

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ÇAPRAZ E-TİCARET PAZARLARINDA HİBRİT ÖNERİ SİSTEMİ

YÜKSEK LİSANS TEZİ

Emre KÖSE

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

AĞUSTOS 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ÇAPRAZ E-TİCARET PAZARLARINDA HİBRİT ÖNERİ SİSTEMİ

YÜKSEK LİSANS TEZİ

**Emre KÖSE
(504181559)**

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Thesis Advisor: Assoc. Dr. Yusuf YASLAN

AĞUSTOS 2023

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**HYBRID RECOMMENDATION SYSTEM AT CROSS E-COMMERCE
MARKETS**



M.Sc. THESIS

**Emre KOSE
(504181559)**

Department of Computer Engineering

Computer Engineering Programme

Thesis Advisor: Assoc. Dr. Yusuf YASLAN

AUGUST 2023

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504181559 numaralı Yüksek Lisans Öğrencisi Emre KÖSE, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ÇAPRAZ E-TİCARET PAZARLARINDA HİBRİT ÖNERİ SİSTEMİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Yusuf YASLAN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Şule Gündüz ÖĞÜDÜCÜ**
İstanbul Teknik Üniversitesi

Doç. Dr. Muhammed Ali AYDIN
İstanbul Üniversitesi

Teslim Tarihi : 1 Temmuz 2023
Savunma Tarihi : 4 Ağustos 2023





Aileme,



ÖNSÖZ

Çok değerli Yusuf Yaslan Hocama, veriden öğrenme araştırma ekibindeki çalışma arkadaşlarıma desteklerinden ötürü teşekkür ederim.

Ağustos 2023

Emre Köse
(Bilgisayar Mühendisi)





İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET	xix
SUMMARY	xxiii
1. GİRİŞ	1
2. ÖNERİ SİSTEMLERİ.....	3
2.1 İşbirlikçi Öneri Sistemi	3
2.2 İçerik Tabanlı Öneri Sistemi	4
2.3 Hibrit Tabanlı Öneri Sistemi	5
2.4 Öneri Sistemlerinde Kullanılan Değerlendirme Metrikleri.....	6
3. ÇİZGE SINIR AĞLARI VE ÖNERİ SİSTEMLERİNDE KULLANIMI ÖN HAZIRLIK.....	9
3.1 Çizge Sinir Ağları.....	9
3.2 Çizge Ağı Tabanlı Öneri Sistemleri	11
3.2.1 Sinir çizge işbirlikçi filtreleme	12
3.2.2 PinSAGE.....	14
4. ÇAPRAZ PAZAR ÖNERİ PROBLEMİ	17
5. İKİ AŞAMALI ÇİZGE AĞI EĞİTİMİ İLE ÇAPRAZ PAZAR ÖNERİ SİSTEMİ.....	19
5.1 Hafif Çizge Evrişimli Ağ	19
5.2 İki Aşamalı Hibrit Çizge Ağı Eğitimi	20
6. DENEYLER ve DEĞERLENDİRME	23
6.1 Veri Kümesi	23
6.2 Model Mimarileri ve Hiper-parametreler	24
6.3 Veri Kümesi İstatistikleri	25
7. SONUÇ VE GELECEK ÇALIŞMALAR	31
KAYNAKLAR	33
ÖZGEÇMİŞ.....	35

KISALTMALAR

XMREC	: Cross Market Recommendation
MAML	: Model Agnostic Meta Learning
LGCN	: Light Graph Convolution Network
NGCF	: Neural Graph Collaborative Filtering
YSA	: Yapay Sinir Ağı
HÖS	: Hibrit Öneri Sistemi
DP	: Doğru Pozitif
DN	: Doğru Negatif
YP	: Yanlış Pozitif
YN	: Yanlış Negatif



SEMBOLLER

σ	: Aktivasyon fonksiyonu
$\mathbf{e}_u$	: u düğümü temsil vektörü
$\mathbf{W}_1, \mathbf{W}_2$	: Ağırlık matrisleri
$\mathbf{N}_u$	: u düğümü komşular kümesi
$\mathbf{M}_{\text{kaynak}}, \mathbf{M}_{\text{hedef}}$	: Kaynak ve hedef pazar
k	: GCN içindeki katman sayısı
l	: GCN içindeki düğüm temsil uzunluğu
k_u	: Kümeleme katsayısı (u düğümü için)



ÇİZELGE LİSTESİ

Sayfa

Çizelge 6.1 : Hedef Pazar Ortalama Değerleri.	25
Çizelge 6.2 : Modellerin nDCG@10 Performans Karşılaştırması.	28





ŞEKİL LİSTESİ

Sayfa

Şekil 3.1 : Çizge örneği.	9
Şekil 3.2 : Çizgeden çizge sınır ağına dönüşüm (Ying ve diğ., 2018).	10
Şekil 3.3 : İki parçalı çizge gösterimi.	11
Şekil 3.4 : NGCF yüksek dereceli kullanıcı-öge etkileşimi (Wang ve diğ., 2019). ..	13
Şekil 5.1 : İki aşamalı çizge ağı eğitim akışı.	22
Şekil 6.1 : Soldan-sağa, yukarıdan aşağı sırasıyla Japonya, Almanya, Meksika ve İngiltere pazarları ilinti matrisleri.	27



Çapraz E-ticaret Pazarlarında Hibrit Öneri Sistemi

ÖZET

Öneri sistemleri, film, müzik, e-ticaret ve diğer çeşitli platformlarda, çeşitli algoritmalar kullanarak kullanıcıların ihtiyaçlarına uygun ürünlerin tavsiye edilmesini amaçlamaktadır. Bu algoritmalar genellikle kullanıcı-öge temsillerini elde ederek öneri yapmaktadır. Çalışmalar başlangıçta matris çarpanlarına ayırma ile ilerlerken, daha sonra hem işbirlikçi hem de içerik tabanlı önerilerde farklı bellek veya model tabanlı yaklaşımlar geliştirilmiş ve geliştirilmeye devam etmektedir.

Çapraz pazar öneri problemi sosyal medya, e-ticaret uygulamaları ve diğer çevrimiçi platformlarda ortaya çıkmış, farklı kaynak pazarın/pazarların verilerini kullanarak, hedef pazar olarak adlandırılan kısıtlı veri kümesinde kullanıcılara öneri amaçlayan yeni bir çalışma alanı olarak ifade edilebilir. Veriden öğrenme aşamasında dikkat edilmesi gereken bazı noktalar bulunmaktadır. Kaynak pazarların verisinden öğrenilen ve optimize edilen modeller, hedef pazarın davranışları dikkate alınmadan uygulanırsa sorunlu sonuçlar ortaya çıkabilmektedir. Örneğin giyim kategorisinin diğer kategorilere göre daha yoğun kullanıldığı bir ülke düşünelim. Bu ülkenin ortalama sıcaklığı hedef pazardan çok daha yüksekse, kaynak pazarda standart pantolon alan bir müşteriye tişört önermek mantıklı olabilir ancak bu hedef pazarda alakasız olabilir. Bu nedenle verilerden öğrenme, her iki pazardaki dağılımları ve yanlılıkları dikkate alabilen bir kapsamda olmalıdır.

Çapraz pazar öneri sistemleri son yıllarda ortaya çıkmış yeni sayılabilecek bir konu olarak ifade ediliyor olsa da bahsi geçen yöntemler burada farklı şekillerde çözüm olarak kullanılabilmektedir. Literatürde, FOREC algoritması bu alanda hem getirdiği çözüm hem de sağladığı açık kaynak veri kümesi ile önemli bir çalışma olarak yer almaktadır. Pazar adaptasyonu ve meta-öğrenme kavramları üzerinde ilerlenerek, 2021 yılında yayınlanan Pazarlar Arası Ürün Önerisi araştırmasında geliştirilen çoklu ağ yapısına sahip algoritma, XMarket ismiyle 18 yerel pazarın, yani ülkenin, 16 farklı kategorideki kullanıcı-öge ikililerini ve skorlarından oluşan veri kümesini de içermektedir. Algoritma içinde ilk olarak GMF, MLP ve NMF modellerini kullanarak pazar-bağımsız, yani kaynak ve hedef pazar verisinin birlikte kullanıldığı bir eğitim gerçekleştirilir. Bu adımda buna ek olarak MAML çerçevesi ile few-shot öğrenme tekniğini de kullanır. İkinci aşamada ise pazara-özel olarak ifade edilen sadece hedef pazar verisi ile ekstra MLP katmanları eğitilerek FOREC sistemi eğitimi tamamlanmış olur.

Yapay sinir ağları milyonlarca parametre ile ürün-kullanıcı çiftleri ile beslenerek, benzerliklerini anlayabileceğimiz ve karşılaştırabileceğimiz temsiller elde edebiliyor olsa da başlangıç noktasında her bir veri örneğini, örneğin kullanıcıları (veya ürünleri) fiziksel manada yakınlıklarını temsil eden bir yapıda değildir. Bu noktada, elimizdeki veriyi kullanıcı ve ürünlerin etkileşim halinde olduğunu da düşünerek, bir çizge ağı olarak temsil etmek, bağlama farklı bir mimari ve öğrenme yöntemi olarak girebilir. Evrişimli çizge ağları, komşu birleştirme yöntemini sadeleştirilmiş bir

şekilde kullanarak, derin sinir ağlarının ya da few-shot öğrenme yönteminin mimari olarak öğrenmesi mümkün olmayan farklı derinliklerdeki komşu düğüm ilişkilerinin kullanımıyla birçok pazar verisinde, tek başına diğer yaklaşımların üstünde bir performans göstererek başarılı sonuçlar alabilmektedir.

Bu çalışmada çapraz marketler için geliştirilen öneri sistemi çizge yapısını kullanmaktadır. Hafif Çizge Evrişimli Ağı (LGCN) yapısı, FOREC çalışmasında olduğu gibi pazar-bağımsız ve pazara-özel adımlarla eğitilmiştir. Bu iki aşama arasında temsil aktarımını uygulayarak geliştirdiğimiz sistem daha sade bir eğitim akışından oluşmaktadır. Eğitimin ilk adımında kaynak ve hedef pazar verisindeki ikililerle oluşturulan çizge ağı yine bu iki pazarın verisiyle eğitilmiştir. Bu aşamadaki eğitim sonrası kaydedilen kullanıcı ve ürün temsilleri, ikinci adımda yeni çizge ağı oluşturulurken yeni temsillerin yarısının başlangıç noktası olarak kullanılmıştır. Temsilin diğer parçası ise pazara-özel öğrenime odaklanabilmesi için bu adımda belli bir dağılımla rastlantısal olarak başlatılmıştır.

Çalışmamızda test aşamasından önce, eğitimi tamamlanan çizge ağı ile farklı pazar verilerinin ilişkilerini ve potansiyel iyileştirme noktalarını keşfedebilmek için, doğrulama verisi ile ilinti gösterebilecek farklı metriklerin incelemesi yer almaktadır. Bu metrikler aşağıda listelenmiştir.

- Kullanıcıların eğitim verisindeki ürünlerine verdiği ortalama puan değeri
- Kullanıcının hedef pazar eğitim kümesinde birinci dereceden kaç ürün ile etkileşimde olduğu
- Kullanıcıların kaynak ve hedef eğitim kümelerindeki ikinci dereceden kaç ikiliye sahip oldukları
- Derece Merkezliliği (Degree Centrality)
- Yakınlık Merkezliliği (Closeness Centrality)
- Düğüm Fazlalık Katsayısı (Node Redundancy Coefficient)
- Kümeleme Katsayısı (Clustering Coefficient)

Görüldüğü üzere bu değerler arasında ham veriden çıkarılabilen temel istatistik değerlerinin hem de iki-parçalı çizge oluşumu sonrası çıkarılabilen metrikler bulunmaktadır. Bu aşamadaki sonuçlardan elde ettiğimiz çıkarım, kullanıcıların bireysel olarak nDCG skorlarının iki-parçalı çizgeden elde edilen Düğüm Fazlalık Katsayısı ve Kümeleme Katsayısı değerlerinin, diğerlerine oranla daha fazla ilintiye sahip olduğudur. Çalışmamızın detayında bu ilinti değerlerinin gelecek çalışmalarda nasıl kullanılabileceği ile ilgili fikirlere yer verilmiştir.

Deney sonuçları yedi farklı modelin sonuçlarını içermektedir. Bunların beş tanesi referans araştırması olarak düşündüğümüz FOREC çalışmasında da yer alan sonuçların bizim benzer şekilde uygulamamız sonrası elde ettiğimiz sonuçlardır. Diğer iki model ise bu problem için geliştirdiğimiz sistemin ilk adımındaki pazar-bağımsız adımın sonucu, diğeri ise iki-aşamanın eğitimi sonrası elde ettiğimiz nihai hibrit LGCN model sonucudur. Bahsedilen sonuçlar pazarların ikili olarak eğitimini ve sonucunu içeren deneylerdir. Yani, FOREC çalışması yedi hedef pazarı üzerinden sonuçları her bir pazar için geriye kalan diğer altı pazarı tekli olarak kaynak pazar olarak kullanır ve eğitimlerini buna göre gerçekleştirerek sonuçlarını alır. Biz de referans noktası olarak düşündüğümüz FOREC çalışmasına benzer şekilde eğitimlerini ilerlettiğimiz sistemimizde, bu hedef pazarların içinden seçtiğimiz dört tanesini alarak ilerledik. Bunlar Almanya, Japonya, Meksika ve İngiltere pazar verileridir. Buna ek olarak Amerika pazarının verisi sadece kaynak veri olarak deneylerde yer almıştır.

İki aşamalı yaklaşımımız ile farklı hedef pazarlar için %5 ve %8’lik bir aralıkta FOREC’in tüm sonuçlarından daha iyi sonuçlar elde ettiğimiz gözlemlenmiştir. Buna ek olarak, ilk adımdan sonra uyguladığımız pazara-özel eğitimin sonuçların iyileşmesinde %1 ile %2 oranında katkı sağladığı açığa çıkmıştır. Sonuç olarak, bu çalışmada çapraz pazarlar için iki aşamalı çizge sinir ağı ile öğrenilen model önerilmiş ve başarımları bu alanda yüksek sonuç verdiği gözlemlenen FOREC algoritması ile karşılaştırılmıştır. Önerilen model farklı hedef pazarlarında $nDCG@10$ değerlendirme metriği kullanıldığında FOREC algoritmasından daha iyi sonuçlar vermektedir.





HYBRID RECOMMENDATION SYSTEM IN CROSS E-COMMERCE MARKETS

SUMMARY

Social media, e-commerce, and other online platforms employ the approach of cross-market recommendation to suggest products or services to customers using several markets or domains. However, data on user engagement with products (clicks, sales, and reviews) reveals a variety of biases that are unique to particular markets, making suggestions more challenging. The FOREC, which focuses on market adaptation, has demonstrated strong performance on the cross-market recommendation problem. In our work, we propose a two-stage framework using the Light Graph Convolution Network (LGCN) algorithm, which has both market-agnostic and market-specific models in the learning cycle like FOREC but a less sophisticated architecture than it.

Recommendation algorithms are frequently utilized by tech companies in a range of applications, including movies, music, e-commerce, and others. Predictions are obtained by using user-item embeddings, which are acquired through a variety of techniques. While studies initially progressed with matrix factorization, both collaborative and content-based recommendations are currently being developed using different memory or model-based methodologies.

In recent decades, some platforms have grown significantly and increased the scope of the services they offer. These kinds of initiatives consequently result in both new requirements and problems. Using both its own data and that from various source markets in online commerce or other digital services, the field of study known as "cross-market recommendation" seeks to make predictions in the context of the limited target market data.

There are points to be considered while making any improvements. If the trained and optimized models from the source data are applied without taking the target market's behaviors into consideration, problematic results may result. For example, let's assume there is a country where the clothing category is used more frequently than other categories. If this country's average temperature is considerably higher than that of the target market, it might make sense to offer a t-shirt to a customer who purchases regular trousers in the source market, but it may not be relevant in the target market. Because of this, learning from data should be done so in a way that can account for both markets' distributions and biases.

Cross Market Recommendation (CMR) and Cross Domain Recommendation (CDR) are two topics for recommending products across markets and domains respectively with the goal of improving the effectiveness of the system. The CMR data, however, typically includes unconnected users and common items across markets. Contrarily, CDR data has overlapping users across domains, unlike CMR. So, the content of data both causes and has solutions to various issues. CMR is a less studied area than CDR so far because there are fewer collected datasets in this area.

The datasets in this problem domain are also new. XMREC is one of a few publicly available CMR datasets that are shared in competitions. It started with research on FOREC, which is also our reference study, and we tried to outperform their results. The dataset released in 2021, which has specific markets with different categories, served as a base for our research. This dataset includes 52.5 million user-product pairs across 18 local markets in 16 distinct product categories. As with FOREC, we used the data from the most popular category, electronics.

Although there are various hybrid methodologies, the general idea is that combining algorithms results in recommendations that are more precise and effective than using just one algorithm because the disadvantages of one algorithm can be countered by the benefits of another algorithm. Combining the approaches can be done in a variety of ways, including separately applying the algorithms and combining the outcomes, incorporating content-based and collaborative filtering approaches.

The approach we propose involves two-stage learning with pairs of markets that could be referred to as source and target. Therefore, our goal is to improve target market predictions that are learned from source and target market data. LGCN is used in both learning stages. However, they are trained using different data foci and embedding lengths. Users' and items' output embeddings from the first stage are used as new starting vectors for the second stage. There are also additional embedding vectors for market-specific phase. With the help of the market-agnostic and market-specific learning stages, the system thus has the advantages of both unseen item prediction and the users' coverage of the target market's predictions.

There are 7 models in the experimental set, 5 of which are models from FOREC, and the remaining models are market-agnostic and hybrid LGCN models. In the dataset we experimented with, there are 5 source markets and 4 target markets. 16 source-target market pairs from Germany, Japan, Mexico, and the UK were used as the source and target markets, except for the US market, which was used only as the source market, resulting in 112 total nDCG@10 scores (7 evaluations for each of the 16 source-target market pairs) and the creation of the final evaluation result.

Our study employs nDCG@10, a common evaluation metric for ranking problems. It is known that the score is the mean of the results from each individual user; this is the target market for our study. The cut-off value for n of DCG is 10, and 99 negative samples were used for validation and test evaluation for each user, similar to the reference study FOREC. Furthermore, as applied in FOREC, if the user has fewer than five interactions, they are eliminated from the dataset. If one user has had more than one interaction with the same item, the most recent rating score is selected. At the end of the pre-processing of markets, the user-item pair numbers of markets are as follows: 15889, 30216, 163439, 4209, and 16816 for DE, UK, US, JP, and MX, respectively.

Before the test results, our study includes the examination of different metrics that can correlate with the evaluation data to discover the relationships between the trained graph network and different market data that can provide potential improvement points. These metrics are listed below.

- Average rating given by users to their products in the training set
- How many first-degree products the user interacts with in the target market training set
- How many second-degree pairs the users have in the source and target training sets

- Degree Centrality
- Closeness Centrality
- Node Redundancy Coefficient
- Clustering Coefficient

As seen, these metrics include both the basic statistical values that can be extracted from the raw data and the values that can be extracted after the bi-partite graph creation. Our conclusion from the results at this stage is that the nDCG scores of individual users are more correlated with the node redundancy coefficient and cluster coefficient values obtained from the bi-partite graph than the other metrics. In the details of our study, we have included ideas about how this correlation can be used in future studies.

Our two-stage strategy has been tested, and the results show that it performs better than FOREC's overall outcomes, with an improvement range of between 5 and 8 percentage points for different target markets. Furthermore, it became apparent that the market-specific training we used after the first step improved the outcomes by 1 to 2 percent.

For future work, there are some important points. Considering the node-specific improvement points first, guiding the training with a node-specific approach, such as adding different negative samples or adding hard negative samples, may provide improvement when the relevant graph metric (for example, the redundancy coefficient) of a node is weak. Apart from these, different data augmentation techniques on a node basis can also improve the results. On the other hand, this approach can be applied to the whole market in a similar way.

Other than the improvement purpose, a different work might be to reduce the processing cost. By using the mentioned graph metrics at the point of simplification of the related graph, getting the same or better results with shorter training durations can be studied as a different problem.

1. GİRİŞ

İnternet çağının hız kazandığı bu dönemde, e-ticaret alanı da bu hıza ayak uyduruyor. Pandeminin de etkisiyle bu sektördeki büyüme hızı son yıllarda olağan değerlerden fazla gerçekleşerek, uygulamalar milyarlarca insanın yaşamında önemli yer ediniyor. Milyonlarca ürünün tek bir ortamda kullanıcılarıyla buluştuğu bu yerler, beraberinde farklı problemleri ve ihtiyaçları da getiriyor. Kullanıcılar gereksinimleri için arama yapabilse de beğenebileceği ürünleri zaman kaybetmeden görebilmesi için önceliklendirmek ve kişiselleştirmek daha kaliteli kullanıcı deneyimi yaşatmak adına önemlidir. Öneri sistemleri kullanıcıların ilgisini çeken ürünleri bulmasını sağlarken, öte yandan ortam sağlayıcılar için satışlarını artırabilir ve bu ortamı kullanan satıcılar da doğru müşteriye daha kolay bulma imkânı yakalamış olur. Sektörde bir hayli büyüeyebilen bazı şirketler ise artık sadece başlangıç yaptığı ülkelerden farklı olarak satış yapabileceği dış pazarlara girebilmektedir. Örneğin Amazon ve eBay gibi firmalar birçok farklı ülkede satışlarını gerçekleştirmeye devam etmektedir. Bu gibi şirketlerin sayısal olarak fazla miktarda ülkeye giriş yapmasıyla, bu araştırmanın da konusu olan çapraz pazar öneri problemi zaman içinde oluşmuş ve farklı çözümler oluşmaya başlamıştır.

Çapraz pazar önerilerinde, yıllar boyu hizmet edilen süreçte olgunlaşmış ve yüksek boyutlara çıkmış pazar verisi, yeni girilen bir pazarda farklı veriden öğrenme yöntemleri ile kullanılarak bu hedef pazarın yeni ve ilerleyen zamanlarında etkin öneriler yapılması hedeflenmiştir. Ancak burada kaynak veriden öğrenilen ve optimize edilen modeller, hedef pazarda dikkat edilmeden kullanılırsa problemli sonuçların doğmasına neden olabilir. Her ne kadar öneri yapılırken her iki pazarın verisi kullanılabilir olsa da başlangıçta çok az miktarda bulunan hedef pazar önerilerinde problemli önerilere neden olan durumlar olabilir. Bu nedenle veriden öğrenme adımları her iki marketteki dağılım ve davranışları öğrenebilecek bir yeteneğe sahip olmalıdır.

Bu çalışmada, FOREC makalesinde açık kaynak olarak kullanılan XMarket veri kümesi kullanıldı (Bonab ve diğ, 2021). Bu veri kümesi 16 farklı ürün kategorisinde

18 yerel pazar kapsayarak toplamda 52,5 milyon kullanıcı-ürün ikilisi barındırıyor. Sonuçlarını geçmeyi hedeflediğimiz FOREC çalışmasında olduğu gibi biz de en popüler kategori olan elektronik kategorisi verisiyle çalıştık.

Önerdiğimiz sistem FOREC’te olduğu gibi pazar-bağımsız ve pazara-özel eğitimleri gerçekleştirir. Ancak bizim çalışmamız FOREC’ten farklı olarak kullanılan modeller itibarıyla tamamen farklı bir yapı olan çizgeleri kullanır ve bunu daha sade bir öğrenim akışıyla gerçekleştirir. Özetlemek gerekirse, ilk adım olan market-bağımsız eğitim aşaması hafif çizge evrimsel ağ (LGCN) yapısının kaynak ve hedef pazar verilerinin kullanımıyla gerçekleştirilir (He ve diğ, 2020). Bu adım sonunda elde edilen düğümler, yani kullanıcı ve ürünlerin temsilleri, ikinci aşama olan markete-özel eğitimin ilk adımı olan çizgenin oluşturulmasında temsillerin bir parçası olarak kullanılır. Bu adımda hedef pazarın davranışlarına odaklanabilmek için yeni vektör parçaları ile daha uzun temsiller oluşturulur. İkinci aşama eğitimi yeni LGCN yapısının sadece hedef pazarın kullanıcı-ürün ikilileriyle beslenerek tamamlanır.

Yukarıdaki gibi özetlenebilecek öneri sistemimiz, Almanya, Japonya, Meksika ve İngiltere hedef pazarlarının test edildiği performans sonuçlarını içermektedir. Hem pazar-bağımsız ve hibrit LGCN hem de referans çalışması olan FOREC içinde yer alan modelleriyle yaptığımız deneylerin detaylarına 6.bölümde yer verdik. Bunun yanı sıra oluşturduğumuz iki parçalı çizgeden elde ettiğimiz farklı düğüm metriklerini doğrulama veri kümemiz ile inceleyerek gelecek çalışmalarda kullanılabilecek yöntemlere ışık tutmaya çalıştık.

2. ÖNERİ SİSTEMLERİ

Mevcut dijital bilgi miktarı ve interneti ziyaret edenlerin sayısındaki patlayıcı büyüme, internetteki ilgi alanlarına zamanında erişimi engelleyen potansiyel bir aşırı bilgi yüklemesi sorunu yarattı (Isinkaye ve diğ, 2015). Arama motorları bu soruna çözüm getirmiş olsa da kullanıcıların farklı uygulamalarda fazla veride/seçenekte boğularak zaman kaybetmesi problemi, bilgilerin önceliklendirilmesi ve kişiselleştirilmesi gibi kavramlar doğurdu. Öneri sistemleri bu problemlere, kullanıcıların zaman içinde farklı noktadaki etkileşimlerini kullanarak uyguladığı filtreleme yöntemleri ile çözüm getirebilmektedir. Böylece bir kullanıcının aşırı bilgi ile yüklenmiş bir ortamda kalitesiz bir deneyim geçirmesi engellenmiş olur. Ek olarak, kullanıcının zaman içinde oluşturulmuş kişisel profiline veya çok yakın zamandaki anonim tercihlerine göre de kullanıcının olası tercihlerini tahmin etme yeteneğine sahiptir. Böylelikle şirketler satış sayılarını, dolayısıyla gelirlerini artırabilirken kullanıcılar ise daha kaliteli bir deneyim yaşayabiliyorlar.

Öneri sistemleri temelde içerik tabanlı ve işbirlikçi filtreleme yaklaşımları olarak ayrılabilirken, farklı yöntemlerin birleştirilmesi ile hibrit yaklaşımlar da uygulanmaktadır.

2.1 İşbirlikçi Öneri Sistemi

İşbirlikçi yöntem sadece kullanıcı ve öge arasındaki etkileşimleri kullanarak öneri yapmayı hedefler. Bu yüzden, kullanıcıların etkileşimlerini veri tabanında saklar ve bu veri işbirlikçi yöntemlerde iki farklı yaklaşımla değerlendirilebilir. Bunlar hafıza ve model tabanlı işbirlikçi yöntemlerdir. Hafıza tabanlı yaklaşım bir kullanıcının etkileşimde olduğu ögeler üzerinden diğer komşu kullanıcılara ve onların etkileştiği ögelerin arasından bir karar verme mekanizması ilerletme mantığındadır, en yakın komşu arama şeklinde de düşünülebilir. Model tabanlı işbirlikçi yöntem ise geçmiş kullanıcı-öge değerlendirme skorlarını kullanarak bir model öğrenir ve üretici bir yaklaşımla yeni önerilerini performansı artıracak şekilde kullanmayı hedefler. Bu teknik, önceden hesaplanmış bir model kullandığı için bir dizi ögeyi hızlı bir şekilde

önerebilir ve komşu temelli öneri tekniklerine benzer öneri sonuçları ürettiklerini kanıtlamışlardır (Isinkaye ve diğ, 2015). Model olarak kullanılabilecek bazı algoritmalara Yapay Sinir Ağları, Tekil Değer Ayrışımı, Regresyon ve Kümeleme örnek verilebilir. Model tabanlı sistemler veri seyrekliği problemini yaşamadan eğitimlerini gerçekleştirerek önerilerde bulunabilir ancak sadece kullanıcı ve öğe ilişkilerini kullandığı için soğuk-başlangıç ismiyle bilinen probleme çözüm üretemezler. Soğuk başlangıç problemi, kullanıcının sisteme yeni dahil olduğu durumda oluşur, bu terimin kökeni otomobillerden gelir, motor soğukken ilk çalıştırmada zorluk çekerken, ancak optimum sıcaklığa ulaştıktan sonra çalıştırmada herhangi bir sorun yaşamazlar (Fayyaz ve diğ, 2020). Öneri sistemlerinde ise sisteme yeni giriş yapan bir kullanıcının hiçbir öğe ile etkileşimi olmadığından herhangi bir kullanıcı veya öğe ile benzerliği kurulamaz ve dolayısıyla öneri yapmanın imkânı bu yaklaşım ile mümkün değildir.

2.2 İçerik Tabanlı Öneri Sistemi

Sadece kullanıcı ve öğeler arasındaki etkileşimlere dayanan işbirlikçi yöntemlerin aksine bu yaklaşımda kullanıcının veya öğenin kendine özgü, onu tasvir eden bilgileri kullanılarak öneri yapılır. Örneğin bir müzik uygulamasını düşünecek olursak, bir şarkının türü, hangi enstrümanları kullandığı, süresi veya diğer özelliklerin yanı sıra kullanıcılar için de yaş, iş, cinsiyet veya diğer kişisel bilgileri bu algorithmada kullanılabilir olur.

İçerik tabanlı modellerin eğitim aşamalarına kısaca değinmek gerekirse, kullanıcı-merkezli veya öğe-merkezli olarak iki farklı şekilde ilerlenebilir. Öncelikle model bahsedilen merkez tiplerinden bağımsız sınıflandırma veya regresyon modellerinden biri olabilir. Yani model, bir kullanıcının bir öğeyi beğenip beğenmeyeceğini bulmaya çalışabilirken, o öğeye kaç puan vereceğini de tahmin edebilir. Merkezli tiplere dönecek olursak, öğe merkezli yöntemde model kullanıcı özniteliklerini kullanarak modelin optimizasyonu yapar. Yani eğitim sonrası her bir öğe için bir model olacak gibi düşünüp, herhangi bir kullanıcının ilgili öğenin modeline girdiğinde o öğeye verebileceği skoru tahmini olarak öğrenebilir. Tam tersi mantıkta düşünersek, öğe özniteliklerini ile çalışıyorsak yani hesaplamaları bir kullanıcı etrafındaki öğelerin özelliklerini kullanarak bir kullanıcı modeli eğitiyorsak, sonuç

olarak da herhangi bir öge belirli bir kullanıcı modeline girdiğinde, yine bir skor tahmini elde edilmiş olacaktır. Sistemlerde genellikle kullanıcı sayısı öge sayısından fazla olduğu için ilk olarak ifade ettiğimiz öge-merkezli yöntem birçok kullanıcı özelliği ile etkileşimde olacağından daha sağlam bir yöntem olarak görülebilir ancak her ne kadar ilgili ögeyle etkileşimde olan kullanıcıların elimizdeki özniteliklerinin benzer olduğunu bilsek de bu kullanıcılar farklı davranışlara sahip olabilir, dolayısıyla burada bir handikap olduğunu ve sonuç olarak da kişiselleştirmeden uzak bir yöntem olduğunu söyleyebiliriz. Kullanıcı-merkezli yöntemde ise kişiselleştirme daha fazladır ancak burada da bazı kullanıcılar için yeterli etkileşim olmayacağı için sağlamlık noktasında öge-merkezliye göre geride kalmaktadır. İki tarafında da negatif yönlerine çözüm olarak ise kullanıcı ve öge özniteliklerini tek bir vektörde birleştirerek bu eğitimi iki tarafın da avantajlarını kullanarak daha başarılı ve kapsayıcı modeller elde edilebilir.

2.3 Hibrit Tabanlı Öneri Sistemi

Hibrit öneri sistemleri, bir yaklaşımın tek başına üstesinden gelemeyeceği problemleri farklı bir yaklaşımla aşarak, tüm sistemin tekil modellerden daha iyi performans elde edebilecek şekilde çalışmasını amaçlar. En yaygın olarak, işbirlikçi filtreleme, hızlanma probleminden kaçınmak için başka bir teknikle birleştirilir (Burke, 2020). Burada temel olan alt dallardan bahsedecek olursak, Ağırlıklandırılmış HÖS içeriğindeki tüm yaklaşımların çıktılarını kullanarak nihai hedef skoru elde eder. Bu işlemi her bir modelin ağırlığını, eşit katsayılarla başlatıp, öğrenebileceği farklı bir lineer kombinasyon uygulanabilirken, daha kompleks ağırlıklandırma yöntemleri de izlenebilir. Karma HÖS farklı modellerin sonuçlarını ayrı ayrı çıktılarken, aralarında bir birleşim amaçlamaz. Değişen HÖS farklı kullanıcı-öge profilleri için kendi karar mekanizması içinde farklı modellerin kullanımını seçebilir, hangi model ile daha iyi öneri almayı bekliyorsa o modelin sonucunu kullanır. Bu değişimle bir yönteme ait davranışsal bir sorun varsa diğerini kullanarak bu durumu önleme yeteneğine sahiptir. Örnek vermek gerekirse yeni kullanıcılar için işbirlikçi öneri sisteminin yetersiz kaldığı noktalarda içerik tabanlı öneri modeli kullanılabilir. Kademeli HÖS tekniği, farklı öğeler arasında bir tercih sırası oluşturmada yinelemeli bir iyileştirme süreci uygular. Bir tekniğin önerileri başka bir öneri tekniğiyle rafine edilir (İsınkaye ve diğ., 2015). Bu teknikte birinci modelden kabaca çıkarılan öneri listesi sonraki

adımında farklı bir model tarafından iyileştirilmesi hedeflenir. Bir diğer hibrit yöntem ise özellik kombinasyonudur. Burada bir modelden çıkan herhangi bir özellik bir diğer modeli besler ve eğitilmesinde kullanılarak ilerlenir.

2.4 Öneri Sistemlerinde Kullanılan Değerlendirme Metrikleri

Değerlendirme metrikleri öneri sistemlerinin kalitesini ölçümleyebilmek ve birbirleri arasında karşılaştırma yapabilmek için kullanılan yöntemlerdir. Başlıcaları; doğruluk, kesinlik, duyarlılık ve F1 skor olarak sıralanabilir. Değerlendirme kavramı öneri (recommendation) ve tahmin (prediction) görevleri için ayrı ayrı düşünülmelidir. Tahmin görevinde değerlendirme tahmin edilen skorların doğruluğunun ölçümünü içerir. En bilinenlerden ortalama kare hatası kökü denklem 2.1’de görüldüğü şekilde ifade edilir ve i, j ikililerini veri kümesindeki kullanıcı ve öğeler olarak düşünüldüğünde, herhangi bir modelin tahminini v gerçek doğru değeri ile farkından maliyetleyerek toplam bir maliyet elde eder.

$$\sum_{(i,j) \in K} \sqrt{\frac{(p_{i,j} - v_{i,j})^2}{n}} \quad (2.1)$$

Öneri görevlerinin değerlendirme metriklerine değinmek gerekirse, yaygın olarak kullanılan metrikler aşağıdaki gibidir. Aşağıda 2.2, 2.3 ve 2.4 olarak sıralanan metrikler karar destek doğruluğu metrikleri (decision support accuracy metrics) başlığı altında ifade edilirken, önerilerin doğruluğunu ölçümlemekte kullanılır.

$$Kesinlik = \#DP / (\#DP + \#YP) \quad (2.2)$$

$$Duyarlılık = \#DP / (\#DP + \#YN) \quad (2.3)$$

$$F1 = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (2.4)$$

Diğer tarafta ise önerilerin birden fazla olduğu ve sıralarının da önem kazandığı durumlarda farklı ölçüm metriklerine ihtiyaç duyulur. Bunların en yaygın kullanılanları MAP@K (Mean Average Precision) ve NDCG (Normalized

Discounted Cumulative Gain) metrikleridir. Eğer ki önerilen öge ilk K öge içinde önerilmiş alakalı bir öge ise bu AP@K değerinin payına 1 eklenir ve tüm K değerleri için bu işlem yapıp K değerine bölündüğünde ortalama kesinlik bulunur, bu şekilde tüm sorgular için AP değerlerinin ortalaması alındığında MAP@K değeri elde edilir. Ancak önerilerin hangi sırada önerildiğinin önemli olduğu durumda bu metrik de yeterli olmayacaktır. NDCG ise bu ihtiyacı karşılamaktadır. Aşağıda 2.5 denkleminde görülen DCG skorunun aynı şekilde ideal doğruya göre hesaplanan değere bölünmesiyle normalize edilmiş değer elde edilir. Burada K, ilk kaç değer hesaba katılmak isteniyorsa o değerdir, G_i ögenin alaka değeri, i ise öneri listedeki sırasıdır.

$$DCG_{@K} = \sum_{i=1}^K \frac{G_i}{\log_2(i + 1)} \quad (2.5)$$




3. ÇİZGE SİNİR AĞLARI VE ÖNERİ SİSTEMLERİNDE KULLANIMI ÖN HAZIRLIK

Bu bölüm ana problem konusu olan çapraz pazar öneri sistemleri konusuna geçmeden önce çizge ağlarının ve bu ağların öneri sistemleri ile nasıl geliştiğinin özetini içermektedir.

3.1 Çizge Sinir Ağları

Çizge sinir ağları, çizge veri yapısını temel alır. Çizge ise en basit tanımıyla düğüm (node) ve düğümleri birbirine bağlayan ayrıtlardan (edge) oluşur. Yaygın olarak kullanılan çizge ifadesi $\mathcal{G} = (D, A)$ şeklindedir. D düğüm, A ise ayrıtlar kümesini ifade eder. Ayrıtlar, temsil edilen veri ve düğümler arasındaki bağımlılıklara göre yönlü veya yönsüz olabilir. Çizgeler genellikle bitişiklik matrisleri ile temsil edilir. Örneğin bir çizge n tane düğüme sahipse bu matris $(n \times n)$ boyutunda 0 ve 1 rakamlarıyla doldurulur. Çizge analizi, makine öğrenimi bağlamında öklid olmayan bir veri yapısı olarak düğüm sınıflandırması, bağlantı tahmini ve kümeleme gibi görevlere odaklanır (Zhou ve diğ., 2020). Aşağıda Şekil 3.1’de farklı renkteki harflerle ifade edilen düğümler ve onları bağlayan ayrıtlarla çizge örneği gösterilmektedir.




Şekil 3.1 : Çizge örneği.

Çizge sinir ağları, çizgelerle ifade edilen veri üzerinde geliştirilen ve farklı derin öğrenme yapı ve fonksiyonları barındıran ağlardır. Bu ağlar eğitilebilir ve problem çeşidine göre farklı çıkarımlar için kullanılabilir. Düğüm sınıflandırma, çizge sınıflandırma, bağ tahmini ve çizge kümelemesi bu problemlere örnek olarak verilebilir. Çizgeden çizge sinir ağına geçişte kullanılan temel işlemler ise düğüm ve/ya ayrıtların temsillerinin çıkarılmasıdır. Bu temsillerin çıkarımı düğümlerin ve ayrıtların kendi içlerinde veya karşılıklı olarak birbiriyle benzerliklerini karşılaştırbilmemize olanak sağlar. Çizge sinir ağları temsili çıkarmakla görevli olan kodlayıcı (encoder) temelde üç işlem üzerine odaklanır. Bunlar;

- Bölgesellik (locality)
- Birleştirme bilgisi (aggregation)
- Sinir ağ katmanları işlemi

Bölgesellik bilgisi, bir düğümün çizge üzerinde ifade edilen komşularının ve bu komşuların komşularının (derinliğe göre artabilir) elde edilmesiyle diğer düğümlerden arındırılmış spesifik bir çizge çıkarımı olarak düşünülebilir. Temsil çıkarımının birleştirme bilgisi ve katman işlemleri birlikte gerçekleşir. Şekil 3.2’de görüldüğü üzere, A hedef düğümünün temsil vektörünü elde edebilmek/güncelleyebilmek için farklı derecelerdeki komşularının çizgesi sağ tarafta gösterilmiştir (Ying ve diğ., 2018). Burada gri renkteki kutular sinir ağını temsil ederken, öncesinde gerçekleşen birleştirme işlemleri ise ilgili düğümün komşu bilgilerini bir sonraki adıma taşımada görev almaktadır.



Şekil 3.2 : Çizgeden çizge sinir ağına dönüşüm (Ying ve diğ., 2018).


Bahsi geçen birleştirme işlemi ortalama, maksimum veya toplama işlemleri ile yapılabileceği gibi daha kompleks bir fonksiyon da olabilir. Eğitim aşaması aşağıdaki formül ile genel manada gösterilir.

$$h_v^{(k+1)} = \sigma \left(W_k \sum_{u \in N(v)} \frac{h_u^{(k)}}{|N(v)|} + B_k h_v^{(k)} \right), \forall k \in \{0, 1 \dots K-1\} \quad (3.1)$$

$N(v)$, v düğümünün komşularını ifade etmektedir. Bu formülde bir önceki katmandaki komşuların $h_u^{(k)}$ ortalama birleştirilmesi uygulanarak sinir ağının parametreleri olan W_k ile çarpılır. Yanındaki $B_k h_v^{(k)}$ ifadesi ise düğümün o anki temsilinin yine bir ağırlık matrisi olan B_k ile çarpılarak bu iki ifadenin toplanmasıyla tüm birleştirme akışı tamamlanmış olur. En dıştaki σ sembolü, aktivasyon fonksiyonunu temsil etmektedir. ReLU veya sigmoid bazı aktivasyon fonksiyonu örnekleridir.

3.2 Çizge Ağı Tabanlı Öneri Sistemleri

Öneri sistemleri çoğu zaman kullanıcı ve ilgili öğelerden meydana gelir. Bu nedenle iki parçalı çizge olarak oluşturulabilirler. Kullanıcılar ve öğeler olarak konumlanan bu iki taraf, bahsedildiği üzere ayrıtlarla birbirine bağlanır. Şekil 3.3 iki parçalı çizge gösterimi örneği olarak aşağıda görülmektedir.



Şekil 3.3 : İki parçalı çizge gösterimi.

Geçmiş kullanıcı-öge etkileşimleri kullanılarak, herhangi bir kullanıcının yeni öğelerle oluşabilecek olası etkileşimi tahmin edilmeye çalışılır. Bu tahminin


yapılabilmesi, tüm kullanıcı-öge kümesini düşündüğümüzde diğer öneri sistemlerinde olduğu gibi temelde iki aşamalı gerçekleşir. Bunlar, aday kümesi çıkarımı ve bu küme içinde sıralama işlemi ile en uygun öğeleri tahmin etme adımlarıdır. En uygun olarak bahsettiğimiz bu öğeler, en iyi K tane öge (top-K) olarak isimlendirilir. Bu işlemin yapılabilmesi, ilk adım sonrası elde edilen öğelerin ilgili kullanıcılarla belli bir fonksiyon kullanılarak skorlanabilir olmasıyla mümkündür. Bu skarlama öneri sistemlerinde genel olarak temsil (embedding) tabanlı modellemelerin eğitimleri ile oluşan vektörlerin yakınlığı ile çıkarılabilir.

Bu noktada geleneksel işbirlikçi filtreleme yöntemlerini kullanmak verinin doğal yapısı olan çizgenin sadece birinci derece yakınlık bağlamında sınırlı kalmasını ve eğitiminin bu öğrenim limitiyle gerçekleşmesine neden olur. Bu nedenle, daha yüksek dereceli yakınlıkları açık bir şekilde yakalayamaz. Çizge ağları ise hem verinin doğal yapısını hem de yüksek dereceli komşuluk ilişkilerini öğrenebilme kabiliyetine doğal olarak sahiptir ve böylece başarılı sonuçlar üretebilmektedir.

3.2.1 Sinir çizge işbirlikçi filtreleme

NGCF (sinir çizge işbirlikçi filtreleme) öneri sistemlerinde çizge sinir ağı kullanımını öneren önemli çalışmalardan biri olarak karşımıza çıkar. Yukarıda değindiğimiz bahsi, bu çalışma şöyle ifade eder. Matriks çarpımı ve derin ağ yöntemlerinin doğal bir dezavantajı, kullanıcı-öge etkileşimlerinde gizli olan işbirlikçi sinyalin temsil çıkarım işleminde kodlanmamasıdır. Bu nedenle, ortaya çıkan temsiller, işbirlikçi filtreleme etkisini yakalamak için yeterli olmayabilir (Wang ve diğ., 2019).

Aşağıda gösterilen Şekil 3.4 figürü araştırmada yer alan bir figürdür ve görüldüğü üzere solda gösterilen kullanıcı-öge etkileşimleri, sağda yüksek dereceli bağlantı şekliyle modellenmiş ve ağa işbirlikçi filtrelemeyi gerçekleştirirken bu bağlantıları da öğrenebilme kabiliyeti kazandırılması amaçlanmıştır.



Kullanıcı-Öğe Etkileşim Çizgesi

u_1 için Çok Dereceli Bağlantı

Şekil 3.4 : NGCF yüksek dereceli kullanıcı-öğe etkileşimi (Wang ve diğ., 2019).

Bu çalışmada önerilen mimari temelde üçe ayrılmaktadır. İlk olarak kullanıcı ve öğe temsil vektörlerinin ilk değerlerinin atanması yapılır. Herhangi bir kullanıcının “u” ile ifade edilirken, d boyutundaki temsil vektörü $e_u \in \mathbb{R}^d$ olarak belirtilir. İkinci adım, yüksek dereceli bağlantı ilişkilerini kullanarak vektör temsillerini iyileştiren çoklu temsil yayılma katmanları adımdır. Bu adımda evrişimli çizgelerin mesaj oluşturma ve birleştirme adımları bulunmaktadır. Denklem 3.2’de belirtilen işlem, etkileşimde olan bir kullanıcı ve öğe ikilisi için mesaj oluşturmaya ifade eder.

$$m_{u \leftarrow i} = \frac{1}{\sqrt{|N_u||N_i|}} (W_1 e_i + W_2 (e_i \odot e_u)) \quad (3.2)$$

Burada $W_1, W_2 \in \mathbb{R}^{d \times d'}$ eğitilen ağırlık matrisleridir, d' dönüşüm boyutunu temsil eder. Genel olarak kullanılan mesaj oluşumundan farklı olarak burada e ve i kullanıcı-öğe etkileşimi, eleman bazlı çarpım ile eklenerek ayrıca formül içinde ağırlıklandırılmıştır. N_u ve N_i tahmin edileceği üzere sırasıyla kullanıcı ve öğenin komşularını ifade eder. Mesaj oluşumundan sonra, birleştirme işlemi 3.3 denkleminde ifade edilmiştir. Bu denklem çok dereceli iletim için genelleştirilmiş şekildedir ve u’nun l. katmandaki değerini (l-1) katmanındaki komşularını ve kendisini kullanarak gerçekleştirir.

$$e_u^{(l)} = \text{LeakyReLU} \left(M_{u \leftarrow u}^{(l)} + \sum_{i \in N_u} m_{u \leftarrow i}^{(l)} \right) \quad (3.3)$$

Burada toplama işleminin sağ tarafı etkileşimdeki öğelerin mesajlarının birleştirme işlemini ifade ederken, solu ise kendi bağlantısını işleme katma amacıyla eklenir. LeakyReLU aktivasyon fonksiyonu ise negatif ve pozitif değerleri iletmekle görevlidir. Birleştirme adımı sonrası ise son adım olan tahmin katmanı bulunmaktadır. Burada ise farklı yayılma katmanlarından elde edilen temsillerin, ilgili kullanıcı-öge ikilisi için sonuç üretme işlemi gerçekleşir.

3.2.2 PinSAGE

PinSAGE öneri sistemleri için tasarlanmış diğer bir önemli algoritmadır. Pinterest uygulaması için geliştirilmiş ve kullanılan bir sistem olarak yayınlanan araştırmasında hem çizge yapısını hem de düğüm özelliği bilgisini içeren düğümlerin temsillerini oluşturmak için verimli rasgele yürüyüşleri ve çizge evrişimlerini birleştiren, veri açısından verimli bir çizge evrişimli ağ olarak tanımlanır (Ying ve diğ., 2018). PinSAGE çizge bağlamından farklı olarak görsel ve metinsel veriyi de ağa dahil ederek daha performanslı sonuçlar elde etmeyi amaçlar. Algoritma içinde performansı kaynak kullanımı ve sonucu iyileştirici etki gösterecek şekilde uygulanan bazı önemli detaylar bulunmaktadır. Bunlardan ilk olarak bahsedilebilecek olan konu dinamik çizge oluşumudur. Bir düğüm etrafındaki komşuları örnekleyerek ve bu örneklenmiş komşulardan anlık olarak dinamik bir hesaplama çizgesi oluşturarak yerelleştirilmiş evrişimler gerçekleşir. Bunun yanı sıra mini parçalarla eğitimi gerçekleştirerek maksimum GPU kullanımı limitlenmiş ve kaynak kullanımı verimli hale getirilmiştir. Bu verimliliği iyileştirecek bir diğer nokta rastgele yürüme (random walk) algoritması ile sağlanmıştır. Amaç, bir düğüm için tüm komşuları kullanmak yerine kısa rastgele yürüme ile seçilen öğelerle hesaplama yapılacak çizgeyi oluşturmaktır. Diğer bir uygulama negatif örnek kullanımıdır. Normal koşullarda eğitimde kullanılan negatif örnek sayısını artırmak sonuçları iyileştirici etki gösterir, ancak bu maliyetli bir uygulamadır. Bu noktada aynı mini-parça içindeki kullanıcılar için ortak negatif örnek kümesi kullanılmıştır. Bu yöntemle öneri performansında azalma yaşamadan düğüm temsillerinin çıkarımındaki hesaplama maliyeti düşmüştür.

Bunların dışında sonucu iyileştirme amaçlı farklı yaklaşımlar da uygulanmıştır. Zor negatif örnekler bunlardan biridir. Negatif örneklerle eğitim sonucu iyileşirken, daha iyi sonuçlar almak için zor negatif örnekler eğitim aşamasında kullanılır.

PinSAGE bu eğitimi gerçekleştirirken müfredat öğrenimi (curriculum learning) yöntemini kullanır. Bu ise temelde zor negatif örnek sayısını kademeli olarak artırmaya dayanır. Her bir devirde (epoch) devir sayısının bir eksiği kadar negatif örnek eğitime dahil edilir. Zor negatif örnekleri elde etmek farklı detaylar içerse de genel olarak bir kullanıcı düğümüne yakın ancak ona bağlı olmayan öge düğümler olarak tanımlanabilir.





4. ÇAPRAZ PAZAR ÖNERİ PROBLEMİ

Çapraz pazar probleminde amaç, görece daha zengin olan kaynak pazarların verisinden yararlanarak, kısıtlı veriye sahip hedef pazarda başarılı öneri yapabilmeyi sağlamaktır. Bu bölümde girişte belirtilen özet bilgilerden farklı olarak son yıllarda dikkat çeken pazarlar arası öneri problemine getirilen çözümlerin teknik olarak hangi yaklaşımlarla yapıldığına eğileceğiz.

İlk olarak sayıca fazla olan pazarlarda bu pazar verilerinin hangi şekillerde eğitildiği önemli bir noktadır. FOREC çalışması hedef pazarlarındaki önerileri sadece tek bir kaynak pazarı kullanarak yapmaya çalışırken, Bernardis (2022) çalışmasında kaynak ve hedef pazarları birden fazla sayıda kullanarak farklı kombinasyonlarda birleştirerek sonuç almaya çalışmıştır. Bu sebeple eğitim aşamasında pazar verilerinin farklı şekillerde kullanımı; problemi, getirilen çözümü ve sonuçları düşünürken dikkate alınması gereken bir konu oluyor.

İkinci olarak değinilecek konu tahmini gerçekleştiren modelin mimari yapısıdır. Pazarlar arası öneri son yıllarda farklı yarışmaların düzenlenmesi ile araştırma alanlarını genişletiyor. Özel sektör verileri üzerinde düzenlenen bu yarışmalarda çözümler genellikle birden fazla modeli başarılı şekillerde birleştirenler olabiliyor. Bu birleşimler 2. bölümdeki farklı hibrit yaklaşımlar şeklinde olabilir. Örneğin FOREC modeli mimarisi içinde birden fazla modeli özellik kombinasyonu HÖS şeklinde yapılandırabilirken farklı çözümlerde birden fazla modelin sonucunun sıralama algoritmaları ile en iyisini elde edecek şekilde de olabilir.

Son olarak bahsedilecek nokta sistemler içinde hangi modellerin kullanıldığıdır. Bilindiği üzere işbirlikçi filtreleme algoritmalarının birçok çeşidi bulunmaktadır. Tek bir pazarda uygulanabilen algoritmalar potansiyel olarak çapraz pazar probleminde de uygulanabilir durumdadır. İstatiksel yaklaşımlardan KNN, SVD gibi algoritmaların ItemKNN, UserKNN, PureSVD gibi versiyonları uygulanabilirken, derin öğrenme yöntemlerinin hızla genişleyen çeşitliliği bu problem içerisinde de etkisini gösteriyor (Cremonesi ve diğ., 2019). MLP, RecVAE, MultVAE, FOREC

gibi farklı kompleksitede olan modeller sıralanabilir (Shenbin ve diğ., 2020). Bunlara ek olarak çizge evrişimli modellerin standart çok katmanlı algılayıcı modellerden daha başarılı performans gösterdiği farklı çalışmalar yapılmıştır. Veri içindeki yapısal bilgiler, çizge olarak temsil edildiğinde varlıklar arasındaki ilişkileri modellemek ve verilerin altında yatan daha umut verici içgörüler sağlamak için kodlanabilir (Zhang ve diğ., 2019). Bu çalışmanın da içerisinde kullanılan Hafif Çizge modeli, evrişimli ağ modeli türlerinden biridir. Son olarak ise meta-öğrenme modelleri az sayıda veriden öğrenme amacı taşıyan ve bu konu üzerine yoğunlaşan yaklaşımlardır. Örneğin, MAML, FOREC mimarisi içinde de yer almış ve araştırma konusu temelinde yer alan hedef pazardaki kısıtlı veriyi öğrenirken few-shot tekniğiyle katkı sağlaması istenen bir uygulama olmuştur (Finn ve diğ, 2017).

5. İKİ AŞAMALI ÇİZGE AĞI EĞİTİMİ İLE ÇAPRAZ PAZAR ÖNERİ SİSTEMİ

Bu bölüm çapraz pazar öneri problemi için tasarladığımız iki aşamalı çizge ağı eğitimi ile gerçekleştirilen öneri sisteminin detaylarını içermektedir. İlk başlıkta kullandığımız çizge ağı tanıtımı, ikinci başlıkta ise sistem detayları bulunmaktadır.

5.1 Hafif Çizge Evrişimli Ağ

Bölüm 3.2’de PinSAGE ve sinir çizge işbirlikçi filtreleme ağlarının öneri sistemlerinde başarı ile uygulandığından bahsedilmişti. İlerleyen zamanlarda devam eden araştırmalarla öneri problemi özelinde daha iyi sonuçlar verebildiği görülen hafif çizge evrişimli ağ geliştirdiğimiz sistemin temel çizge modeli olarak konumlandırıldı.

LGCN fikir olarak NGCF (Sinir Çizge İşbirlikçi Filtreleme) çalışmasında temelinde ilerleyen bir çalışmadır. LGCN’deki yaklaşımın farkı ise NGCF modelindeki özellik dönüşümü ve doğrusal olmayan aktivasyon ekleme adımlarının olmayışıdır. LGCN’de bu uygulamaların öneri sistemlerinde başarıyı düşürücü etki gösterdiğini, komşu biriktirme adımının tek başına uygulanmasının tahminleri iyileştirici sonuçlar getirdiğini farklı deneylerle göstererek gerçekleştirmişlerdir (He ve diğ., 2020). Denklem 5.1’de bahsi geçen biriktirme fonksiyonunun denklemi verilmiştir.

$$e_u^k = AGG(e_u^{k-1}, \{e_i^{k-1} : i \in N_u\}) \quad (5.1)$$

AGG olarak ifade edilen biriktirme fonksiyonu, çizge evrişimli ağların temel işlemidir. Bir düğümün komşu düğümlerinin özellik vektörlerini (denklemden e_i^{k-1} olarak ifade edilen), sonraki k . katmana aktaran işlem olarak ifade edilebilir. Diğer çizge ağları bu adımda özellik dönüşümünü bir matris çarpanı olarak bulundururken, LGCN herhangi ekstra bir şey kullanmaz, sadece komşu temsillerin normalize edilmiş toplamalarını bir sonraki katmana iletir. Böylece güncellenen parametreler sadece sıfırıncı katman olarak düşünebileceğimiz başlangıç düğüm temsilleri olur.

Sonuç olarak, tüm öğrenme akışı diğer çizge evrişimli ağlardan daha sade ve hızlı gerçekleşmiş olur.

Aynı düğümün benzer biriktirme fonksiyonu ilgili katmanda uygulanırken her birinde farklı temsilleri elde edilir. Bu farklı temsiller a_k önem derecesi ile çarpılır ve nihai temsil elde edilir. LGCN deneyler süresince en iyi çarpanı $1/(K+1)$ şeklinde belirlemiştir.

$$e_u = \sum_{k=0}^K a_k e_u^{(k)} ; \quad e_i = \sum_{k=0}^K a_k e_i^{(k)} ; \quad (5.2)$$

5.2 İki Aşamalı Hibrit Çizge Ağı Eğitimi

Bu bölümde geliştirdiğimiz sistemin veriden öğrenme akışının detayları yer almaktadır. Bahsedildiği üzere öneri sistemimizin temel modeli LGCN'dir. Eğitim ardışıl olarak gerçekleşen iki adımdan oluşur. Bu adımlar pazardan bağımsız ve pazara özel eğitim aşamalarıdır. İlk adımda eğitilen LGCN temsilleri, ikinci adımda oluşturulan çizgenin temsil parçalarında kullanılır, böylece geliştirilen sistem özellik kombinasyonlu hibrit öneri sistemi grubuna ait olarak konumlandırılabilir. Aşağıda k temsili katman sayısı ve l temsil uzunluğunu ifade eden parametreleri ile eğitim akışının sözde kodu bulunmaktadır.

İki Aşamalı Çizge Ağı Eğitim Akışı

Kaynak Pazarlar: $M_{\text{kaynak}} = [M_0, \dots, M_m]$

Hedef Pazarlar: $M_{\text{hedef}} = [M_0, \dots, M_n]$

Pazar-bağımsız ve Pazara-özel model parametrelerinin tanımı: Katman sayısı k , Düğüm temsil uzunluğu $l \rightarrow k_{pb}, k_{pö}, l_{pb}, l_{pö}$


```

1  for hedef pazar  $M_h$  in  $M_{\text{hedef}}$ 
2      for kaynak pazar  $M_k$  in  $M_{\text{kaynak}}$  do
3           $M_h$  ve  $M_k$  pazarlarından oluşan kullanıcı ve ürün temsillerine başlangıç değeri atama
4           $M_k$  ve  $M_h$  temsillerini kullanarak pazar-bağımsız LGCN oluştur ( $k_{pb}$  ve  $l_{pb}$  parametreleri ile)
5           $M_k$  ve  $M_h$  pazarlarının kullanıcı-ürün ikilileri ile pazar-bağımsız LGCN modelini eğit ve
              düğüm temsillerini kaydet
6           $l_{pb} + l_{pö}$  temsil uzunluğu ve  $k_{pö}$  temsili katman sayısı ile hibrit LGCN modeli oluştur
7          Kaydedilen ilk adım temsillerini yeni LGCN modeli temsillerinin bir parçası olarak yükle
8          Pazara-özel öğrenime odaklanacak  $l_{pö}$  temsil parçasına başlangıç değeri ata
9          Sadece  $M_h$  kullanıcı-ürün ikililerini kullanarak hibrit model eğitimini tamamla
11     end
12 end

```

İki aşamalı eğitim akışının görselleştirilmiş hali Şekil 5.1’de görüldüğü gibidir. Şekilde kaynak ve hedef pazar kullanıcı-öge etkileşimlerinin birlikte kullanıldığı eğitim, sol kısımda gösterilen pazar-bağımsız eğitimle ifade edilirken, sadece hedef pazar etkileşimlerinin kullanıldığı eğitim adımı sağ kısımda pazara-özel eğitim şeklinde gösterilmektedir. Hedef pazar kullanıcıları mavi düğümlerle ifade edilirken, kaynak pazar kullanıcıları kırmızı düğümlerle gösterilmiştir. Etkileşimde olunan ürünler ise mor renkle gösterilmektedir.

Yukarıda sözde kodda sıralanan 6, 7 ve 8. adımlar şeklin ortasında yer alan bilgi transferi ile ifade edilmiştir. Bu alanda ilk adımda gerçekleşen eğitim sonrası elde edilen temsiller, ikinci aşamada kullanılmak üzere rastgele atanan vektör parçalarıyla birleştirilmektedir. İlk adımda kaynak pazarın bağlamı hedefle birlikte öğrenilirken, ikinci adımda sadece hedefe odaklanılarak daha spesifik bir öğrenme gerçekleştirilir. Her iki öğrenimin avantajıyla böylece daha sağlam bir sistem gerçekleşmiş olur.



Şekil 5.1 : İki aşamalı çizge ağı eğitim akışı.

6. DENEYLER ve DEĞERLENDİRME

Bu bölümde deneyler ve performans testlerinin detayları yer almaktadır. Bunlara ek olarak, deneylerin uygulandığı veri kümesinin içeriği ve hazırlanması, modellerin hiper-parametreleri gibi diğer bilgiler de bulunmaktadır.

Bahsedildiği üzere çalışmanın referans noktası FOREC araştırmasıdır. Bu nedenle performans testlerinde FOREC çalışmasında yer alan GMF, MLP, NMF, MAML ve FOREC modellerini uygulayarak, bu modellerin sonuçlarına yer verildi. Bunların yanında pazarlar arası öneri problemi için tasarladığımız sistemin ilk adımı ve ikinci yani nihai adımındaki modellerin performans ölçümleriyle birlikte Çizelge 6.2’de tamamına yer verilen toplamda 7 farklı modelin sonuçları bulunmaktadır. Performans ölçüm kriteri olarak $nDCG@10$ sıralama metriği kullanıldı.

6.1 Veri Kümesi

Modeller hedef pazarda tahminlemeleri yapabilmek için hem kendi yani hedef pazarı hem de kaynak pazar olmak üzere iki pazarın verisini kullanarak eğitildi. Bu pazarları şu şekilde sıralayabiliriz. Almanya, İngiltere, Japonya, Meksika ve Amerika Birleşik Devletleri (ABD sadece kaynak pazar olarak kullanıldı). Listelenen bu pazarların toplam kullanıcı-ürün etkileşim sayısı sırasıyla 15889, 30216, 4209, 16816, 163439 şeklindedir. Sayılardan anlaşılacağı üzere kullanıcı-ürün etkileşim verisi bakımından en büyük pazar Amerika Birleşik Devletleri, en küçüğü ise Japonya’dır.

Referans çalışma olarak ifade edilen FOREC’te yapıldığı üzere burada da eğitim, doğrulama ve test aşamalarında benzer şekilde verinin ön işleme adımları uygulandı. İlk olarak bir kullanıcı için minimum 5 adet ürün ile etkileşimi eşik değeri olarak filtrelendi ve daha az sayıda etkileşimi olan kullanıcılar elendi. Sonrasında, her bir kullanıcı için birer ürün etkileşimi doğrulama ve test kümelerine alındı ve o kişinin geriye kalan ürün etkileşimleri eğitim verisi olarak ayrıldı.

6.2 Model Mimarileri ve Hiper-parametreler

Beşinci bölümde hibrit modelin nasıl bir akışla eğitildiğinden bahsedilmişti, burada ise deneylerde eğitilen modellerin hangi hiper-parametrelerle, ne şekilde gerçekleştirildiğinin detaylarına yer verilecektir.

FOREC başarımı, market-bağımsız LGCN ve hibrit LGCN ile karşılaştırılacağından ötürü burada kullanılan hiper-parametreler referans çalışmaya benzer şekilde uygulamaya çalıştık. Bunu yaparken öncelikle FOREC’te uygulanmış hiper-parametreler birebir uygulandı, ancak sonrasında farklı hiper-parametrelerle iletlenen deneylerimizde, farklı negatif örnekleme sayısı kullanmanın FOREC için performans ölçümlerinde daha yüksek sonuçlar verdiğini tecrübe ettik. Bu nedenle FOREC özelinde sadece negatif örnekleme sayısını 4’ten 48’e değiştirildiği parametre değerlerinin sonuçlarına yer verildi. Barındırdığı modellerden bahsetmek gerekirse, GMF modelinde her bir kullanıcı ve ürünü uzunluğu sekiz olan vektörler ile temsil edip, öğrenme aşamasında Adam optimize edici ve L2 düzenleyicisi kullanıldı (Kingma ve diğ., 2014). Öte yandan MLP modeli üçü ara katman olmak üzere 16, 64, 32, 16, 8 düğüm sayılarında beş katmanlı bir ağ yapısıyla, yine Adam ve L2 kullanılarak eğitildi. NMF modeli ise MLP ve GMF modellerinin katmanlarını kullanarak eğitilmesiyle son halini aldı. Üç modelin her biri 25 devir sayısı, 1024 parça boyutu ve ikili çapraz entropi kayıp fonksiyonu ile eğitildi. Sonraki adımda NMF modeli üzerinden MAML modeli, doyum noktasına hızlı ulaştığı için 10 devir sayısı, kendine özgü parametreleri 0.1 meta-öğrenme katsayısı ve 20 parça boyutu ile eğitildi. FOREC’in son adımında dondurulan MAML modeli katmanları üzerine 16, 32, 16 düğüm sayılarına sahip katmanlar ekleyerek, 20 parça boyutu ve 10 devir sayısı ile eğitildi ve FOREC için nihai model elde edilmiş oldu.

Tasarladığımız sistemin ilk adımında temel LGCN modelinde her bir kullanıcıyı ve ürünü 1024 vektör uzunluğu ile temsil ederek çizge modeli yapılandırıldı. İkinci aşamada ise ekstra 1024 uzunluğundaki vektörle toplamda 2048 uzunluğunda vektör temsilleri ile çizge oluşturuldu. Her bir pozitif örnek için 4 negatif örnek eklenerek eğitim kümesi zenginleştirildi. Katman sayısı k her iki adımdaki çizge için 4, parça boyutu 2048, öğrenme katsayısı 0.001, L2 düzenleyici, Adam optimize edici ve 20 devir sayısı hiper-parametreleri ile eğitim tamamlandı.

6.3 Veri Kümesi İstatistikleri

Bu bölümde veri kümesi pazarları içindeki temel ortalama metriklerine ve iki-parçalı çizgeden çıkarılan farklı çizge metriklerine yer verildi. Bunlara ek olarak bu metriklerin, doğrulama verisi ile ilişkisi incelendi. Bu metrikler aşağıda listelenmiştir.

Skor: Kullanıcıların ürünlere verdiği skorların normalize edilmiş hali

Kaynak Pazar Uzunluğu: Bir hedef pazarın test kümesi içindeki kullanıcıların etkileşimde olduğu öğelerin diğer pazarların (kaynak) eğitim verisi içindeki ikili sayılarının ortalaması

Hedef Pazar Uzunluğu: Bir hedef pazarın test kümesi içindeki kullanıcıların kendi eğitim verisi içindeki ikili sayısı ortalaması

Diğer 4 metrik çizgeye özel değerlerdir. Bu değerlerin çıkarımı kaynak ve hedef pazar ikilileri ile iki-parçalı çizge oluşturulduktan sonra, yine hedef pazar kullanıcılarının değerlerinin ortalaması ile elde edilmiştir. Sonuç olarak veriden elde ettiğimiz toplamda 7 farklı metriğe Çizelge 6.1’de yer verilmiştir.

Çizelge 6.1 : Hedef Pazar Ortalama Değerleri.

Metrik	Almanya	Meksika	İngiltere	Japonya
Skor	0,89	0,92	0,91	0,87
Kaynak Pazar Uzunluğu	31,4	80,07	42,83	14,01
Hedef Pazar Uzunluğu	39,58	335,7	124,5	14,02
Derece Merkeziliği	0,0011	0,0011	0,0008	0,0013
Yakınlık Merkeziliği	0,282	0,283	0,289	0,265
Düğüm Fazlalık Katsayısı	0,462	0,67	0,492	0,381
Kümeleme Katsayısı	0,11	0,37	0,16	0,1

Çizelge incelendiğinde, Meksika pazarı düğüm fazlalığı ve kümeleme katsayılarının yanı sıra kullanıcıları kaynak ve hedef pazarlarındaki etkileşim sayılarında maksimum değerlere sahiptir. Diğer tarafta Japonya bu değerler için bu dört pazar

içinde minimum değerlere sahiptir. Çizgeden elde ettiğimiz bu metrikleri incelemek gerekirse düğüm fazlalık katsayısı denklem 6.1’de görüldüğü gibidir.

$$dfk(v) = \frac{|\{ \{u, w\} \subseteq N(v), \exists v' \neq v, (v', u) \in E \text{ and } (v', w) \in E \}|}{\frac{|N(v)|(|N(v)| - 1)}{2}} \quad (6.1)$$

Bu değer her ikisi de diğer düğümlere bağlı olan v'nin komşu çiftlerinin oranını gösterir; burada $N(v)$, v düğümünün komşuları kümesini, E ise kenar ikilileri kümesidir. Diğer bir ifadeyle u ve w, v düğümü olmadan da birbiri ile bağlanabilir. Düğüm fazlalığı katsayısının, derece ile birlikte düşmesi şaşırtıcı değildir, çünkü bir düğümün önemli miktarda fazlalığa sahip olması için gerekli olan projeksiyondaki bağlantıların sayısı derecesinin karesi ile birlikte artar (Latapy ve diğ, 2008). Bu değerlerden yola çıkarak, Meksika'daki çoğu kullanıcının diğer pazarlara göre daha bağlantılı olduğu sonucuna varılır, bu durumun da başarılı tahminleri kolaylaştırıcı etki göstereceği beklenebilir.

İkinci olarak, formül 6.2’de görülen k_u kümeleme katsayısı bağlantıların yerel yoğunluğunun bir ölçüsüdür.

$$k_u = \frac{\sum_{v \in N(N(u))} k_{uv}}{|N(N(u))|} \quad (6.2)$$

İkinci dereceden komşular $N(N(u))$ ve formül 6.3’te verilen u ve v düğümleri arasında k_{uv} ikili kümeleme katsayısını kullanır. Kümeleme katsayısı, grafikteki toplam düğüm sayısına odaklanmadığı için merkezilik ölçümlerine göre (Scott ve Carrington, 2011) daha yorumlanabilir görünmektedir.


$$k_{uv} = \frac{|N(u) \cap N(v)|}{|N(u) \cup N(v)|} \quad (6.3)$$

6.4 Performans Ölçümleri ve Farklı İlintiler

Çalışmamızda deneylenen ikililer FOREC’teki tüm pazarların tüm kombinasyonları gibi değil, daha az sayıdaki ikililerle yapıldı. Yukarıda listelenen pazarlardan DE, UK, JP ve MX hem hedef hem de kaynak pazar olarak kullanılırken, US ise sadece kaynak pazar olarak deneylerde yer aldı. Yani 4 hedef pazar için farklı 4 kaynak

pazar verisi kullanılarak her biri için 7 farklı modelin deneyi ile toplamda 112 performans testi ölçümü yapılmış oldu.

Test sonuçlarına geçmeden önce Çizelge 6.1’de bulunan metrikler ile kullanıcıların doğrulama verisi üzerindeki $nDCG@10$ skorları arasındaki ilişkileri incelendi. Bahsedilen değişkenlerin ilintilerine aşağıda Şekil 6.1’de görüldüğü üzere yer verilirken, bu ilinti matrisleri bağlamında gelecek çalışmalarda olası iyileştirme ve farklı araştırma noktalarına değinildi.



Şekil 6.1 : Soldan-sağa, yukarıdan aşağı sırasıyla Japonya, Almanya, Meksika ve İngiltere pazarları ilinti matrisleri.

Şekilde kısaltma olarak ifade edilen metrikler şunlardır ve tamamı hedef pazardaki kullanıcılar özelinde hesaplanmıştır.

KIU: Kullanıcı-ürün birinci dereceden ikili uzunluğu

DM: Derece merkeziliği

DF: Düzüm fazlalık katsayısı

KK: Kümeleme katsayısı

YM: Yakınlık merkeziliği

KAIU: Kaynak pazardaki ikili uzunluğu (ikinci derece komşular dahil)

HEIU: Hedef pazardaki ikili uzunluğu (ikinci derece komşular dahil)

Bu ilinti matrislerinden anlaşılacağı üzere, düğüm fazlalığı ve kümeleme katsayısı metrikleri, Meksika pazarında NDCG skoru ile diğerlerinden daha yüksek ilinti katsayılarına sahipken, Japonya bu metrikler için minimuma ilintiye sahiptir. Pazarların davranışları Çizelge 6.1 istatistiklere benzerdir. Bu nedenle, yüksek düğüm fazlalığı veya kümelenme katsayısı değerlerine sahip düğümlerden oluşan pazarlar için daha iyi tahminlerin yapılabilme ihtimali daha yüksektir sonucu çıkarılabilir. Bölümün başında detaylarını ifade ettiğimiz test sonuçlarına Çizelge 6.2’de yer verdik.

Çizelge 6.2 : Modellerin nDCG@10 Performans Karşılaştırması.

	Model Type	Almanya	Meksika	İngiltere	Japonya
En İyi Kaynak	GMF	0,29	0,54	0,37	0,17
	MLP	0,28	0,54	0,36	0,18
	NMF	0,28	0,54	0,37	0,18
	MAML	0,31	0,55	0,34	0,2
	FOREC	0,32	0,57	0,34	0,21
	LGCN	0,35	0,59	0,41	0,26
	LGCN _{hibrit}	0,37	0,61	0,42	0,27
Kaynakların Ortalaması	GMF	0,27	0,51	0,34	0,16
	MLP	0,26	0,51	0,35	0,16
	NMF	0,27	0,51	0,32	0,16
	MAML	0,3	0,54	0,34	0,17
	FOREC	0,31	0,56	0,34	0,2
	LGCN	0,35	0,59	0,41	0,25
	LGCN _{hibrit}	0,36	0,61	0,42	0,27
Sabit Kaynak (US)	GMF	0,29	0,54	0,34	0,17
	MLP	0,28	0,54	0,35	0,18
	NMF	0,28	0,54	0,34	0,18
	MAML	0,3	0,55	0,34	0,16
	FOREC	0,31	0,57	0,35	0,19
	LGCN	0,35	0,59	0,41	0,26
	LGCN _{hibrit}	0,36	0,61	0,42	0,27

Değerlendirmeler FOREC ile aynı şekilde en iyi kaynak, kaynakların ortalaması ve sabit kaynak pazar (US) olarak üç kısımda gruplanmıştır. Sonuçlardan anlaşılacağı üzere iki aşamalı hibrit LGCN yaklaşımı, farklı hedef pazarlar için yüzde 5 ila 8 puanlık bir iyileşme ile FOREC'in tüm sonuçlarından daha iyi performans aldığı deneylendi. Ek olarak, ikinci adımdaki pazara özel eğitim ilk adımdaki LGCN sonuçlarının yüzde 1 ila 2 oran aralığında iyileşmesine katkı sağladığı görülmektedir.





7. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada, teknoloji şirketlerinin yeni ülkelere girmesi durumunda ortaya çıkabilecek kıt veri sorununu çapraz pazar öneri problemi bağlamında ele alındı. Böyle bir durumda etkin tahminler yapabilmek için şimdiye kadar yapılan çalışmaları inceleyerek, alandaki güncel bir çalışma olan FOREC'te açık kaynak olarak verilen veri kümesi kullanıldı. Farklı özelliklere sahip eğitimlerin birleştirilmesiyle çok az sayıdaki etkileşimden öğrenme yeteneğinin yanı sıra, kaynak pazarın nispeten çok daha fazla veriye sahip olduğu durumlarda dengesiz öğrenmeyi önleyecek yeteneğe de sahip olması amaçlandı.

Verinin iki parçalı çizge ile yapılandırılması, düğüm temsillerinin çıkarımında farklı derinliklerdeki komşuluk ilişkilerinin yakalanarak sonucu iyileştirici etki göstermesi önemli bir nokta oldu. Öte yandan, iki farklı hafif çizge evrişimli ağı pazar bağımsız ve pazara özel şekilde uygulayarak kaynak pazarın hedef pazara adaptasyonu ve hedef pazarın spesifik davranışlarının yakalanması amaçlandı. Gerçekleştirilen deneyler sonuçların nDCG@10 değerlendirme metriğinde %5 ile %8 arasında iyileştirme sağladığını gösterdi.

Sonuçların dışında veriden çıkarılan çizge istatistikleri pazarların kullanıcı-ürün etkileşimlerinin farklı özelliklere sahip olduğunu gösterdi. Örneğin, Meksika pazarı düğüm fazlalık ve kümeleme katsayılarına bakıldığında diğer pazarlardan yüksek değerler gösterirken, Japonya içlerinde en düşük değerlere sahip oldu. Bu iki metriğin düğümlerin komşuluk ilişkilerinin yoğunluğuyla ilintili olduğu düşünülürse, yüksek değerlere sahip olan Meksika'nın daha başarılı öneri sonuçları alması beklendiği gibi gerçekleşti.

Şekil 6.1'deki ilinti matrisleri nDCG sonuçlarının ilgili düğümlerin çizge istatistikleri ile ilişkisini gösterirken, üzerinde çalışılan problemde bazı iyileştirmeler konusunda da fikir verdi. Bu metrikler tekil düğümlerin ortalama değerleri üzerinden çıkarıldığı için hem düğüm spesifik hem de ait olduğu pazara özgü yaklaşımlarla iyileştirme yöntemlerine kapı aralamaktadır.

İlk olarak düğüm spesifik iyileştirme noktaları düşünüldüğünde, bir düğümün ilgili çizge metriğinin (örneğin fazlalık katsayısı) düşük olduğu durumda farklı negatif örnek sayısı veya zor negatif örnek eklenmesi gibi o düğüme özel bir yaklaşımla eğitime yön verilmesi iyileştirme sağlayabilir. Bunların dışında düğüm bazında farklı veri büyütme teknikleri de sonuçları iyileştirici etki gösterebilir. Öte yandan bu yaklaşım benzer şekilde tüm pazara da uygulanabilir. Çizelge 6.1’de düşük değerlere sahip pazarlar farklı hiper-parametrelerle eğitilerek iyileştirme alınması yine farklı araştırma noktalarından biri olarak uygulanabilir.

İyileştirme amacı dışında farklı bir çalışma alanı işlem maliyetini düşürmek olabilir. Bahsedilen çizge metrikleri ilgili çizgenin sadeleştirilmesi noktasında kullanılarak daha kısa sürede eğitim süreleriyle aynı ya da daha iyi sonuçların alınması farklı bir problem olarak çalışılabilir.

KAYNAKLAR

- Bernardis, C.** (2022). Multi-stage Ensemble Model for Cross-market Recommendation. Unpublished manuscript.
- Bonab, H., Aliannejadi, M., Vardasbi, A., Kanoulas, E., & Allan, J.** (2021, October). Cross-market product recommendation. *In Proceedings of the 30th ACM International Conference on Information & Knowledge Management* (pp. 110-119).
- Burke, R.** (2002). Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, 12(4), 331-370.
- Cremonesi, P., Koren, Y., & Turrin, R.** (2010, September). Performance of recommender algorithms on top-n recommendation tasks. *In Proceedings of the fourth ACM conference on Recommender systems* (pp. 39-46).
- Fayyaz, Z., Ebrahimian, M., Nawara, D., Ibrahim, A., & Kashef, R.** (2020). Recommendation systems: Algorithms, challenges, metrics, and business opportunities. *applied sciences*, 10(21), 7748.
- Finn, C., Abbeel, P., & Levine, S.** (2017, July). Model-agnostic meta-learning for fast adaptation of deep networks. *In International conference on machine learning* (pp. 1126-1135). PMLR.
- He, X., Deng, K., Wang, X., Li, Y., Zhang, Y., & Wang, M.** (2020, July). Lightgcn: Simplifying and powering graph convolution network for recommendation. *In Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval* (pp. 639-648).
- Isinkaye, F. O., Folajimi, Y. O., & Ojokoh, B. A.** (2015). Recommendation systems: Principles, methods and evaluation. *Egyptian informatics journal*, 16(3), 261-273.
- Kingma, D. P., & Ba, J.** (2014). Adam: A method for stochastic optimization. Unpublished manuscript.
- Kipf, T. N., & Welling, M.** (2016). Semi-supervised classification with graph convolutional networks. Unpublished manuscript.
- Latapy, M., Magnien, C., & Del Vecchio, N.** (2008). Basic notions for the analysis of large two-mode networks. *Social networks*, 30(1), 31-48.
- Scarselli, F., Gori, M., Tsoi, A. C., Hagenbuchner, M., & Monfardini, G.** (2008). The graph neural network model. *IEEE transactions on neural networks*, 20(1), 61-80.
- Scott, J., & Carrington, P. J.** (2011). The SAGE handbook of social network analysis. *SAGE publications*.

- Shenbin, I., Alekseev, A., Tutubalina, E., Malykh, V., & Nikolenko, S. I.** (2020, January). Recvae: A new variational autoencoder for top-n recommendations with implicit feedback. *In Proceedings of the 13th International Conference on Web Search and Data Mining* (pp. 528-536).
- Wang, X., He, X., Wang, M., Feng, F., & Chua, T. S.** (2019, July). Neural graph collaborative filtering. *In Proceedings of the 42nd international ACM SIGIR conference on Research and development in Information Retrieval* (pp. 165-174).
- Ying, R., He, R., Chen, K., Eksombatchai, P., Hamilton, W. L., & Leskovec, J.** (2018, July). Graph convolutional neural networks for web-scale recommender systems. *In Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining* (pp. 974-983).
- Zhang, S., Tong, H., Xu, J., & Maciejewski, R.** (2019). Graph convolutional networks: a comprehensive review. *Computational Social Networks*, 6(1), 1-23.
- Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., Wang, L., Li, C., & Sun, M.** (2020). Graph neural networks: A review of methods and applications. *AI Open*, 1, 57–81.

ÖZGEÇMİŞ

Ad-Soyad : Emre KÖSE

ÖĞRENİM DURUMU:

- **Lisans** : 2018, İstanbul Teknik Üniversitesi, Bilgisayar ve Bilişim Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2018-2019 Huawei - Yazılım Geliştirme Mühendisi
- 2019-2021 Turkcell - Yapay Zeka ve Makine Öğrenmesi Mühendisi
- 2021- Çiçeksepeti - Makine Öğrenmesi Mühendisi

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

Köse, E. & Yaslan, Y. 2023. Cross-Market Recommendation with Two-stage Graph Learning. Unpublished manuscript.
(8. Uluslararası Bilgisayar Bilimleri ve Mühendisliği Konferansı'na kabul edildi)