlk100 olarak tanımlanmış farklı uzunluktaki öneri listeleri üzerinden elde edilmiştir. Beklenildiği üzere öneri listesi uzunluğu arttıkça duyarlılık oranı da artacak ya da sabit kalacaktır.

Tablo V: İçerik Tabanlı Filtreleme başarım tablosu

Senaryo	Kümeleme Tabanlı Veri			Tüm Veri		
	İlk5	İlk10	İlk100	İlk5	İlk10	İlk100
1	8,17	10,61	27,45	9,62	12,19	29,39
2	11,05	12,92	26,78	14,10	16,11	29,50
3	8,17	10,61	27,45	9,62	12,19	29,39
4	8,42	10,83	27,18	9,76	12,32	29,26
5	6,83	9,35	27,67	10,89	13,34	31,25

Tablo V’te İTF sonuçları kümelenmiş veriler kullanılarak alınan ve tüm veri kullanarak alınan performansları ayrı ayrı göstermektedir. Tüm veri ile elde edilen sonuçlardaki başarımlar görece yüksek olmasına rağmen işlem yükü olarak oldukça pahalıdır. Diğer yandan, kümeleme kullanımı beklenildiği üzere başarımlarına sebep olurken işlem yükü tasarrufu sağlamaktadır.

Tablo VI: İşbirlikçi Filtreleme başarım tablosu

Senaryo	İlk5	İlk10	İlk100
1	7.42	11.22	34.10
2	7.70	11.42	34.17
3	7.57	11.50	34.93
4	7.60	11.42	34.38
5	6.21	9.63	30.79

Tablo VI’da İF sisteminin sonuçları verilmiştir. İTF sonuçları ile karşılaştırıldığında İTF sistemin kısa listede (İlk5) daha başarılı olduğu fakat uzun listede (İlk100) İF yönteminin öne geçtiği gözlemlenmiştir.

Senaryolar karşılaştırıldığında, İTF yönteminin senaryo 2’deki görece yüksek performansı 2 rezervasyonlu grubu başarılı bir şekilde tahmin ettiğini göstermektedir. Bu grubun sadece eğitime katıldığı 3. senaryoda ise İF sisteminde önemli bir artış görülmemiştir. İTF’de eğitim kümesine eklenen veriler herhangi bir etkide bulunmadığı için senaryo 1 ve 3 performansları Tablo V’te aynıdır. Öte yandan, senaryo 4 ve 5 karşılaştırıldığında, her iki tekil sistemde de yüksek rezervasyonlu müşteri verisinde (senaryo 5) nispeten daha düşük performans alındığı gözlemlenmiştir.

İki yöntemde de senaryo 5’in performansının diğer senaryolara göre nispeten düşük olmasının sebebi bu senaryoya ait veri setinin küçük olması olarak gösterilebilir. Kullanıcılara ait rezervasyon miktarı veri zenginliğini arttırmaktadır fakat yüksek rezervasyonlu müşteri sayısı oldukça düşüktür. Veri seti büyüklüğünün önemi senaryo 2’nin göstermiş olduğu performans artışı ile de ortaya çıkmaktadır. Özellikle İTF yönteminde dramatik bir artış gösteren senaryo 2, İF yönteminde aynı etkiyi gösterememiştir. Bunun sebebi olarak da Matris Ayırıştırma yönteminin az ürün/skor değerlendirme sayılı veriler ile nispeten daha kötü çalışması olarak gösterilebilir.

Tablo VII: Melez Filtreleme başarım tablosu

Senaryo	Kümeleme Tabanlı			Tüm Veri		
	İlk5	İlk10	İlk100	İlk5	İlk10	İlk100
1	10.62	15.25	41.81	12.01	16.73	44.09
2	14.07	18.31	42.21	17.16	21.46	45.72
3	10.69	15.42	42.43	12.07	16.92	44.70
4	11.09	15.69	41.88	12.25	17.05	44.20
5	8.43	12.88	39.21	12.77	17.18	43.36

Tablo VII’de performansları verilen melez öneri listeleri Bölüm II-C’de belirtilen şekilde oluşturulmuştur. İlk5 listesi oluşturulurken 5. ürün önerisi olarak İlk5 listesinde daha başarılı olan İTF sistemi kullanılmıştır. Melez sistem başarımları diğer tekil sistemlerin başarımlarına göre önemli bir artış göstermiştir.

IV. VARGILAR

Öneri sistemleri arasında birbirinden farklı iki önemli yöntem olan İTF ve İF yöntemleri turizm sektöründe otel rezervasyon verisi kullanılarak uygulanmıştır. Yöntemler, performansların karşılaştırılabileceği farklı senaryolar ile test edilmiş ve elde edilen gözlemler raporlanmıştır.

Sıralı liste birleşimi sayesinde oluşturulan melez öneri sistemi sayesinde öneri performansı tekil sistemlere göre önemli derecede yükseltilmiştir. Müşterilere sunulmak üzere makul uzunlukta olan İlk10 öneri listeleri ele alındığında ve eğitim-test kümesi için tüm verilerin kullanıldığı Senaryo 2’de duyarlılık %21.46’dır.

İlerleyen dönemlerde öneri sisteminin devreye alınması ve müşterilere önerilerin bildirilmesi veya gösterilmesi planlanmaktadır. Bu sayede öneri sisteminin daha gerçekçi duyarlılık değerleri alınmış olacaktır. Sunulan öneriler müşteri ilgisini çekerek listeden bir ürün ile etkileşimin gerçekleşme ihtimalinin de artması beklenmektedir.

V. BİLGİLENDİRME

Bu çalışma, Etstur tarafından desteklenmiştir.

KAYNAKÇA

- [1] G. Adomavicius and A. Tuzhilin, “Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions,” *IEEE Trans. on Knowl. and Data Eng.*, vol. 17, no. 6, pp. 734–749, Jun. 2005.
- [2] X. Chen, Y. Zhang, Q. Ai, H. Xu, J. Yan, and Z. Qin, “Personalized key frame recommendation,” in *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval*, ser. SIGIR ’17. New York, NY, USA: ACM, 2017, pp. 315–324.
- [3] R. Sharma, D. Gopalani, and Y. Meena, “Collaborative filtering-based recommender system: Approaches and research challenges,” in *2017 3rd International Conference on Computational Intelligence Communication Technology (CICIT)*, Feb 2017, pp. 1–6.

- [4] M. J. Pazzani and D. Billsus, "The adaptive web," P. Brusilovsky, A. Kobsa, and W. Nejdl, Eds. Berlin, Heidelberg: Springer-Verlag, 2007, ch. Content-based Recommendation Systems, pp. 325–341.
- [5] R. Burke, "Hybrid recommender systems: Survey and experiments," *User Modeling and User-Adapted Interaction*, vol. 12, no. 4, pp. 331–370, Nov 2002.
- [6] J. Su, H. Yeh, P. S. Yu, and V. S. Tseng, "Music recommendation using content and context information mining," *IEEE Intelligent Systems*, vol. 25, no. 1, pp. 16–26, Jan 2010.
- [7] K. Yoshii, M. Goto, K. Komatani, T. Ogata, and H. G. Okuno, "An efficient hybrid music recommender system using an incrementally trainable probabilistic generative model," *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 16, no. 2, pp. 435–447, Feb 2008.
- [8] Q. Diao, M. Qiu, C.-Y. Wu, A. J. Smola, J. Jiang, and C. Wang, "Jointly modeling aspects, ratings and sentiments for movie recommendation (jmars)," in *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ser. KDD '14. New York, NY, USA: ACM, 2014, pp. 193–202. [Online]. Available: <http://doi.acm.org/10.1145/2623330.2623758>
- [9] A. Said, S. Berkovsky, and E. W. De Luca, "Putting things in context: Challenge on context-aware movie recommendation," in *Proceedings of the Workshop on Context-Aware Movie Recommendation*, ser. CAMRa '10. New York, NY, USA: ACM, 2010, pp. 2–6. [Online]. Available: <http://doi.acm.org/10.1145/1869652.1869665>
- [10] G. Lekakos and P. Caravelas, "A hybrid approach for movie recommendation," *Multimedia tools and applications*, vol. 36, no. 1-2, pp. 55–70, 2008.
- [11] J. B. Schafer, J. A. Konstan, and J. Riedl, "E-commerce recommendation applications," *Data mining and knowledge discovery*, vol. 5, no. 1-2, pp. 115–153, 2001.
- [12] J. Wang and Y. Zhang, "Opportunity model for e-commerce recommendation: right product; right time," in *Proceedings of the 36th international ACM SIGIR conference on Research and development in information retrieval*. ACM, 2013, pp. 303–312.
- [13] G. Linden, B. Smith, and J. York, "Amazon.com recommendations: Item-to-item collaborative filtering," *IEEE Internet Computing*, vol. 7, no. 1, pp. 76–80, Jan. 2003.
- [14] F. Ricci, L. Rokach, and B. Shapira, "Recommender systems: introduction and challenges," in *Recommender systems handbook*. Springer, 2015, pp. 1–34.
- [15] R. Mu, "A survey of recommender systems based on deep learning," *IEEE Access*, vol. 6, pp. 69 009–69 022, 2018.
- [16] R. Chen, Q. Hua, Y. Chang, B. Wang, L. Zhang, and X. Kong, "A survey of collaborative filtering-based recommender systems: From traditional methods to hybrid methods based on social networks," *IEEE Access*, vol. 6, pp. 64 301–64 320, 2018.
- [17] F.-M. Hsu, Y.-T. Lin, and T.-K. Ho, "Design and implementation of an intelligent recommendation system for tourist attractions," *Expert Syst. Appl.*, vol. 39, no. 3, pp. 3257–3264, Feb. 2012. [Online]. Available: <http://dx.doi.org/10.1016/j.eswa.2011.09.013>
- [18] H. Liu, J. Li, and J. Peng, "A novel recommendation system for the personalized smart tourism route: Design and implementation," in *2015 IEEE 14th International Conference on Cognitive Informatics Cognitive Computing (ICCI*CC)*, July 2015, pp. 291–296.
- [19] R. Saga, Yoshihiro Hayashi, and H. Tsuji, "Hotel recommender system based on user's preference transition," in *2008 IEEE International Conference on Systems, Man and Cybernetics*, Oct 2008, pp. 2437–2442.
- [20] K. Takuma, J. Yamamoto, S. Kamei, and S. Fujita, "A hotel recommendation system based on reviews: What do you attach importance to?" in *2016 Fourth International Symposium on Computing and Networking (CANDAR)*, Nov 2016, pp. 710–712.
- [21] K. Jalan and K. Gawande, "Context-aware hotel recommendation system based on hybrid approach to mitigate cold-start-problem," in *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)*, Aug 2017, pp. 2364–2370.
- [22] Q. Qi, J. Cao, Y. Tan, and Q. Xiao, "Cross-domain recommendation method in tourism," in *2018 IEEE International Conference on Progress in Informatics and Computing (PIC)*, Dec 2018, pp. 106–112.
- [23] K. Zhang, K. Wang, X. Wang, C. Jin, and A. Zhou, "Hotel recommendation based on user preference analysis," in *2015 31st IEEE International Conference on Data Engineering Workshops*, April 2015, pp. 134–138.
- [24] R. Zhang, Q. Liu, Chun-Gui, J. Wei, and Huiyi-Ma, "Collaborative filtering for recommender systems," in *2014 Second International Conference on Advanced Cloud and Big Data*, Nov 2014, pp. 301–308.
- [25] Y. Zhou, D. Wilkinson, R. Schreiber, and R. Pan, "Large-scale parallel collaborative filtering for the netflix prize," in *Proceedings of the 4th International Conference on Algorithmic Aspects in Information and Management*, ser. AAIM '08. Berlin, Heidelberg: Springer-Verlag, 2008, pp. 337–348.
- [26] Y. Koren, R. Bell, and C. Volinsky, "Matrix factorization techniques for recommender systems," vol. 42, no. 8. Los Alamitos, CA, USA: IEEE Computer Society Press, Aug. 2009, pp. 30–37.
- [27] I. Pilászy, D. Zibriczky, and D. Tikk, "Fast als-based matrix factorization for explicit and implicit feedback datasets," in *Proceedings of the Fourth ACM Conference on Recommender Systems*, ser. RecSys '10. New York, NY, USA: ACM, 2010, pp. 71–78. [Online]. Available: <http://doi.acm.org/10.1145/1864708.1864726>
- [28] A. T. Bayrak, A. İ. Yılmaz, K. B. Yılmaz, R. Düzağaç, and O. T. Yıldız, "Near duplicate detection in relational databases," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2018, pp. 1–4.
- [29] M. Pakyürek, M. S. Sezgin, S. Kestepe, B. Bora, R. Düzağaç, and O. T. Yıldız, "Customer clustering using rfim analysis," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*, May 2018, pp. 1–4.