



Bankacılık Sektöründe Tavsiye Sistemleri: Bir Literatür Çalışması

Yudum PAÇİN^{1*} 

¹Türkiye Vakıflar Bankası, ARGE ve İnovasyon Müdürlüğü, İstanbul

Özet

Tavsiye sistemleri, günümüzde hızla artan kullanıcı ve ürün veri havuzlarını işlemek üzere sofistike algoritmaların kullanıldığı ve ürünler ile müşteriler arasında en uyumlu eşleşmeyi bulmayı amaçlayan bir teknolojidir. Farklı sektörlerde çeşitli ürün tipleri için uygulanabilse de, ana hedef her zaman müşteri memnuniyetini optimize etmek, kişiselleştirilmiş bir kullanıcı deneyimi sunmak ve satışları artırmaktır. Bu çalışma, bankacılık sektöründeki tavsiye sistemlerine odaklanır ve mevcut literatürü derinlemesine inceleyerek kullanılan veri setlerini ve yöntemleri ele alır. Çalışmanın amacı, bankacılık sektöründe tavsiye sistemlerinin potansiyel faydalarını ortaya koymak ve gelecekteki araştırmalar için potansiyel alanları belirlemektir.

Anahtar Kelimeler: Tavsiye sistemleri, bankacılık, literatür çalışması

Makale Bilgisi

Başvuru:
10/07/2023
Kabul:
24/09/2023

Recommendation Systems in Banking: A Literature Review

Abstract

Recommendation systems are a technology aimed at finding the most compatible match between products and customers, using sophisticated algorithms to process the rapidly growing pools of user and product data in today's world. While they can be applied to various product types across different sectors, the primary goal is always to optimize customer satisfaction, provide a personalized user experience, and boost sales. This study focuses on recommendation systems in the banking sector, delving deeply into the current literature while examining the datasets and methods used. The aim of the research is to highlight the potential benefits of recommendation systems in the banking industry and identify potential areas for future research.

Keywords: Recommendation systems, banking, literature review

* İletişim e-posta: yudum.pacin@vakifbank.com.tr

1 Giriş

Tavsiye sistemleri kullanıcıların ilgilenebileceği öğeleri sunan destekleyici bilgi filtreleme ve karar verme sistemleri olarak tanımlanmaktadır [1]. Bilgi filtreleme, tavsiye sistemlerinin altında yatan en temel teknolojidir [2]. 1992 yılında Goldberg ve arkadaşları, Tapestry adında, kullanıcı değerlendirmelerine dayalı işbirlikçi bilgi filtreleme sistemi önermiştir [3]. Bu çalışma, MIT araştırmacılarına ilham vermiş ve tavsiye sistemlerinin öncüsü sayılabilecek GroupLens [4] adlı filtreleme modelini ortaya çıkarmıştır [2].

1990'lı yıllardan günümüze kadar olan süreçte, tavsiye sistemleri artık, birçok farklı alanda kullanılmakta ve popüleritesi, Netflix gibi yayın platformları ve Amazon benzeri e-ticaret sitelerindeki başarılı kullanım örnekleriyle daha da artmaktadır. Tavsiye sistemleriyle kullanıcıların karşısına ihtiyaçlarına özel ürün sunumu sağlanması ve bu yolla doğru ürünün doğru kullanıcıyla eşleştirilerek satışların artırılması hedeflenmektedir. Tavsiye sistemleri, ayrıca, kullanıcıyı kendisine en uygun olabilecek ürünü araştırma zahmetinden de kurtarmaktadır. Örneğin, Google verilerine göre, öneriler, Google Play'deki uygulama indirmelerinin %40'ını, Youtube izlenmelerinin ise %60'ını oluşturmaktadır [5].

Bankacılık uygulamalarında ürün ve hizmet çeşitliliğinin ve müşteri sayısının artmasıyla tavsiye sistemlerinin bankacılıkta uygulanabilirliği konusunda çalışmalara başlanmıştır.

Tavsiye sistemlerinin etkin bir şekilde uygulanması aşağıdaki hedeflerin elde edilmesini sağlar [1]:

- 1- Satış yapılan ürün sayısının artırılması: Ticari uygulamalar için kullanılan tavsiye sistemlerinin ana amacı doğru ürünü doğru kullanıcıya sunarak satışları arttırmaktır.
- 3- Satılan ürünlerin çeşitliliğinin artırılması: Tavsiye sistemleri sayesinde, kullanıcının popüler olmayan ama kendine uygun olan ürünlerle eşleştirilmesi sağlanabilir.
- 4- Müşteri memnuniyetinin artırılması: İyi bir tavsiye sistemi kullanıcı deneyimini iyileştirebilir ve kullanıcının ürünü kullanımını arttırabilir.
- 5- Müşteri bağlılığının artırılması: Kullanıcının sistemle daha fazla etkileşim halinde olması, bu yolla modelin de daha fazla veriden faydalanması sağlanacaktır.

6- Müşteriyi daha iyi tanıma: Tavsiye sistemlerinin kullanıcı seçimlerini izlemesi, bu seçimlerin daha ileri düzeyde iyileştirilmesine imkan sağlar.

7- Çapraz satış olanaklarının artırılması: Çapraz satış, bir müşteriye satın aldığı veya satın almayı düşündüğü bir ürüne ek olarak, o ürünle ilişkili veya tamamlayıcı diğer ürünleri de satma stratejisidir. Tavsiye sistemleri, müşterilere satın alabilecekleri ek ürünler önererek çapraz satışı artırır [6].

Tavsiye sistemlerinin tasarım ve işlevselliği, kullanıcılardan alınan geri bildirimler temelinde şekillendirilmektedir. Kullanıcılardan genellikle iki tür geri bildirim toplanmaktadır;

Açık Geri Bildirim: Kullanıcının kullandığı ürün için açıkça bir değerlendirme puanı ya da reyting vermesi ile oluşan geribildirimdir.

Kapalı Geri Bildirim: Kullanıcının ödeme tarihçesi, tıklama bilgileri, arama tarihçesi gibi dolaylı yoldan alınan geri bildirimdir. Kısaca, bu tip geri bildirimde, kullanıcının davranışlarından geri bildirim bilgisi çıkarılır.

Bankacılık uygulamalarında sadece kapalı geri bildirim ile kullanıcının ürüne olan ilgisi anlaşılabilir. Açık geri bildirimde ulaşılamaması tavsiye sistemlerinin finans sektöründe uygulanmasını kısıtlayan en önemli dezavantajlardan biridir. Başka bir açıdan bakılırsa, bankacılık uygulamalarında sadece kapalı geri bildirimler ile veri oluşturulması, puan, reyting gibi sübjektif bir veri yerine, gerçek uygulama verisi kullanılması açısından daha güvenilir sonuçların alınmasına yol açabilir [1].

Kapalı geri bildirim, çapraz kanal stratejisi çerçevesinde kullanılabilir. Örneğin kullanıcının bankanın internet sitesinde veya mobil bankacılık uygulamasında yaptığı aramalar ve hareketleri analiz edilebilir. Eğer konut kredisi ile ilgili faiz oranları ile ilgilendiyse, konut kredisi veya konut sigortası teklifi sunulabilir. Kapalı geri bildirim kullanımına, kullanıcının harcama tarihçe bilgilerinden uygun kredi kartı teklif verilmesi örneği de verilebilir.

Tavsiye Sistemleri diğer modeller gibi belirli bir algoritmadan, belli bir istatistik hesaplama paketinden, ya da belirli bir tür veriden oluşmaz. Tavsiye sistemi, çıktı olarak kişiselleştirilmiş öneriler üreten veya kullanıcıyı kişiselleştirilmiş bir şekilde, olası seçeneklerden oluşan geniş bir alanda ilginç veya faydalı nesnelere yönlendirme etkisine

sahip herhangi bir sistem olarak tanımlanır ve bu da tanım gereği seçeneklerin kapsamını genişletir. Bu nedenle temel sorun, tavsiye tekniklerinin, hangi problemlerle en etkili şekilde eşleştirileceğinin belirlenmesidir [1].

Recommender Systems Handbook [1] adlı eserden alınan Finansal Servisler ve Hayat Sigortası alanına özgü tavsiye sistemi kullanıma dair veriler Tablo 1'de sunulmuştur. Bankacılığa özgü bir örnek mevcut olmadığından, daha geniş bir kategoriye temsil eden finansal servislerle ilgili bilgiler sağlanmıştır. Finansal Servisler ve Hayat Sigortası kategorisinde tavsiye edilen ürünler yüksek risk içerdiğinden, bilgiye dayalı tavsiye sistemleri önerilmiştir.

Tablo 1. Finansal servis ve hayat sigortalarında önerilen tavsiye sistemleri [1]

Alan	Finansal Servisler
	Hayat Sigortası
Risk	Yüksek
Heterojenlik	Düşük
Kullanıcı Tercihleri	Sabit
Etkileşim	Açık
Açıklanabilirlik	Gerekli
Örnek Çalışma	Koba4MS [7], FSAdvisor [8]
Teknoloji	Bilgi Tabanlı Tavsiye Sistemi

Bu çalışmada özellikle bankacılık uygulamaları için en güncel tavsiye sistemleri çalışmaları özetlenmiştir. Tavsiye Sistemi Metotları bölümünde tavsiye sistemi yöntemlerinin kısa bir anlatımı verilmektedir. Bankacılıkta Tavsiye Sistemi bölümünde ise bankacılıkla ilgili tavsiye sistemi kullanım literatür bilgisi özetlenmiştir.

2 Tavsiye Sistemi Metotları

Tavsiye sistemleri mimarisi için farklı yaklaşımlar kullanılabilir. Kullanılan yaygın bir mimari 3 aşamadan oluşur: Aday Üretimi, Skorlama ve Tekrar Sıralama [5]. Mimari, çok büyük müşteri ve ürün verisinden daha küçük bir veri kümesini elde etmek için kullanılan bir dizi filtreleme adımından meydana gelir.

Aday Üretimi: Aday üretimi tavsiye sisteminin ilk aşamasıdır. Sistem bu aşamada, büyük bir aday havuzundan daha küçük bir alt küme oluşturur. Modelin hızlı bir şekilde çalışabilmesi için bu

aşamada birden fazla aday üreticisi farklı altkümeler üretebilir [5].

Skorlama: Diğer bir model bu aşamada, adayları skorlar ve sıralar [5].

Tekrar Sıralama: Son aşamada, belli kısıtlara göre adaylarda filtreleme yapar. Örneğin kullanıcının açıkça kullanamayacağı bir ürün var ise çıkartılır, yeniden sıralanır [5].

Tavsiye sistemlerini değerlendirirken bilinmesi gereken bir diğer önemli terim ise benzerlik metriğidir. Benzerlik metriği, tavsiye sistemlerinde iki öğenin ne kadar benzer olduğunu ölçmek için kullanılır. Örneğin, işbirlikçi filtreleme için A müşterisi ile B müşterisi geçmiş ürün etkileşim verilerine göre ne kadar benzerdir, ya da içerik tabanlı filtreleme için bir banka ürününün diğeriyle ne kadar benzer olduğunun ölçülmesi çeşitli metrikler kullanılarak ölçülebilir.

Benzerliğin ölçülmesi için birçok farklı yöntem bulunmaktadır. Kullanılan yöntem tavsiye sistemine bağlı olarak değişebilir. En yaygın kullanılan benzerlik metrikleri aşağıda sıralanmıştır.

Kosinüs Benzerliği: İki vektör arasındaki kosinüs açısının ölçülmesidir. Açının değeri 0'a yaklaştıkça iki vektör arasındaki kosinüs değeri ve dolayısı ile benzerlik artar. Kosinüs benzerliği formülü, A ve B vektörleri için aşağıda (1) verilmiştir.

$$\text{cosine_similarity}(A, B) = \frac{A \cdot B}{|A||B|} \quad (1)$$

Pearson Korelasyon Katsayısı: İki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü ölçer. Değerler -1 ile 1 arasında değişir. 1'e yakın değerler güçlü pozitif bir ilişkiyi, -1'e yakın değerler ise güçlü negatif bir ilişkiyi gösterir. Korelasyon katsayısı formülü (2) verilmiştir.

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (2)$$

Jaccard Benzerlik Katsayısı: İki küme arasındaki benzerliği ölçmek için kullanılır. İki kümenin kesişimini, bu kümelerin birleşimine bölerek elde edilir. Jaccard Benzerlik Katsayısı formülü (3) A ve B kümeleri için aşağıda verilmiştir.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (3)$$

Öklidyen Mesafesi: İki nokta arasındaki doğrusal mesafeyi ölçer. Matematiksel olarak, iki noktanın koordinatları arasındaki farkların karelerinin toplamının karekökü olarak tanımlanır. Öklidyen

mesafe formülü (4) aşağıda verilmiştir. Mesafe ne kadar küçükse benzerlik o kadar fazladır.

$$d(A, B) = \sqrt{\sum_{i=1}^n (a_i - b_i)^2} \quad (4)$$

Manhattan Mesafesi: İki nokta arasındaki mesafeyi, yatay ve dikey hareketlerle ölçer. Bu mesafe, iki noktanın koordinatları arasındaki mutlak değer farklarının toplamı olarak da tanımlanabilir. Manhattan mesafe formülü (5) aşağıda verilmiştir. Mesafe ne kadar küçükse iki vektör arasındaki benzerlik o kadar fazladır.

$$d(A, B) = \sum_{i=1}^n |a_i - b_i| \quad (5)$$

Nokta Çarpımı (Dot Product): Vektörlerin bileşenlerinin çarpımının toplamıdır. Vektörlerin normalleştirilmiş olduğu durumlarda benzerlik metriği olarak kullanılabilir. Nokta çarpımı (dot product) mesafe formülü (6) aşağıda verilmiştir.

$$A \cdot B = \sum_{i=1}^n a_i b_i \quad (6)$$

Bu bölümün devamında literatüre geçmeden önce, konu ile ilgili farklı tavsiye sistemleri yöntemleri verilmiştir.

2.1 İçerik Tabanlı Tavsiye Sistemi

İçerik tabanlı tavsiye sistemlerinde, sistem kullanıcının geçmişte tercih ettiği veya kullandığı ürünlere benzer ürünler önerir. Örneğin, kullanıcı komedi türünde bir film beğendiyse, komedi türündeki diğer filmler öneri olarak sunulur.

Bu yöntemde benzerlik metriği ürüne ait özelliklerden oluşturulan özellik matrisinden hesaplanır [9].

Tablo 2. Özellik Matrisi Örneği

	OZL1	OZL2	OZL3	OZL4
URN1	1	0	1	1
URN2	0	1	0	0
URN3	1	0	0	0
KUL1	1	0	1	0

Tablo 2’de Google Play’de yer alan uygulamalar için [5]’ye benzer içerik tabanlı filtreleme metoduna göre oluşturulan bir özellik matrisi sunulmuştur. Matriste her satır bir ürünü yani uygulamayı, her kolon ise bir uygulama özelliğini temsil etmektedir. Bu özellikler, uygulama kategorisi, uygulama yaratıcısı ve benzeri uygulama indirme bilgileri olabilir. Matris, kullanıcı bilgilerini de içerecek şekilde düzenlenmiştir; en alt satır, kullanıcıdan

elde edilen bilgilerle doldurulmuştur. Ancak bu matris yalnızca tek bir kullanıcıyı temsil eder ve diğer kullanıcıları içermez [5]. 1 ve 0 değerleri, o özelliğin var olup olmadığını göstermek için kullanılmıştır. Farklı bir sistemde farklı skorlarla da doldurulabilir. Tablo 2’de KUL1 satırı <1,0,1,0> vektörü ile ifade edilebilir. KUL1 vektörünün hangi uygulamayla eşleştirileceğine, hangi uygulamayla benzer özellikte uygulamaları tercih ettiğine göre karar verilebilir. Örneğin bu örnekte, nokta çarpımı benzerlik vektörü kullanılarak bir ürün tavsiye edileceğini varsayarsak, tüm uygulama vektörlerinin kullanıcı vektörü ile benzerliği karşılaştırılırsa, kullanıcıya nokta çarpımı 2 olan ve en yüksek benzerliğe sahip olduğu için URN1 ürünü tavsiye edilecektir.

Soğuk başlangıç (cold-start) problemi, öneri sistemlerinde yeni bir ürün veya kullanıcının sistemde yeterli geçmiş verisi olmadığından tavsiye üretilememesi sorunudur. İçerik tabanlı yöntem, ürün bilgilerine dayanarak yeni müşterilere öneriler sunabildiğinden, soğuk başlangıç problemi yaşanmaz.

İçerik tabanlı filtreleme yöntemi açıklaması kolay bir modeldir. Bu da bankacılık uygulamaları için önemli bir avantajdır. Ancak bu yöntemin zayıflığı, modelin büyük oranda metadata kalitesine bağımlı olmasıdır. Metadata kalitesi, kullanılan ürünün özelliklerinin iyi belirlenmiş olması ile belirlenir, bu da bankacılık sektöründe finansal uzmanlık gerektirir. Ayrıca, metadata tabanlı modeller genellikle finans alanında önerilmez, çünkü ürün kullanımını etkileyen diğer bağlamsal faktörlerin de dikkate alınması gerekmektedir [10]. İçerik tabanlı filtreleme yönteminin bir diğer dezavantajı ise modelin sadece kullanıcının mevcut ürün kullanım bilgileriyle sınırlı olmasıdır.

2.2 İşbirlikçi Filtreleme Tabanlı Tavsiye Sistemi

İşbirlikçi filtreleme yönetiminde, sistem kullanıcıya kendi profilinin benzer olduğu diğer kullanıcıların tercih ettiği ürünleri önerir. İki kullanıcı arasındaki benzerlik metriği, kullanıcıların geçmişteki derecelendirme veya işlem verilerinden hesaplanır. Bu yöntem aynı zamanda “kişiler arası korelasyon” (“people-to-people correlation”) adı da verilmektedir [1]. Örneğin Tablo 3’te örnek bir kullanıcı ürün matrisi verilmiştir. Bu matriste, kullanıcılar satırlar, ürünler sütun olarak verilmiş, matris değerleri ise kullanıcıların ürüne sahiplik durumunu belirten 0 veya 1 değerleri ile

doldurulmuştur. Bu değerlerin nasıl doldurulacağı kullanılan yöntemle göre değişiklik gösterebilir. Örneğin, RFM yöntemi ile müşteri işlem verilerinden dolayı olarak skor hesaplanabilir [11]. İşbirlikçi filtreleme, tavsiye sistemlerinde kullanılan en popüler yöntemlerden biridir. İşbirlikçi filtreleme metodu, kullanıcının işlem bilgilerini değerlendirerek davranışsal desen bilgilerini çıkarır. Bu bilgilere yalnızca metadeta verisiyle erişmek mümkün olmayabilir, dolayısıyla bu metod, metadeta tabanlı modellere kıyasla genellikle daha yüksek doğruluk oranlarına sahiptir. İçerik tabanlı metotlar kadar finansal uzmanlık bilgisine dayanmayan bu model, kullanıcıların yeni önerileri keşfetmesine yardımcı olabilir çünkü diğer kullanıcıları da hesaba katar. Ancak, işbirlikçi filtrelemenin sonuçlarını açıklamak zordur, ki bu da yüksek risk içeren finansal alanlar için potansiyel bir dezavantajdır [10]. Yeni bir ürün eklendiğinde, modelin bu ürün için öneri oluşturması mümkün olmayabilir (soğuk başlangıç problemi). Bu sorunu çözmek için, yeni bir ürün eklendiğinde, aynı kategorideki diğer ürünlerin ortalaması kullanılarak bir başlangıç noktası oluşturulabilir [5].

Tablo 3. Kullanıcı Ürün Etkileşim Matrisi Örneği

	URN1	URN2	URN3	URN4
KUL1	1	0	1	1
KUL2	0	1	0	0
KUL3	1	0	0	0

İşbirlikçi filtreleme yöntemi iki temel başlıkta ayrıştırılmaktadır, bunlar Bellek Tabanlı (Memory Based) ve Model Tabanlı (Model Based) İşbirlikçi Filtrelemedir.

2.2.1 Bellek Tabanlı İşbirlikçi Filtreleme (Memory Based Collaborative Filtering)

Bellek Tabanlı adından da anlaşılacağı gibi tarihsel kullanıcı - ürün etkileşimi verilerinin kullanılarak öneri sistemi oluşturulmasıdır. Bellek Tabanlı İşbirlikçi Filtreleme, kullanıcılara öneri sunulması için benzer kullanıcıların bilgisinin kullanıldığı Kullanıcı Tabanlı İşbirlikçi Filtreleme ve benzer ürünleri bulmak için kullanıcıların ürünlere verdiği puanların benzerliğinin temel alındığı Öğe Tabanlı İş Birlikçi Filtreleme Yöntemi olarak ikiye ayrılır. Bellek tabanlı işbirlikçi filtreleme bazı kaynaklarda komşuluk metotları (neighborhood methods) olarak da adlandırılmaktadır [12].

2.2.2 Model Tabanlı İşbirlikçi Filtreleme (Model Based Collaborative Filtering)

Model tabanlı işbirlikçi filtreleme yöntemi ise daha önceki yöntemlerden farklı olarak sadece benzerlik metriğine dayanmaktansa, genellikle makine öğrenimi teknikleri kullanılarak kullanıcılar ve ürünler arasındaki ilişkiyi yakalamaya çalışır. Bu yaklaşımda, kullanıcı-ürün etkileşim verisi üzerinden model eğitilir ve model tahminleri öneri oluşturmak için kullanılır. Bu bölüm makine öğrenmesi ile tavsiye sistemlerinin kesişim bölgesi olarak değerlendirilebilir.

2.2.2.1. Matris Faktörizasyonu (Matrix Factorization) Yöntemleri

Matris Faktörizasyonu, model tabanlı işbirlikçi filtreleme yöntemleri arasında en popüler olanlardandır. Kullanıcı ve ürün etkileşim matrisi, SVD (Singular Value Decomposition) gibi teknikler kullanılarak belirli sayıda bileşene ayrıştırılır. Sonraki aşamada, bir kullanıcının bir ürüne vereceği olası değerlendirme, ayrıştırılan matrislerin çarpımıyla tahmin edilir. Bu alanda kullanılan bazı matris ayrıştırma yöntemleri şunlardır: Matris Faktörizasyonu için Stokastik Gradyan İniş (Stochastic Gradient Descent - SGD), Negatif Olmayan Matris Faktörizasyonu (Non-negative Matrix Factorization - NMF), Alternatif En Küçük Kareler (Alternating Least Squares - ALS) ve Matris Faktörizasyonu ile Bayesian Personalized Ranking (BPR).

Matris faktörizasyonu metotları, kullanıcı-ürün etkileşim matrisini daha düşük boyutlu matrislere ayırarak gizli (latent) faktörleri ortaya çıkarmayı amaçlar. Bu nedenle, bu tür metotlar kimi kaynaklarda "gizli faktör modeli"(latent factor models) olarak da adlandırılır [12]. Bu modeller, gözlemlenen veride açıkça belirtilmeyen ancak kullanıcıların ve ürünlerin etkileşimlerini etkileyen gizli özellikleri veya faktörleri temsil eder.

2006 yılında Netflix'in mevcut film tavsiye sistemini (Cinematch) %10 oranında geliştirecek bir algoritma bulmayı amaçlayan yarışma Netflix Prize'da bu tür yöntemler öne çıkmış ve 2009'da sonuçlanan yarışma SVD gibi matris faktörizasyonu tekniklerinden faydalanan takımın başarısıyla sonuçlanmıştır [12].

2.3 Bilgi Tabanlı Tavsiye Sistemi

Bilgi-tabanlı tavsiye sistemleri, kullanıcı ihtiyaçlarına/tercihlerine karşılık gelen ürün özelliklerine dayalı olarak oluşturulan bir tekniktir.

Bu sistemde kullanıcı hakkındaki bilgiler genellikle bir bilgi edinme arayüzü aracılığı ile toplanır ve kişiselleştirilmiş öneri, elde edilen bilginin temsiline dayalı olarak hesaplanır. Bu sistemlerin avantajı, alan özelinde bilgiye ve kullanıcı seçimine dayalı kısıtlara dayanması ve açıklanabilir olmasıdır. Bilgi tabanlı yöntemler, finansal alanlar için karmaşık kullanıcı tercihlerini ele alabilecekleri için etkili çözümler olabilirler. Ancak, bu sistemlerin sürekli bakım ve güncelleme ihtiyacı vardır, bu da iş yükünü artırabilir [10].

2.4 Durum Tabanlı Tavsiye Sistemi

Durum Tabanlı Tavsiye Sistemleri (Case-Based Recommender Systems, CBRS), Durum Tabanlı Çıkarıma (Case-Based Reasoning, CBR) prensiplerini temel alır. Esasen, CBR yeni bir problemi çözme sürecinde, ilk olarak daha önce çözülmüş ve mevcut duruma benzeyen bir önceki durumu geri çağırır ve daha sonra bu durumu mevcut problemin çözümüne uygular. Bir durum, ürün tanımı, kullanıcı tercihleri, arama kriteri, durumun sonucu gibi çeşitli şekillerde tanımlanabilir [10]. Örneğin, bankacılık için, müşterinin para yatırma, para çekme, kredi kartı işlemleri gibi geçmiş bankacılık işlemleri bir durum tabanını oluşturabilir. CBR'nin en basit öneri oluşturma uygulamasında, durum tabanı önerilecek ürünleri modellemekte ve kullanıcının kısmen tanımladığı benzer ürünler durum tabanından çekilerek önerilen ürün seti oluşturulmaktadır [13]. CBRS karmaşık problemlerin çözümü için ele alınabilir ve açıklanabilir öneriler sunabilir. Musto ve arkadaşları [14] tarafından yapılan bir çalışmada, CBR'nin finansal alanlar için işbirlikçi filtrelemeye kıyasla daha iyi özelliklere sahip olduğu belirtilmiştir [10]. Bununla birlikte, bu tür yöntemler durumlar hakkında büyük miktarda veri gerektirmektedir [10].

2.5 Hibrit Tavsiye Sistemi

Hibrit tavsiye sistemleri, birden fazla tavsiye sistemi yöntemini birleştirerek oluşturulur. Bunun amacı, bir yöntemin avantajlarından kullanılarak diğer bir yöntemin dezavantajlarını gidermektir. Örneğin işbirlikçi filtreleme yönteminin soğuk başlangıç problemini- yani, yeni müşteriye ürün önerilememesi - içerik tabanlı filtreleme yöntemi ile aşılabilir, çünkü bu yöntem ürünün özelliklerine göre öneri oluşturur. Bu nedenle, iki yöntemin beraber kullanıldığı birçok çalışma bulunmaktadır [15].

3 Bankacılıkta Tavsiye Sistemleri

Bu bölümde literatür çalışmasına yer verilmiştir. Literatür çalışması Google Scholar aracılığı ile "recommendation systems in banking" anahtar kelimesinden çıkan sonuçlardan filtrelenmiştir. IEEE, Springer Link, ScienceDirect, ACM gibi veri tabanları kullanılmıştır. Ayrıca Zibriczky'nin ilgili derleme çalışmasından [10] da faydalanılmıştır. Çalışmalar kullanılan yöntemlere göre farklı başlıklarda sunulmuştur. Kimi çalışmalarda birden fazla yöntem kullanılmıştır, örneğin hibrit tavsiye sistemlerde işbirlikçi tavsiye sistemi de kullanılabilir [16, 17]. Çalışmaların gruplanması adına başlık olarak kullanılan bir yöntem seçilmiştir.

3.1 Bilgi Tabanlı Tavsiye Sistemleri Örnekleri

Fano ve Kurth [18] kullanıcıya interaktif bir şekilde kişisel finans yönetim yardımı sunan bir araç geliştirdiler. Araç, kullanıcının harcama, finansal hedefler ve zaman bilgilerine dayanarak optimize edilmiş bir algoritmayla öneriler sunmaktadır. Benzer bir şekilde, Felfernig ve Kiener [8] bir bilgi tabanlı tavsiye sistemi oluşturmuşlardır. Felfernig, aynı zamanda kural tabanlı bir tavsiye sistemi ile kredi önerisi sunan bir uygulama geliştirmiştir. Ancak, bu uygulamalar, kural tabanlı olduklarından sürekli bakım ve finansal uzmanlık bilgisi gerektirir [10].

3.2 Bankacılıkta İşbirlikçi Filtreleme Tavsiye Sistemleri Örnekleri

Gallego ve Huecas, bir İspanyol bankasının mobil bankacılık uygulaması için bağlama duyarlı bir tavsiye sistemi geliştirdiler [19]. Tavsiye sistemleri genellikle iki boyutlu bilgilere dayanır, bunlar ürün ve kullanıcıdır. Ancak, bağlama duyarlı tavsiye sistemlerinde sadece ürün ve kullanıcı değil, aynı zamanda ürünle bağlantılı olan bağlamsal değişkenler de dikkate alınır. Bu çalışmada ilk olarak sosyal boyut oluşturulmuştur. Müşterilerin cinsiyet, yaş ve yıllık ortalama kredi kartı harcamaları bilgileri ve kümeleme algoritmaları aracılığıyla müşteriler kümelerine ayrılmıştır. Ardından sosyal kümeler kredi kartı işlem bilgileri ile eşleştirilmiş ve son olarak alışveriş yapılan yerler de bu veri kümesine eklenmiştir. Çalışmanın ikinci aşaması kullanıcının konumunu alınması, son boyutta ise anlık saat ve aktivite bilgisi alınması hedeflenmiştir.

Bu model, müşterilere, benzer kümelerdeki kullanıcıların kredi kartı harcamaları yaptığı yer bilgileri ile oluşturulmuş yer önerilerini

sunmaktadır. Bu sistem İspanyol bankası tarafından gerçek ortamda kullanılmış ve müşterilerden olumlu geri dönüşler alınmış olması yönüyle de önemlidir. Gallego ve Huecas'ın çalışmasında açıkça işbirlikçi filtreleme metodundan bahsedilmese de bu çalışmada benzer kullanıcılara, diğer kullanıcıların geçmişte harcama yaptığı yerler üzerinden tavsiye üretildiği için bu kategoriye dahil edilmiştir.

Sharifhosseini'nin İran'da bir banka için yaptığı çalışmada, tavsiye sistemi teknolojisi, müşterilerin daha önce banka kartını kullanmadıkları ancak kullanabilecekleri olası POS yerlerini tahmin etmek ve müşterilere harcama önerisi olarak sunmak amacıyla kullanılmıştır [11]. Bu çalışmada, kapalı geri bildirim elde etmek için RFM (Recency, Frequency, Monetary) metodu ve K-Means algoritması kullanılmıştır. Veri seti, İran'daki bir özel bankanın debit kart kullanım verilerinden oluşmaktadır. Veri seti, müşterilerin başarılı POS işlem bilgileri ve harcama yerlerinden oluşmaktadır.

Müşteri No, Şube Kodu ve Final Etiket (reyting skoru) verileri, reyting matrisi oluşturmak için kullanılmıştır. İşbirlikçi Filtreleme Tabanlı, Genelleştirilmiş Tekil Değer Ayrıştırması (Generalized Singular Value Decomposition) kullanılarak, müşterinin bir sonraki harcama yerini tahmin eden bir tavsiye sistemi oluşturulmuştur.

Gigli, Lillo ve Regoli, büyük bir Avrupa bankası tarafından sağlanan yatırım ürününün satın alınıp alınmadığına dair ikili hedef değişkeni olan bir veri seti üzerinde çeşitli tavsiye sistemi yöntemlerini uygulayarak karşılaştırmışlardır [20]. Çalışmada, en popüler ürünlerin veri setinden çıkarılmasıyla modelin kişiye özel ürün sunma başarısının daha ölçülebilir hale geldiği belirtilmiştir. Eğer popüler ürünler veri setinden çıkarılmazsa, en başarılı algoritmanın Bayesian Personalized Ranking with Matrix Factorization olduğu, ancak 50 popüler ürün çıkarıldığında en iyi algoritmanın ALS (Alternating Least Squares) olduğu belirtilmiştir.

Matris faktörizasyonu yöntemlerinin dışında, ürün etkileşim verisinin sınıflandırma problemine dönüştürülerek tavsiye sistemi oluşturulması da mümkündür. Jaramillo ve diğerleri, Kaggle'daki "Santander Product Recommendation" yarışmasından [15] elde edilen geçmiş banka işlem tarihçesi verisi üzerinde farklı sınıflandırma modellerini karşılaştırmışlardır [21]. Bu çalışmada, Çok Değişkenli Uyarlamalı Regresyon (Multivariate

Adaptive Regression Splines (MARS)) modelinin en başarılı sonucu verdiği belirlenmiştir.

Kaggle'daki "Santander Product Recommendation" yarışmasında 1. Sırada yer alan çözüme bakıldığında yine [21] ile benzer bir yaklaşımla çözüldüğü görülmektedir [22]. 24 ürün tahmininden oluşan veriseti kullanılacak alt modele göre ya çok hedefli ya da çok terimli olacak şekilde bir ön işleme adımından geçmiş ve sınıflandırma problemi olarak çözülmüştür. Sinir Ağları ve Gradyan Artırma Makineleri (Gradient Boosting Machines - (GBM)) ile kurulan ensemble model en başarılı çözüm olarak öne çıkmaktadır.

3.2 Bankacılıkta Duygu Analizi ile Tavsiye Sistemleri Örnekleri

Ghobakhloo ve Ghobakhloo tarafından gerçekleştirilen çalışmada, diğer çalışmalardan farklı olarak duygu analizi ile tavsiye sistemi oluşturulmuştur. Twitter duygu analizi kullanılarak bankacılık sektörü için kişiselleştirilmiş bir tavsiye sistemi geliştirilmiştir [23]. Bu yöntemde veri kümesi, müşterilerin banka hizmetleri hakkındaki görüş ve deneyimlerinden oluşmaktadır. Müşteri görüşleri ve deneyimleri, Twitter'da bankanın hizmetleriyle ilgili etiketlerin çıkarılması ve bu veriyle duygu analizi çalışması yapılması sonucu oluşturulmuştur. Çalışmada izlenen adımlar aşağıda verilmiştir:

1. Twitter'da İran'da en çok tercih edilen bankacılık hizmetlerine ilişkin Farsça etiket bilgileri, #marriage loan, #housing loan, #car loan, #property renovation loan, #construction loan, #home appliance loan ve #business startup loan gibi, araştırılmış ve ilgili tweetler toplanmıştır. Her bir tweet'in metni, yazarı, beğeni ve retweet bilgileri de kaydedilmiştir.

2. Duygu analizi, bir önceki adımda toplanan tüm tweetler için kişilerin ilgili bankacılık ürünü hakkında pozitif veya negatif bir düşünceye sahip olup olmadığı bilgisini belirlemek için kullanılmıştır. Duygu analizi için CNN ve Naive Bayes modellerinin kombinasyonu kullanılmıştır.

Kullanıcıların bankacılık hizmetleri hakkındaki ilgileri ve duygu tipleri tespit edildikten sonra hesaplanan duygu skoru ve benzerlikleri bularak bankacılık hizmetleri almak için en iyi seçenek bireylere sunulmuştur.

3.3 Bankacılıkta Hibrit Tavsiye Sistemleri Örnekleri

Oyebode ve Orji tarafından sunulan çalışmada, bankacılıkta tavsiye sistemlerinin kullanılmasındaki engellerin açık geri bildirim eksikliği ve soğuk başlangıç problemlerinin olduğu vurgulanmıştır. Bu problemleri çözmek için, demografik bilgilere dayanan ve işbirlikçi filtreleme yöntemini kullanan beş aşamalı bir hibrit tavsiye sistemi önerilmiştir [16]. Tavsiye sisteminin amacı müşteriye en uygun ürün önerisinin sunulmasıdır. Çalışmadaki yöntem aşağıda özetlenmiştir;

- 1- Product Rating (PR) algoritması ile işlem geçmişi verilerinden yola çıkarak, her kullanıcıya her bankacılık ürünü için 1-5 arası puan atanması sağlanır. Puan kullanıcının bankacılık ürününü ne kadar sık kullandığına göre değişmektedir.
- 2- PR algoritması ile elde edilen veri kullanılarak, işbirlikçi filtreleme yöntemi ile puanlanmamış ürünler için puan tahmini yapılır.
- 3- Müşteri demografik verileri (yaş, cinsiyet, medeni durum, meslek) kullanılarak, müşteriler K-Means algoritması ile kümelendir ve her kümeye elde edilen ortalama puan atanır.
- 4- Dinamik ortalama tekniği ile tahmin edilen ve ortalama puanlar birleştirilir.
- 5- Müşteriye (yeni veya mevcut), daha önce kullanılmamış ve kullanıcının kullanabileceği tahmin edilen 10 ürün önerilir.

2021 yılında ING Bankası, Perakende Bankacılık için hibrit bir tavsiye sistemi tasarlamıştır [17]. Bu sistemde, ALS ve çok-kollu haydut (multi-armed bandit) algoritmaları bir arada kullanılmıştır. Çalışmada vurgulandığı üzere, tüm disiplinlerde başarı sağlayan tek bir makine öğrenme algoritmasının olmadığı (No Free Lunch teoremi) kabul edilmiştir. Bu nedenle, mevcut veriye en iyi yanıtı veren model seçilmiştir. Tavsiye sistemi, müşterilerin dijital davranışlarına, olumlu veya olumsuz etkileşimlerine ve satış ile ürün dönüşümlerine dayanarak çalışır. Bu, müşterinin bir kampanya linkine tıklamasını ve ardından bir ürün satın almasını içerir. Ayrıca, daha zengin öneriler sunmak için müşteri özellikleri ve eğilim modelleri temel alınarak segmentasyon yapılmıştır. Bu segmentasyon, ALS algoritmasının daha önce geri bildirimde bulunmamış müşteriler için tahminler yapmasına olanak tanır. Modelde, en yeni ve en az tercih edilen ürünlerin seçiminde çok-kollu haydut algoritması kullanılmıştır, bu da soğuk başlangıç probleminin üstesinden gelmeyi amaçlar.

3.4 Bankacılıkta Durum Tabanlı Tavsiye Sistemi Örnekleri

Hernández-Nieves ve diğer çalışma arkadaşlarının CEBRA adını verdikleri çalışmada, bulut tabanlı sis bilişim mimarisi kullanarak durum tabanlı bir tavsiye sistemi geliştirmiştir [24]. Bu sistem, kullanıcıların geçmiş deneyimlerini temel alarak kişiselleştirilmiş öneriler sunmaktadır. Araştırmada, Durum Tabanlı Çıkarıma (Case-Based Reasoning) yöntemi kullanılmış ve bir makine öğrenme tekniği olarak uygulanmıştır.

Veri seti olarak, durum tabanlı bir yaklaşımla oluşturulan bir veri sözlüğü kullanılmıştır. Bu sözlükte, müşterilerin demografik bilgileri ve ürün sahipliği özelliklerini (ürüne başvurma, ürün sahipliği, ilk başvuru gibi) içermektedir. Ek olarak, sosyal medya üzerinden müşterinin ilgi alanlarına dair bilgiler alınabilecek bir kategori ve özellik seti oluşturulmuştur.

Takiben, müşteriler arasındaki benzerlikler hesaplanmıştır. Benzerlik skorları belirlendikten sonra, her kullanıcı için en yakın k benzer kullanıcı belirlenmiştir. Benzerlik skorları oluşturulurken müşterilerin farklı özelliklerine (yaş, çocuk, iş) göre farklı benzerlik metrikleri tasarlanması dikkat çekmektedir. Benzerlik skorlarının belirlenmesinin ardından, CBR (Case-Based Reasoning) kullanılarak en yakın olarak belirlenen müşterilerin en çok tercih ettiği ürün, tavsiye modelinin çıktısı olarak sunulmuştur.

3.5 Bankacılıkta Derin Öğrenme ile Tavsiye Sistemi Örnekleri

Liu ve arkadaşları tarafından yapılan bir başka çalışmada, İspanyol Bankası Bank Santander'ın Kaggle'da yayınlanan "Santander Product Recommendation" veri seti [15] kullanılarak, ürün sahipliği ve kullanıcı meta verilerinin zamansal bağlamını hesaba katan bir model sunulmuştur [25]. Bu yöntem, dil modellemeye benzer bir yaklaşım kullanarak, zaman periyodlarını kelime olarak temsil etmiştir ve her bir periyod bir harfle temsil edilmiştir. Diğer veri ön işleme yöntemlerinden farklı olarak kullanılan veri, dil modelleme verilerine benzetilerek sıralı olarak hazırlanıp modele girdi olarak verilmiştir. Girdi T kelimedenden oluşan bir metin olarak oluşturulmuştur.

Zamansal girdi gösterimi daha önce, e-ticaret ya da video platformlarında da kullanılan oturuma dayalı tavsiye sistemleri için de kullanılmıştır. Ancak, bu modellerde tüm geçmiş etkileşimler verilmeden,

yinelemeli sinir ağı (RNN) metodu kullanılmıştır [25].

Avcı ve Sakar tarafından gerçekleştirilen çalışmada, Kaggle Santander Bankası ürün geçmişi veri seti [20] kullanılmıştır. Veri setinde bir müşteriye ait aylık ürün hareket bilgisi ikili sistem ile gösterilmiş, o ay ilgili ürüne sahipse 1 değilse 0 olarak işaretlenmiştir. Hazırlanan veri kümesine e-ticaret verilerine önceden uygulanmış olan Dinamik Tekrarlayan Sinir Ağı (DREAM) mimarisi ile uygulanmıştır [26]. Bu uygulama sonucunda, DREAM modelinin bankacılık sektöründe tavsiye sistemi tasarımı için potansiyel oluşturduğu belirtilmiştir.

4 Bankacılık Sisteminde Tavsiye Sistemi Kullanımı Kısıtları

Bankacılık uygulamalarında tavsiye sistemlerinin kullanılmasının bazı kısıtlamaları bulunmaktadır. Bu kısıtlamalar; gizlilik, soğuk başlangıç problemi, açık geri bildirim eksikliği, güvenlik sorunları ve büyük veri setlerindeki yavaşlama olarak sıralanabilir [1].

- **Gizlilik:** İşbirlikçi filtreleme tavsiye sistemlerinde, daha doğru önerilerde bulunabilmek için benzer kullanıcıların işlem bilgilerine başvurulur. Bu tür bilgilerin kullanımı, kullanıcının rızası gerektirebilir, bu nedenle veri koruma ve gizlilik politikalarına uygun hareket edilmesi önemlidir.
- **Soğuk Başlangıç:** Yeni müşteriler ve yeni tanımlanan ürünler için mevcut verinin olmayışı, tavsiye sistemlerinin etkinliğini sınırlayabilir. Bu durum, müşteri ve ürün veri tabanının genişletilmesine bağlı olarak zamanla çözülebilir.
- **Açık Geribildirim Eksikliği:** Bankacılık sektöründe, kullanıcıların ürünlere doğrudan bir değerlendirme yapması genellikle olası olmaz. Bu nedenle, tavsiye sistemlerinin metriklerini oluşturmak için işlem bilgileri kullanılır.
- **Güvenlik:** Tavsiye sistemleri, sahte bilgilerin ve olası manipülasyonların oluşturabileceği risklere karşı korunmalıdır. Özellikle puanlama sistemlerinde, sistemi manipüle etmek amacıyla yapılan yanıltıcı değerlendirmelere karşı önlem alınması gereklidir. Bankacılıkta ise, belirli işlemler tavsiye sistemine dahil edilmeden önce dikkatli bir şekilde incelenmelidir.
- **Hız:** Büyük veri setlerini işleyen tavsiye sistemleri algoritmaları yavaş çalışabilir ve bu, kullanıcıya en güncel tavsiyelerin sunulmasını

engelleyebilir. Sistemin, kullanıcılara en güncel tavsiyeleri sunabilmek için büyük veri setlerinde hızlı bir şekilde çalışabilmesi kritiktir. Modeller, eğitildikleri andaki verilere dayanarak önerilerde bulunurlar. Model eğitildikten sonra kullanıcı tercihlerindeki değişiklikleri otomatik olarak yakalayamazlar. Bu nedenle, kullanıcı tercihlerinde önemli değişiklikler olduğunda veya yeni kullanıcı veya ürün eklendiğinde modelin düzenli olarak yeniden eğitilmesi ve güncellenmesi gerekmektedir.

5 Sonuçlar

Bankacılık sistemlerinde kullanılan tavsiye sistemleri literatür çalışmasında konuyla ilgili çeşitli makaleler detaylı bir şekilde anlatılmıştır. Tablo 4'de çalışma yapılan yıla göre sıralı özet bilgiler verilmiştir. İşbirlikçi filtreleme çoğu modelde kullanıldığı için tabloda bu kategoriye ait alt kategoriler verilmiştir.

Tablo 4. Literatür Çalışması Özeti

Kaynak	Yöntem	Veri Seti
[2] (Fano ve Kurth, 2003)	Bilgi Tabanlı	Kullanıcı arayüzü ile alınan kullanıcı tercihleri ve finansal uzmanlık bilgisi
[3] (Felfernig ve Kiener, 2005)		
[5] (Gallego ve Huecas, 2012)	Bağlama Duyarlı	Bir İspanyol bankası müşteri demografik, kredi kartı harcama ve harcama yerleri verisi
[7] (Gigli vd., 2017)	Matris Faktörizasyonu	Bir Avrupa bankasına ait yatırım ürünü kullanım verisi
[10] (Hernández, 2019)	Durum Tabanlı	Bir bankaya ait müşteri demografik bilgileri ve çeşitli ürünlere ait kullanım verileri
[11] (Sharifhosseini, 2019)	Matris Faktörizasyonu	Bir İran Bankasına ait debit kart kullanım verileri
[16] (Oyebode ve Orji, 202)	Hibrit	Bir bankaya ait, müşteri demografik verileri ve çeşitli ürünlere ait işlem tarihçe verisi

[26] (Avcı ve Sakar, 2021)	Derin Öğrenme	Santander Product Recommendation [15]
[21] (Jaramillo, 2021)	Sınıflandırma Modeli	Santander Product Recommendation [15]
[25] (Vaquero vd., 2021)	Hibrit	ING Bankası Müşteri kampanya etkileşimleri, müşteri ürün etkileşimleri, müşteri özellik ve eğilim modelleri
[23] (Ghobakhloo, ve Ghobakhloo, 2022)	Duygu Analizi	Banka hizmetleri etiketli Twitter verisi
[11] (Liu vd., 2022)	Derin Öğrenme	Santander Product Recommendation [15]

İncelenen makalelerde, içerik tabanlı filtreleme sisteminin uygulama örneğine rastlanmamıştır. Bunun nedeni bankacılık ürün yelpazesinin kısıtlılığı ve bu yöntem için gerekli olan ürün özelliklerinin çıkarılması aşamasının büyük oranda uzman bilgisi gerektirmesi olabilir. Ek olarak, Bellek tabanlı işbirlikçi filtreleme sistemlerinin de daha nadir olarak tercih edildiği dikkat çekmiştir. Tavsiye sistemlerinde, kullanıcılar ve ürünler arasındaki etkileşimleri temsil eden matris genellikle seyreklerdir. Bankacılık sektöründe açık geri bildirim olmaması ve müşterilerin her birinin tüm ürünlerle etkileşimi olmayabileceğinden, kullanıcı ürün matrisi daha seyrek olması anlaşılabilir. İçerik tabanlı ve bellek tabanlı işbirlikçi filtreleme sistemleri doğrudan kullanıcı ürün matrisine dayandığından daha az tercih edilmeleri olasıdır. Bu iki yöntemin daha az kullanılmasının bir diğer sebebi ise kullanıcı ürün etkileşiminin dışında ürün kullanımı etkileyen diğer bağlamsal faktörlerin de olabilmesidir.

Bir diğer önemli nokta ise bankacılık sektörü için müşteri ürün etkileşiminin yalnızca kapalı geri bildirim dayanmasıdır. Müşterilerin ürünlere ait açıkça bir değerlendirmesi olmadığından, reyting bilgisinin ürün etkileşimine göre oluşturulması veri ön işleminin en önemli parçalarından biri olduğu ve çalışmalarını birbirinden ayıran anahtar noktalardan biri olduğu görülmüştür.

En yaygın tavsiye sistemi yöntemi olan işbirlikçi filtreleme ise, bellek veya model tabanlı olsun, belli miktarda kullanıcı ürün etkileşim verisine ihtiyaç

duymaktadır. Bu nedenle soğuk başlangıç problemini çözmek için yeni müşteriye sunulacak ürün yöntemi belirlenmelidir. Yapılan bazı çalışmalarda bu problemin çözümü için hibrit sistemler kullanıldığı gözlenmiştir [16, 17].

Ayrıca model tabanlı işbirlikçi filtreleme yöntemi sonuçları açıklanabilir olmadığından, öneri nedeninin açıkça belirtilmesi gereken durumlarda kullanılması potansiyel riskleri beraberinde getirebilir. Eğer tavsiye sisteminde açıklanabilirlik ve finansal alan bilgisi önemli ise bilgi tabanlı filtreleme tavsiye sistemleri tercih edilebilir.

Teşekkür

Bu çalışma sürecindeki destekleri için Vakıfbank ARGE ekibine teşekkürlerimi sunarım.

Kaynaklar

- [1] Ricci, F., Rokach, L., Shapira, B. and Kantor, P. B, Recommender Systems Handbook. Boston, MA: Springer US. doi: 10.1007/978-0-387-85820-3. 2011.
- [2] Dong, Z Wang, X Xu, Jun Tang, R Wen, J, A Brief History of Recommender Systems, s. In Proceedings of ACM Conference (Conference'17). ACM, New York, NY, USA, 9 pages, 2022.
- [3] Goldberg, D. Nichols, D. Oki, B. M. and Terry, D., Using collaborative filtering to weave an information tapestry. Communications of The ACM 35, 12 (1992), 61–70, 1992.
- [4] Resnick, P. Iacovou, N. Suchak, M. Bergstrom, P. and Riedl, J., GroupLens: An Open Architecture for Collaborative Filtering of Netnews. Research Papers in Economics, 1994.
- [5] Recommendations: What and Why?, Recommendation Systems Google Developers. <https://developers.google.com/machine-learning/recommendation/overview> (18.11.2022).
- [6] Schafer, J.B., Konstan, J.A. & Riedl, J. E-Commerce Recommendation Applications. Data Mining and Knowledge Discovery 5, 115–153. <https://doi.org/10.1023/A:1009804230409>, 2001.
- [7] Felfernig, A. , Koba4ms: Selling complex products and services using knowledge-based recommender technologies. In: CEC '05: Proceedings of the Seventh IEEE International Conference on E-Commerce Technology (CEC'05), pp. 92–100. IEEE Computer Society, 2005.
- [8] Felfernig A. and Kiener A., Knowledge-based Interactive Selling of Financial Services with FSAdvisor, American Association for Artificial Intelligence (www.aaai.org), 100, 1475–1482, 2005.
- [9] Sharaf, M. Hemdan, E.E.D. El-Sayed, A ve El-Bahnasawy, N. A. A survey on recommendation systems for financial services Multimedia Tools and Applications (2022) 81:16761–16781, 2022.

- [10] Zibriczky, D. Recommender Systems meet Finance: A literature review, in. doi: 10.13140/RG.2.1.1249.2405, 2016.
- [11] Sharifhosseini, A. . A Case Study for Presenting Bank Recommender Systems based on Bon Card Transaction Data. 2019 9th International Conference on Computer and Knowledge Engineering (ICCKE), 2019.
- [12] Y. Koren, R. Bell and C. Volinsky, "Matrix Factorization Techniques for Recommender Systems," in *Computer*, vol. 42, no. 8, pp. 30-37, Aug. 2009, doi: 10.1109/MC.2009.263, 2009.
- [13] Lorenzi, F. and Ricci, F., Case-Based Recommender Systems: a Unifying View, in *Proceedings of the 2003 International Conference on Intelligent Techniques for Web Personalization, ITWP'03*, pp. 89-113, Berlin, Heidelberg, 2003.
- [14] Musto, C. Semeraro G. Lops, P. Gemmis, M. ve Lekkas G., 'Personalized finance advisory through case-based recommender systems and diversification strategies', *Decision Support Systems*, 77, 100-111, 2015.
- [15] Santander Product Recommendation, Can you pair products with people? <https://www.kaggle.com/c/santander-product-recommendation> (18.11.2022).
- [16] Oyebode, O., & Orji, R., A hybrid recommender system for product sales in a banking environment. *Journal of Banking and Financial Technology*, 4(1), 15-25. <https://doi.org/10.1007/s42786-019-00014-w>, 2020.
- [17] Vaquero-Patricio, C. Ommeren N. Gil-Begue S. Recommenders in Banking: An End-to-end Personalization Pipeline within ING, *RecSys '21*, September 27-October 1, 2021, Amsterdam, Netherlands, 2021.
- [18] Fano, A. and Kurth, Scott W, Personal Choice Point: Helping users visualize what it means to buy a BMW', *Control*, 46-52, 2003.
- [19] Gallego, V. D. ve Huecas, G., Generating Context-aware Recommendations using Banking Data in a Mobile Recommender System, *ICDS 2012 : The Sixth International Conference on Digital Society Generating*, 73-78, 2012.
- [20] Gigli, A., Lillo, F., & Regoli, D., Recommender systems for banking and financial services. *Conference on Recommender Systems*, 1905, 1-2. http://ceur-ws.org/Vol-1905/recsys2017_poster13.pdf, 2017.
- [21] Jaramillo, I.F., Villarroel-Molina, R., Pico, B.R., Redchuk, A.. A Comparative Study of Classifier Algorithms for Recommendation of Banking Products. In: Rocha, Á., Adeli, H., Dzemyda, G., Moreira, F., Ramalho Correia, A.M. (eds) *Trends and Applications in Information Systems and Technologies. WorldCIST 2021. Advances in Intelligent Systems and Computing*, vol 1366. Springer, Cham. https://doi.org/10.1007/978-3-030-72651-5_25, 2021.
- [22] Santander Product Recommendation | Kaggle.. <https://www.kaggle.com/competitions/santander-product-recommendation/discussion/26835> (26.08.2023).
- [23] Ghobakhloo, M., Ghobakhloo, M., Design of a personalized recommender system using sentiment analysis in social media (case study: banking system), *Social Network Analysis and Mining* (2022) 12:84, 2022.
- [24] Hernández-Nieves E., Hernández, G., Gil-González, A.B., Rodríguez-González S. Corchado, J. M., Fog computing architecture for personalized recommendation of banking products, 2019.
- [25] Liu, D. Farajalla, G. P. ve Boulenger, A., BRec the Bank: Context-aware Self-attentive Encoder for Banking Products Recommendation, 2022 International Joint Conference on Neural Networks (IJCNN), 2022, pp. 1-8, 2022.
- [26] H. A. C. Okan Sakar, "A Dynamic Recurrent Neural Networks-Based Recommendation System for Banking Customers," 2021 29th Signal Processing and Communications Applications Conference (SIU), Istanbul, Turkey, 2021, pp. 1-4, doi: 10.1109/SIU53274.2021.9477967, 2021.