



**DERİN ÖĞRENME YAKLAŞIMLARI İLE
ÇOKLU-KRİTERLİ ÖNERİ SİSTEMLERİNİN
PROBLEMLERİNİ ÇÖZMEK**

Doktora Tezi

Zeynep BATMAZ

Eskişehir 2019

**DERİN ÖĞRENME YAKLAŞIMLARI İLE ÇOKLU-KRİTERLİ ÖNERİ
SİSTEMLERİNİN PROBLEMLERİNİ ÇÖZMEK**

Zeynep BATMAZ

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Yazılımı Bilim Dalı

Danışman: Doç. Dr. Cihan KALELİ

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Aralık 2019

Bu tez çalışması BAP Komisyonu tarafından kabul edilen 19ADP032 no.lu proje kapsamında desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Zeynep BATMAZ'ın Derin Öğrenme Yaklaşımları ile Çoklu-kriterli Öneri Sistemlerinin Problemlerini Çözmek başlıklı tezi 02/12/2019 tarihinde aşağıdaki jüri tarafından değerlendirilerek “Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği”nin ilgili maddeleri uyarınca, Bilgisayar Mühendisliği Anabilim dalında Doktora tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye (Tez Danışmanı)	: Doç. Dr. Cihan KALELİ	
Üye	: Doç. Dr. Alper BİLGE	
Üye	: Doç. Dr. Muhammet Recep OKUR	
Üye	: Prof. Dr. Yaşar HOŞCAN	
Üye	: Doç. Dr. Kemal ÖZKAN	

Prof. Dr. Murat TANIŞLI

Lisansüstü Eğitim Enstitüsü Müdürü

ÖZET

DERİN ÖĞRENME YAKLAŞIMLARI İLE ÇOKLU-KRİTERLİ ÖNERİ SİSTEMLERİNİN PROBLEMLERİNİ ÇÖZMEK

Zeynep BATMAZ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Yazılımı Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Aralık 2019

Danışman: Doç. Dr. Cihan KALELİ

Artan İnternet kullanımıyla birlikte kullanıcılar kişisel zevklerine uygun ürünlere/hizmetlere erişmekte zorlanırlar. Geleneksel öneri sistemleri bu durumla başa çıkabilmede etkili yöntemlerdendir. Ancak günümüzde kullanıcılar geleneksel öneri sistemlerindeki aksine ürünler/hizmetler hakkında farklı kriterler bazında değerlendirmelerde bulunurlar. Çoklu-kriterli öneri sistemleri, kullanıcılarına farklı kriterler altında değerlendirme yapmalarına olanak sunan geleneksel öneri sistemi uzantılarıdır. Çoklu-kriterli öneri sistemlerinde üretilen tahminlerin doğruluğu, kullanıcı memnuniyetini ve bu sistemlerin sürdürülebilirliğini etkiler. Ayrıca artan kriter sayısına bağlı olarak çoklu-kriterli öneri sistemlerinde veri seyrekliği problemi daha belirgin bir sorun haline dönüşmekte ve artan veri miktarından dolayı makul zamanda tahminler üretmek zorlaşmaktadır.

Derin öğrenme tekniklerinin heterojen ve büyük boyutlu veriden gizli, kompleks ve lineer olmayan özellikleri çıkarmadaki başarısı bu tekniklerin geleneksel öneri sistemlerinde sıklıkla kullanılmasını sağlamıştır. Bu tez kapsamında çoklu-kriterli öneri sistemlerinin temel problemlerinden olan doğruluk, veri seyrekliği ve ölçeklenebilirlik sorunlarını çözebilmek amacıyla otokodlayıcılara dayanan yeni yaklaşımlar önerilmiştir. Gerçek veri setleri üzerinden gerçekleştirilen deneysel çalışmalar ve analizler, önerilen yöntemlerin mevcut öncü çoklu-kriterli öneri sistemi algoritmalarına göre belirtilen problemlerin çözümünde daha etkili olduklarını göstermiştir.

Anahtar Sözcükler: Çoklu-kriterli öneri sistemleri, Doğruluk, Veri seyrekliği, Ölçeklenebilirlik, Derin öğrenme.

ABSTRACT

DEEP LEARNING-BASED APPROACHES TO HANDLE CHALLENGES OF MULTI-CRITERIA RECOMMENDER SYSTEMS

Zeynep BATMAZ

Department of Computer Engineering

Programme in Computer Software

Eskişehir Technical University, Institute of Graduate Programs, December 2019

Supervisor: Assoc. Prof. Dr. Cihan KALELİ

With increasing usage of the Net, users have difficulties in accessing products/services which matching their personal tastes. Traditional recommender systems are effective methods to cope with this situation. However, unlike traditional recommender systems, users have evaluated products/services considering different criteria recently. Multi-criteria recommender systems are extensions of traditional recommender systems that allow users to evaluate considering different criteria. Accuracy of produced predictions by multi-criteria recommender systems affects users' satisfaction and sustainability of these systems. Furthermore, due to the increasing number of criteria, sparsity becomes a more prominent problem for multi-criteria recommender systems and producing predictions at a reasonable time becomes difficult due to the increasing amount of data.

The success of deep learning techniques in extracting hidden, complex and non-linear features from heterogeneous and big data has led to the frequent usage of these techniques in traditional recommender systems. In this dissertation, new approaches based on autoencoders have been proposed in order to solve main problems of multi-criteria recommender systems such as accuracy, sparsity and scalability. Experimental works and analyzes performed on real data sets have shown that the proposed methods are more effective than the existing state-of-the-art multi-criteria recommendation techniques in solving the specified problems.

Keywords: Multi-criteria recommender systems, Accuracy, Sparsity, Scalability, Deep learning.

TEŞEKKÜR

Öncelikle, tez çalışması sürecinde deneyimlerini, bilgilerini ve desteğini en üst düzeyde hissettiğim danışman hocam Sayın Doç. Dr. Cihan KALELİ'ye katkılarından ötürü en derin teşekkürlerimi sunarım. Çalışmama oldukça katkı sağlayan tez izleme süreçleri boyunca tez izleme jürisinde yer alan hocalarım ve komite üyesi hocalarım Sayın Doç. Dr. Alper BİLGE, Sayın Doç. Dr. Muhammet Recep OKUR, Sayın Prof. Dr. Yaşar HOŞCAN ve Sayın Doç. Dr. Kemal ÖZKAN'a verdikleri öneriler, paylaştıkları bilgi birikimleri ve desteklerinden ötürü teşekkürlerimi sunarım. Tez çalışmama katkı sağlayan Sayın Doç. Dr. Alper Kürşat UYSAL'a sunduğu fikir ve önerilerden ötürü teşekkürlerimi sunarım. Tez çalışmam sürecinde benden hiçbir zaman desteğini esirgemeyen sevgili eşime ve her zaman yanımda olan aileme saygı, sevgi ve teşekkürlerimi sunarım.

Zeynep BATMAZ

Aralık, 2019

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Zeynep BATMAZ

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vi
İÇİNDEKİLER.....	vii
TABLolar DİZİNİ	ix
ŞEKİLLER DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ	1
1.1. Öneri Sistemleri.....	1
1.1.1. OF teknikleri.....	1
1.1.2. İçerik-tabanlı filtreleme teknikleri	2
1.2. Çoklu-kriterli Ortak Filtreleme.....	2
1.3. ÇKOF Sistemlerinde Karşılaşılan Problemler	5
1.4. Tezin Amacı	7
1.5. Derin Öğrenme	9
1.5.1. Otokodlayıcılar	11
1.6. Tezin Katkıları	12
1.7. Tez Organizasyonu	13
2. OTOKODLAYICILARA DAYANAN YENİ BİR BİRLEŞTİRME- FONKSİYONU TABANLI ÇKOF YAKLAŞIMI	14
2.1. Motivasyon ve Önerilen Yaklaşımın Özgünlüğü	14
2.2. AE-MCCF	15
2.3. Deneysel Çalışmalar	20
2.3.1. Veri setleri ve değerlendirme ölçütleri	21
2.3.2. Deneysel sonuçlar ve tartışma	22
2.3.2.1. Değişen otokodlayıcı parametrelerinin etkileri	22
2.3.2.2. AE-MCCF algoritmasının öncü ÇKOF yaklaşımlarıyla karşılaştırılması.....	25

2.4. Değerlendirmeler.....	26
3. OTOKODLAYICILARA DAYANAN YENİ BİR ÖLÇEKLENEBİLİR BENZERLİK-TABANLI ÇKOF YAKLAŞIMI	28
3.1. Motivasyon ve Önerilen Yaklaşımın Özgünlüğü	28
3.2. AE-simMCCF	30
3.3. Deneysel Çalışmalar	34
3.3.1. Veri setleri ve değerlendirme ölçütleri	35
3.3.2. Deneysel sonuçlar ve tartışma	35
3.3.2.1. Ağ parametrelerinin etkileri.....	35
3.3.2.2. AE-simMCCF algoritmasının öncü ÇKOF yaklaşımlarıyla karşılaştırılması.....	40
3.4. Tartışma	41
3.5. Değerlendirmeler.....	43
4. OTOKODLAYICILARA DAYANAN YENİ BİR BENZERLİK- TABANLI HİBRİT ÇOKLU-KRİTERLİ ÖNERİ SİSTEMİ YAKLAŞIMI	44
4.1. Motivasyon ve Önerilen Yaklaşımın Özgünlüğü	44
4.2. AE-simMCCF++	45
4.3. Deneysel Çalışmalar	52
4.3.1. Veri setleri ve değerlendirme ölçütleri	52
4.3.2. Deneysel sonuçlar ve tartışma	53
4.3.2.1. Ağ parametrelerinin etkileri.....	53
4.3.2.2. AE-simMCCF++ algoritmasının AE-simMCCF ile kaynştırılması.....	55
4.4. Değerlendirmeler.....	56
5. DEĞERLENDİRMELER VE GERÇEKLEŞTİRİLMESİ PLANLANAN DİĞER ÇALIŞMALAR.....	57
KAYNAKÇA.....	60
ÖZGEÇMİŞ	68

TABLÖLER DİZİNİ

Sayfa

Tablo 2.1. YM veri seti için değişen kodlayıcı katman sayılarının AE-MCCF algoritmasının performansına etkileri	23
Tablo 2.2. TA veri seti için değişen kodlayıcı katman sayılarının AE-MCCF algoritmasının performansına etkileri	24
Tablo 2.3. YM veri seti için değişen aktivasyon fonksiyonlarının AE-MCCF algoritmasının performansına etkileri	25
Tablo 2.4. TA veri seti için değişen aktivasyon fonksiyonlarının AE-MCCF algoritmasının performansına etkileri	25
Tablo 2.5. YM veri seti için AE-MCCF algoritmasının öncü ÇKOF yaklaşımları ile kıyaslanması.....	26
Tablo 2.6. TA veri seti için AE-MCCF algoritmasının öncü ÇKOF yaklaşımları ile kıyaslanması.....	26
Tablo 3.1. YM veri seti için değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının U-AE-simMCCF algoritmasının performansına doğruluk ve kapsama açısından etkileri	37
Tablo 3.2. TA veri seti için değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının U-AE-simMCCF algoritmasının performansına doğruluk ve kapsama açısından etkileri	38
Tablo 3.3. YM veri seti için değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının I-AE-simMCCF algoritmasının performansına doğruluk ve kapsama açısından etkileri	39
Tablo 3.4. YM veri seti için AE-simMCCF algoritmasının öncü ÇKOF teknikleriyle kıyaslanması.....	41
Tablo 3.5. TA veri seti için AE-simMCCF algoritmasının öncü ÇKOF teknikleriyle kıyaslanması.....	41
Tablo 4.1. Değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının AE-simMCCF++ algoritmasının performansına doğruluk ve kapsama açısından etkileri	55

Tablo 4.2. Doğruluk ve kapsama açısından AE-simMCCF++ algoritmasının AE-simMCCF ile kıyaslanması.....	56
--	----



ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Tek-kriterli ve çok-kriterli öneri sistemleri (Adomavicius vd., 2011)	3
Şekil 1.2. Tipik bir otokodlayıcı	11
Şekil 2.1. Her bir kriter bazlı otokodlayıcı için eğitim süreci	16
Şekil 2.2. AE-MCCF yönteminin genel gösterilişi	17
Şekil 2.3. AE-MCCF ile tahmin üretme prosedürü	18
Şekil 2.4. AE-MCCF algoritmasının sözde kodu	19
Şekil 3.1. U-AE-simMCCF algoritmasının genel görünümü	31
Şekil 3.2. U-AE-simMCCF algoritmasının sözde kodu	32
Şekil 4.1. AE-simMCCF++ algoritmasının genel görünümü	47
Şekil 4.2. AE-simMCCF++ algoritmasının sözde kodu	48

SİMGELER VE KISALTMALAR DİZİNİ

AO	:	Arıtan Otokodlayıcılar (Denoising Autoencoders)
AOY	:	Arıtan Otokodlayıcı Yığınları (Stacked Denoising Autoencoder)
ÇKOF	:	Çoklu-kriterli Ortak Filtreleme (Multi-criteria Collaborative Filtering)
DLB	:	Doğrultulmuş Lineer Birim (Rectified Linear Unit)
KBM	:	Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines)
KOMH	:	Kök Ortalama Mutlak Hata (Root Mean Squared Error)
KSA	:	Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
OF	:	Ortak Filtreleme (Collaborative Filtering)
OMH	:	Ortalama Mutlak Hata (Mean Absolute Error)
ÖÜLB	:	Ölçeklendirilmiş Üstel Lineer Birim (Scaled Exponential Linear Unit)
TA	:	TripAdvisor
tanh	:	Hiperbolik Tanjant (Hyperbolic Tangent)
TBA	:	Temel Bileşen Analizi (Principle Component Analysis)
TDF	:	Ters Doküman Frekansı (Inverse Document Frequency)
TF	:	Terim Frekansı (Term Frequency)
TF-TDF	:	Terim Frekansı – Ters Doküman Frekansı

	(Term Frequency – Inverse Document Frequency)
ÜLB	: Üstel Lineer Birim, (Exponential Linear Unit)
YM	: Yahoo!Movies
YMTDA	: Yüksek Mertebe Tekil Değer Ayrıştırma (Higher Order Singular Value Decomposition)
YSA	: Yinelemeli Sinir Ağları (Recurrent Neural Networks)



1. GİRİŞ

Günümüzde gittikçe yaygınlaşan İnternet kullanımı, İnternet kullanıcılarının elektronik alışveriş sitelerinden alışveriş yapma, seyahat planlama, kişisel zevklerine uygun film, kitap, restoran, aktivite vb. ürün ve hizmetleri seçebilmesine olanak sağlayan çeşitli hizmetleri de beraberinde getirmiştir. Ancak, İnternet ortamındaki verinin fazlalığı ve çeşitliliği kullanıcıların kendi zevklerine ilişkin ürünlere/hizmetlere kolay bir şekilde erişimini engellemektedir. Öneri sistemleri, aşırı bilgi problemi denilen bu sorun ile başa çıkabilmeyi sağlayan etkili bir yöntemdir.

1.1. Öneri Sistemleri

Öneri sistemleri, kullanıcıların kişisel zevklerine uygun ürünlere/hizmetlere kolay ve hızlı bir şekilde ulaşabilmelerine olanak tanır (Schafer vd., 2001). Çevrimiçi ürün/hizmet sağlayıcıları öneri sistemlerinden yararlanarak kullanıcılarına kişiselleştirilmiş ürünler/hizmetler sağlarlar. Böylelikle kullanıcılar ilgilerini çeken ürünlere/hizmetlere maddi kayıp ve zaman kaybı olmadan hızlıca erişim imkanı bulurlarken ürün/hizmet sağlayıcıları da maddi kazanç elde ederler.

Tipik bir öneri sisteminin bir ürün/hizmet için tahmin üretme (prediction) ve üretilen tahminlere göre kişiselleştirilmiş ürün/hizmet listeleri sunma (recommendation) olmak üzere iki temel fonksiyonu vardır (Sarwar vd., 2001). Tahmin üretme teknikleri açısından öneri sistemleri; ortak filtreleme (OF) teknikleri, içerik tabanlı-filtreleme teknikleri ve her iki yaklaşımın olumlu yönlerini birleştirmeyi hedef edinen hibrit yaklaşımlar olmak üzere üçe ayrılır (Adomavicius ve Tuzhilin, 2005).

1.1.1. OF teknikleri

OF teknikleri, en çok yararlanılan tahmin üretme teknikleridir. OF tekniklerinde aktif kullanıcı için tahminler üretilirken aktif kullanıcı ile benzer davranış eğilimi gösteren diğer kullanıcıların tercihleri göz önünde bulundurulur. OF teknikleri “Geçmişte benzer tercih eğilimi gösteren kişiler gelecekte de benzer tercih eğilimi içerisindeyler.” varsayımına dayanmaktadır. OF tekniklerinden yararlanan sistemlerde ürünlerin/hizmetlerin içerik özellikleri yerine kullanıcıların oy bazlı profilleri tahmin üretme işleminin temelini oluşturur. OF teknikleri kullanıcılarını şaşırtan öneriler sunabilir ancak oy bazlı sistemler olduğundan hakkında değerlendirme bulunmayan ürünleri/hizmetleri kullanıcılarına öneremezler.

OF teknikleri; hafıza-tabanlı yaklaşımlar, model-tabanlı yaklaşımlar ve her iki yaklaşımın olumlu yönlerini kullanan hibrit yaklaşımlar olmak üzere üçe ayrılır. Hafıza-tabanlı yaklaşımlar tahminler üretirken tüm kullanıcı-ürün matrisi üzerinde işlem yaparlar (Breese vd., 1998). Model-tabanlı yaklaşımlarda ise çeşitli veri madenciliği ve makine öğrenmesi teknikleri ile kullanıcı-ürün matrisi üzerinde çevrimdışı bir model oluşturulur. Çevrimiçi OF sistemlerinde daha önceden eğitilen bu model kullanılarak tahminler üretilir (Ricci vd., 2015).

1.1.2. İçerik-tabanlı filtreleme teknikleri

İçerik-tabanlı filtreleme tekniklerinde kullanıcıların geçmişte tercih etmiş oldukları ürünlere içerik olarak benzerlik gösteren diğer ürünler önerilir (Van Meteren ve Van Someren, 2000). İçerik-tabanlı filtreleme, özellikle sisteme yeni eklenen ve hakkında hiç değerlendirme bulunmayan ürünleri/hizmetleri içerik bilgilerini kullanarak kullanıcılara önermede oldukça etkilidir. Ancak bu teknikler, içerik olarak kullanıcılarının geçmişte tercih ettikleri ürünlere/hizmetlere benzeyen önerilerde bulunduklarından kullanıcılarını şaşırtma konusunda zayıf kalırlar (Ricci vd., 2015).

1.2. Çoklu-kriterli Ortak Filtreleme

Geleneksel OF tekniklerinde kullanıcılar ürünleri/hizmetleri tek bir genel kriter üzerinden değerlendirirler. Ancak öneri sistemlerinin giderek yaygınlaşması ile birlikte kullanıcıların zaman içindeki beklentileri de değişmeye başlamıştır. Kullanıcılar ürünleri/hizmetleri tek bir genel kriter altında değerlendirmenin dışında çeşitli alt kriterler bazında da fikirler sunmaya başlamışlardır. Örneğin, bir kullanıcı otel değerlendirmesi yaparken otelin konumunu, tesis imkânlarını, yemeklerini, personel davranışlarını vb. birden fazla kriteri göz önünde bulundurur. Çoklu-kriterli ortak filtreleme teknikleri (ÇKOF) kullanıcıların ürünleri/hizmetleri genel bir kriter altında değerlendirmelerinin yanı sıra çeşitli kriterler altında da değerlendirmelerine olanak sağlayan bir OF uzantısıdır. Böylelikle kullanıcılar bir ürünü/hizmeti değerlendirirken daha kişisel veriler sağladıklarından daha kişiselleştirilmiş öneriler elde ederler. Ürün/hizmet sağlayıcıları da kullanıcılarından daha detaylı bilgi edindiklerinden eksik ve zayıf yönlerini daha kolay tespit edebilirler. Aynı zamanda ÇKOF teknikleri kullanıcıların genel bir değerlendirme yaparken önem verdikleri alt kriterlerin de belirlenmesine olanak sağlar. ÇKOF yöntemleri gezi planlaması, otel ve restoran seçimi gibi birden fazla kriter bazında

değerlendirme gerektiren pek çok alanda kullanılmaktadır (Di Bitonto vd., 2010; Sanchez-Vilas vd., 2011; Farokhi vd., 2016).

Kullanıcı zevklerinin tek bir genel kriter yerine farklı kriterler bazında sunulması öneri sistemlerinin doğruluğunu da artırmıştır (Adomavicius ve Kwon, 2007; Bilge ve Kaleli, 2014). Şekil 1.1’de gösterildiği üzere Alice kullanıcısına Fargo filmi için tek-kriterli öneri sistemlerinde geleneksel OF teknikleri kullanılarak tahmin üretirken Alice kullanıcısına en benzer komşu olan John kullanıcısının Fargo filmine vermiş olduğu oy kullanılır. Şekil 1.1’de açık olduğu üzere kullanıcıların genel kriter değerlendirmelerinin yanı sıra alt kriter değerlendirmelerinin de göz önünde bulundurulduğu çoklu-kriterli öneri sistemlerinde Alice kullanıcısına, yapılan tercihler açısından en çok benzeyen kullanıcı Mason kullanıcısı olduğu görülmektedir. Dolayısı ile Alice kullanıcısına ÇKOF teknikleri ile Fargo filmi için tahmin üretilirken Mason kullanıcısının Fargo filmine yapmış olduğu değerlendirmeler kullanılır. Bu örnekten de görüldüğü üzere kullanıcıların değerlendirmelerini çeşitli kriterler altında sunmaları tercih eğilimleri açısından daha iyi ifade edilebilmelerini sağlar böylelikle kalitesi daha yüksek öneriler üretilmiş olur.

Tek-kriterli öneri sistemi					
	Wanted	Wall-E	Star Wars	Seven	Fargo
Alice	5	7	5	7	?
John	5	7	5	7	9
Mason	6	6	6	6	5

Çoklu-kriterli öneri sistemi					
	Wanted	Wall-E	Star Wars	Seven	Fargo
Alice	5,2,2,8,8	7,5,5,9,9	5,2,2,8,8	7,5,5,9,9	?,?,?,?,?
John	5,8,8,2,2	7,9,9,5,5	5,8,8,2,2	7,9,9,5,5	9,8,8,10,10
Mason	6,3,3,9,9	6,4,4,8,8	6,3,3,9,9	6,4,4,8,8	5,2,2,8,8

Şekil 1.1. Tek-kriterli ve çok-kriterli öneri sistemleri (Adomavicius vd., 2011)

Tipik bir OF sisteminde kullanıcı ve ürünler arasındaki ilişki $R: \text{Kullanıcı} \times \text{Ürün} \rightarrow R_0$ fonksiyonu ile ifade edilirken, bir ÇKOF öneri sisteminde ise kullanıcı ve ürünler arasındaki ilişki $R: \text{Kullanıcı} \times \text{Ürün} \rightarrow$

$R_0 \times R_1 \times R_2 \times \dots \times R_k$ fonksiyonu ile temsil edilir. Burada R_0 kullanıcıların ürünlere vermiş oldukları genel oyları gösterirken $i \in 1, 2, \dots, k$ olmak üzere R_k kullanıcıların ürünlere vermiş oldukları i . kriter bazındaki oyları temsil eder.

ÇKOF teknikleri Adomavicius ve Kwon (2007) tarafından benzerlik-tabanlı yaklaşımlar ve birleştirme fonksiyonu-tabanlı yaklaşımlar olmak üzere iki gruba ayrılmıştır. Benzerlik tabanlı yaklaşımlarda, kullanıcı ve ürünler arasındaki birleştirilmiş benzerlikler çeşitli çok boyutlu mesafe ölçütleri veya benzerlik ölçütleri ile hesaplanır. Benzerlik ölçütlerinin kullanıldığı durumlarda birleştirilmiş korelasyon hesaplanırken öncelikle kullanıcı ve ürünler arasındaki her bir kriter bazındaki korelasyonlar belirlenen benzerlik ölçütü ile hesaplanır. Birleştirilmiş korelasyon değeri ise ortalama veya en kötü durum benzerliği yaklaşımlarından biriyle hesaplanır. Ortalama benzerlik yaklaşımında tüm kriter bazındaki korelasyonların ortalaması birleştirilmiş korelasyon değeri olarak kullanılırken, en kötü durum benzerliği yaklaşımında ise bu korelasyonların en küçüğü birleştirilmiş korelasyon değeri olarak kullanılır. u ve v 'nin genel kriter değerlendirmeleri ve alt kriterler bazındaki değerlendirmeleri içeren iki kullanıcı profili olduğunu varsayarsak u ve v kullanıcı profilleri arasındaki korelasyon değerleri ortalama ve en kötü durum benzerliği yaklaşımlarına göre sırasıyla Eşitlik 1.1 ve 1.2'deki gibi hesaplanır.

$$corr_O(u, v) = \frac{\sum_{c=0}^{c=k} corr_c(u, v)}{k+1} \quad (1.1)$$

$$corr_O(u, v) = \min_{c=0, \dots, k} corr_c(u, v) \quad (1.2)$$

Birleştirilmiş korelasyon değeri hesaplandıktan sonra u kullanıcısının i ürüne vereceği oy Eşitlik 1.3'teki gibi hesaplanır.

$$P(u, i) = \frac{\sum_{v \in N(u)} corr_O(u, v) R(v, i)}{\sum_{v \in N(u)} |corr_O(u, v)|} \quad (1.3)$$

Burada, $N(u)$ u kullanıcısının en benzer- n komşusunu temsil ederken, $R(v, i)$ ise v kullanıcısının i ürününe vermiş olduğu genel kriter bazındaki oyu temsil eder.

Birleştirme fonksiyonu-tabanlı yaklaşımlarda ise kullanıcıların kriter bazındaki oyları ile genel kriter oyları arasındaki ilişkiyi çıkaran bir birleştirme-fonksiyonu kullanılır. Birleştirme fonksiyonu kullanıcı-, ürün-tabanlı olabilir veya tüm veri kullanılarak öğrenilebilir. Birleştirme-fonksiyonu tabanlı yaklaşımlar kriter bazındaki oyların tahmin edilmesi ve birleştirme fonksiyonunun öğrenilmesi olmak üzere iki aşamadan oluşur. Birleştirme fonksiyonu öğrenilirken uzman görüşlerinden, istatistiksel

yöntemlerden, makine öğrenmesi ve veri madenciliği tekniklerinden yararlanılır (Adomavicius ve Kwon, 2007). Kriterler bazındaki tahminler ise herhangi bir öneri sistemi tekniği kullanılarak üretilir. Genel kriter bazındaki tahminler ise kriter bazında üretilen tahminler ve öğrenilen birleştirme-fonksiyonu f kullanılarak tahmin edilir.

$$R_o = f(R_1, R_2, \dots, R_k) \quad (1.4)$$

1.3. ÇKOF Sistemlerinde Karşılaşılan Problemler

OF tekniklerinde olduğu gibi, ÇKOF teknikleri ile tahmin üretilen öneri sistemlerinde de kullanıcıların, tahminlerin doğruluğu açısından yeterince memnun olmaları ilgili sistemlerin kullanılabilirliğini ve devam edilebilirliğini artıracaktır (Adomavicius vd., 2011; Shani ve Gunawardana, 2011). Dolayısı ile ÇKOF tekniklerinde araştırmacılar üretilen oyların doğruluğunu artırmaya yönelik çalışmalar yapmışlardır. Kriterler bazında üretilen benzerlikler benzerlik-tabanlı ÇKOF tekniği kullanılarak üretilen oyların doğruluğunu etkilediğinden bazı çalışmalar da benzerlik ölçütü iyileştirilmiştir (Naak vd., 2009; Hu, 2014a; Hu, 2014b; Hu vd., 2015). Bu amaçla kullanıcılar ve ürünler arasındaki benzerlikler Öklid uzaklığı yöntemi (Wasid ve Ali, 2018), gri ilişkisel analiz (Hu, 2014a; Hu, 2014b; Hu vd., 2015) gibi yöntemlerle hesaplanmıştır. Ancak bu yöntemlerin hepsi lineer yaklaşımlara dayanmaktadır. Birleştirme fonksiyonu-tabanlı yaklaşımlarda üretilen tahminlerin doğruluğu hem üretilen kriter bazındaki oyların doğruluğuyla hem de öğrenilen birleştirme fonksiyonu ile ilişkilidir. Bu sebeple yapılan çalışmaların bir kısmı kriter bazındaki oyların doğruluğunu iyileştirmeyi amaçlarken (Zhang vd., 2009; Farokhi vd., 2016; Majumder vd., 2017; Ashraf ve Hussain, 2018; Kant vd., 2018) diğerleri ise birleştirme fonksiyonunu iyileştirmeyi hedeflemişlerdir (Hwang, 2010; Jannach vd., 2012a; Jannach vd., 2012b; Fan ve Xu, 2013; Agathokleous ve Tsapatsoulis, 2014; Nilashi vd., 2015a; Nilashi vd., 2015b; Hassan ve Hamada, 2017; Hamada ve Hassan, 2018; Tallapally vd., 2018; Kaur ve Ratnoo, 2019). Zhang vd. (2009) olasılıklı gizli anlamsal analiz yöntemini çoklu-kriterli öneri sistemlerine uyarlayarak kriter-bazında oylar üretmişlerdir. Farokhi vd. (2016) kriter bazında tahminler üretirken bulanık c-kümeleme yönteminden yararlanmışlardır. Majumder vd.'nin çalışmasında (Majumder vd., 2017) kriter-tabanlı tahminler matris faktörizasyonu yaklaşımı ile üretilmiştir. Kant vd. (2018) kriter bazındaki tahminleri üretirken bulanık Bayesian yaklaşımından yararlanmışlardır. Ashraf ve Hussain (2018) bulanık dilbilimsel model yaklaşımını kullanarak kriter-tabanlı

tahminler üretmişlerdir. Kriter-tabanlı tahminlerin doğruluğunu iyileştirmeyi amaçlayan bu çalışmalar lineer olmayan yöntemlere dayanmaktadır. Lineer olmayan yöntemlerle elde edilen özellikler lineer olan yöntemlerle elde edilenlere göre daha kompleks ve beklenmediktir (Batmaz vd., 2019). Araştırmacılar çeşitli lineer ve lineer olmayan birleştirme fonksiyonları önermişlerdir. Gri ilişkisel analiz (Hu vd., 2018), destek vektör regresyon yöntemi (Jannach vd., 2012b), uyarlamalı nöro-bulanık çıkarım yöntemi (Nilashi vd., 2015a; Nilashi vd., 2015b), yapay sinir ağları (Hamada ve Hassan, 2018), genetik algoritma (Kaur ve Ratnoo, 2019) gibi çeşitli lineer ve lineer olmayan yaklaşımlar kullanılarak kriter bazındaki oylar ve genel kriter bazındaki oylar arasındaki ilişki çıkarılmıştır. Ancak bu çalışmalarda her ne kadar kriterler bazındaki oylar ve genel kriter oyları arasındaki ilişkiler lineer olmayan yöntemlerle çıkarılmış olsa da daha gizli ve kompleks ilişkileri çıkaracak yöntemler kullanılmamıştır. Tallapally vd. derin öğrenme tekniklerini ÇKOF sistemlerinde kullanmışlardır (Tallapally vd., 2018). Tallapally vd.'nin (2018) çalışmasında otokodlayıcı yığınları kullanılarak sadece kriter-bazındaki oylarla genel kriter oyları arasındaki ilişki lineer olmayan yöntemlerle çıkarılmış ve genel kriter tahminlerinin doğruluğuna etkisi analiz edilmiştir. Doktora tezi kapsamında yapılan çalışmalar hem kriter bazındaki tahminleri hem de birleştirme fonksiyonunu lineer olmayan yöntemlerle üretir.

ÇKOF tekniklerinin sağladığı doğruluk avantajına karşın, yararlanılan verinin boyutunun artan kriter sayısından dolayı artması ölçeklenebilirlik ve veri seyrekliği problemlerinin daha belirgin hale gelmesine neden olmaktadır (Adomavicius vd., 2011). Veri seyrekliği problemi ÇKOF tekniklerinde üretilen tahminlerin doğruluğunu olumsuz yönde etkilemekte ve hatta tahminler üretememeye sebep olmaktadır (Adomavicius vd., 2011). Araştırmacılar ÇKOF tekniklerine dayalı öneri sistemlerinde bu problemlerle başa çıkabilmek için çeşitli yöntemler geliştirmişlerdir. OF tekniklerinde veri seyrekliği ile başa çıkabilmede ürünlerin içerik bilgisinden yararlanmak sıklıkla kullanılır (Batmaz vd., 2019). ÇKOF tekniklerinde de araştırmacılar taksonomi veya ontolojilerden çıkarılan ürünlerin anlamsal özelliklerini kullanarak hibrit çoklu-kriterli öneri sistemleri geliştirmişlerdir (Shambour ve Lu, 2011; Shambour vd., 2016). Shambour vd. (2016) veri seyrekliği problemi ile başa çıkabilmek için çok boyutlu kullanıcı-ürün matrisi kullanılarak üretilen tahminler ile ürünlerin ikili anlamsal profilleri üzerinden üretilen tahminlerin harmonik ortalamasını alarak tahminler üretmişlerdir. Kermany ve Alizadeh tarafından yapılan çalışmada (Kermany ve Alizadeh, 2017) ÇKOF sistemlerinde veri

seyrekliđi problemini çözebilmek için kullanıcıların içerik verileri ve ontolojik anlamsal filtreleme kullanılmıştır. Seyrek oy profilleri üzerinde korelasyon hesaplamak yerine tercih-tabanlı benzerlik kullanılarak veri seyrekliđi problemi çözülmeye çalışılmıştır (Fan ve Xu, 2013). Aynı zamanda artan kriter sayısına bađlı olarak kullanıcılara makul zamanda tahmin üretme işlemi de zorlaşmaktadır. Boyut indirgeme yaklaşımları, yüksek boyutlu ve seyrek veriyi daha düşük boyutlu ve daha yoğun bir hale dönüştürdüğünden ÇKOF sistemlerinde hem veri seyrekliđi ile hem de ölçeklenebilirlik problemi ile başa çıkmada kullanılan yöntemlerdendir. Kumar Bokde vd. (2015) veri seyrekliđi ve ölçeklenebilirlik problemleriyle başa çıkabilmek için Temel Bileşen Analizi (TBA) ve Yüksek Mertebe Tekil Deđer Ayırıştırma (YMTDA) yaklaşımlarını kullanarak çok boyutlu kullanıcı profillerini daha düşük boyutlu hale dönüştürmüşlerdir. Çalışmalarda ölçeklenebilirlik problemi TBA ile boyut indirgeme işlemi yapılarak çözülmeye çalışılmıştır (Nilashi vd., 2016; Nilashi vd., 2017). Nilashi vd. (Nilashi vd., 2015b) veri seyrekliđi problemini çözmek amacıyla nöro-bulanık sistemi kullanarak daha hassas özellikler elde etmişlerdir. YMTDA yaklaşımı ile de ölçeklenebilirlik sorununu çözmeyi hedeflemişlerdir. Veri seyrekliđi ve ölçeklenebilirlik problemine odaklanan mevcut çalışma sayısı sınırlı olmakla birlikte var olan çalışmalardaki boyut indirgeme ve özellik çıkarımında kullanılan yöntemler de lineer yaklaşımlara dayanmaktadır. Bu sebeple ÇKOF sistemlerindeki belirtilen mevcut problemleri çözebilmek için lineer olmayan yöntemlere dayanan yeni yaklaşımlara ihtiyaç duyulmaktadır.

1.4. Tezin Amacı

ÇKOF teknikleri kullanıcıların ürünleri/hizmetleri çeşitli kriterler altında değerlendirmesine olanak sağlar. Ancak artan kriter sayısı ile birlikte kullanılan verinin miktarının artması kullanıcılara makul zamanda tahminler sunmayı zorlaştırarak ölçeklenebilirlik problemine yol açmaktadır. Yine aynı şekilde bu sistemlerde yararlanılan verinin fazlalığı veri seyrekliđi problemine de yol açmaktadır. ÇKOF sistemlerinin kullanılabilirliği ve sürdürülebilirliği üretilen tahminlerin doğruluđuyla yakından ilişkilidir. Veri seyrekliđi problemi üretilen tahminlerin doğruluđunu olumsuz yönde etkilemekte ve hatta tahmin üretememeye neden olabilmektedir. ÇKOF sistemlerinde üretilen tahminlerin doğruluđunu iyileştirmeye çalışan mevcut yaklaşımların pek çođu karmaşık ve gizli özellikleri göz ardı eden lineer yaklaşımlara dayanmaktadır. Mevcut lineer olmayan yöntemler ise sadece birleştirme fonksiyonunu öğrenmeyi hedeflemişlerdir. ÇKOF tekniklerine dayalı sistemlerde veri seyrekliđi ve

ölçeklenebilirlik problemini çözmeye çalışan mevcut çalışmaların sayısı oldukça sınırlı olmakla birlikte bu çalışmaların tamamı lineer yöntemlere dayanmaktadır.

Çok katmanlı yapay sinir ağlarına dayanan derin öğrenme teknikleri farklı kaynaklardan elde edilen ve büyük boyutlu olan verilerde gizli, karmaşık ve lineer olmayan özellik çıkarımına olanak sağlamaktadır. Bu tez kapsamında derin öğrenme tekniklerine dayanan lineer olmayan yaklaşımlar önerilerek ÇKOF tekniklerinden yararlanan öneri sistemlerinde doğruluk, veri seyrekliği ve ölçeklenebilirlik problemleriyle başa çıkabilmek hedeflenmektedir. Belirtilen amaç doğrultusunda bu tezin temel problemi “Derin öğrenme teknikleri ile ÇKOF sistemlerinin doğruluğunu iyileştirmek ve veri seyrekliği ile ölçeklenebilirlik problemlerine çözüm üretebilmek için hangi yöntemler geliştirilebilir?” şeklinde ifade edilebilir.

Bu doktora tezi kapsamında çoklu-kriterli öneri sistemlerinin doğruluk, veri seyrekliği ve ölçeklenebilirlik problemleriyle başa çıkabilmek için otokodlayıcılara dayanan üç yeni yaklaşım önerilmiştir. Önerilen ilk yaklaşım birleştirme-fonksiyonu tabanlı olup çoklu-kriterli öneri sistemlerinin doğruluğunu iyileştirebilmek için tahminler üretirken kullanıcılar ve ürünler arasındaki otokodlayıcılar tarafından çıkarılan lineer olmayan ve kompleks özellikler ile genel kriter oylarıyla kriter-tabanlı oylar arasındaki ileri beslemeli sinir ağları tarafından çıkarılan gizli ve karmaşık özelliklerden yararlanır. Önerilen ikinci yaklaşım benzerlik-tabanlı olup çoklu-kriterli öneri sistemlerinde veri seyrekliği ve ölçeklenebilirlik problemleriyle başa çıkmayı hedefler. Bu bağlamda önerilen yaklaşım, tahminler üretirken kriter bazındaki ham, seyrek ve yüksek boyutlu kullanıcı/ürün profilleri yerine bu profillerden otokodlayıcılar yardımıyla çıkardığı karmaşık, gizli, yoğun ve düşük boyutlu özellikleri kullanır. Böylelikle önerilen yöntem hem veri seyrekliği probleminin üretilen tahminler üzerindeki olumsuz etkisini azaltmış olur hem de ölçeklenebilir bir yaklaşım sağlamış olur. Tez kapsamında önerilen son yöntem ise çoklu-kriterli öneri sistemlerinde veri seyrekliği problemiyle daha iyi başa çıkabilmek için kullanıcıların oy verilerinin yanı sıra yapmış oldukları yorumlardan da yararlanır. Önerilen son yaklaşım, tahminler üretmek için kullanıcılar/ürünler arasındaki benzerlikleri hesaplarken oy-tabanlı profillerden çıkarılan kompleks, yoğun ve düşük-boyutlu özelliklere ek olarak otokodlayıcılar tarafından yorum-tabanlı profillerden çıkarılan gizli ve karmaşık özellikleri de kullanır.

1.5. Derin Öğrenme

Derin öğrenme teknikleri çok katmanlı yapay sinir ağlarını kullanarak öğrenmeye dayanır. Derin öğrenme teknikleri ile heterojen, karmaşık ve büyük boyutlu veriden lineer olmayan, kompleks ve gizli özellikler çıkarılabilir. Son zamanlarda büyük veri depolama olanaklarının artmasıyla ve hızlı işlem yapabilen güçlü işlem birimlerinin tasarlanmasıyla birlikte derin öğrenme teknikleri de popüler hale gelmeye başlamış ve doğal dil işleme, örüntü tanıma, imge işleme gibi pek çok alanda sıklıkla kullanılmıştır (LeCun vd., 2015; Batmaz vd., 2019). Derin öğrenme tekniklerinin bilgisayar bilimlerindeki bu başarısı araştırmacıları bu teknikleri tek-kriterli öneri sistemlerinde de kullanmaya yönlendirmiştir. Tek-kriterli öneri sistemlerinde sıklıkla yararlanılan derin öğrenme teknikleri arasında otokodlayıcılar, konvolüsyonel sinir ağları (KSA), kısıtlı Boltzmann makineleri (KBM) ve yinelemeli sinir ağları (YSA) gösterilebilir.

Derin öğrenme teknikleri, ham veriden gizli ve karmaşık özellikleri çıkarabilme ve farklı kaynaklardan bilgileri bir araya getirebilme yetilerinden dolayı geleneksel OF sistemlerinde üretilen tahminlerin doğruluğunu iyileştirmek için sıklıkla kullanılmıştır. Tek-kriterli öneri sistemlerinde, derin öğrenme yaklaşımları, kullanıcıların ve ürünlerin gizli ve kompleks özelliklerini elde etmek, hem kullanıcı hem de ürün tabanlı öneri sistemlerinin birleşik modelini oluşturmak ve içerik, yorum gibi ekstra verilerden özellik çıkarımı yaparak bu bilgileri tek-kriterli öneri sistemlerine entegre etmek için yaygın olarak kullanılırlar. Salakhutdinov vd. (2007) KBM ile Tekil Değer Ayırıştırma yaklaşımını birleştirerek geleneksel OF sistemlerinde doğruluğu iyileştirmişlerdir. Sedhain vd. (2015) doğruluğu iyileştirmek amacıyla otokodlayıcılardan direkt tahmin üretmede yararlanan bir OF tekniği önermişlerdir. Zheng vd. (2016) sinirsel otoregresif ağlar kullanarak doğruluğu iyileştirmeyi hedeflemişlerdir. Truyen vd. (2009) Boltzman makinelerini kullanarak kullanıcı profillerinden çıkarılan gizli ve karmaşık özellikleri kullanıcılar-arası ve ürünler-arası korelasyon verilerine entegre ederek üretilen tahminlerin doğruluğunu iyileştirmeye çalışmışlardır. Derin öğrenme teknikleri, kullanıcı zevklerinin zaman içindeki gelişimini izlemekte ve bu da önerilerin doğruluğunu yükseltmeye yardımcı olmaktadır. Dai vd. (2016) kullanıcı davranışı tahmininde doğruluğu artırmak amacıyla kullanıcı-madde etkileşimlerinin eş-evrimsel doğasını modellemek için YNS'leri kullanmışlardır.

Tek-kriterli öneri sistemlerinde veri seyrekliği problemi ile başa çıkabilmek için araştırmacılar yüksek boyutlu ve seyrek kullanıcı-ürün tercih matrisi üzerinde derin


öğrenme teknikleri ile boyut indirgeme işlemi yaparak daha yoğun ve düşük boyutlu bir küme elde etmeye çalışmışlardır (Georgiev ve Nakov, 2013; Strub ve Mary, 2015; Du vd., 2017; Yang vd., 2017). Derin öğrenme tekniklerinden tek-kriterli öneri sistemlerinde içerik verisi gibi verilerden özellik çıkarımı yapmada ve bu bilgileri kullanıcı-ürün tercihlerine entegre etmede yararlanılmıştır. Wang vd. (2015) Bayesian arıtan otokodlayıcı yığınlar (AOY) yardımıyla ürün içeriklerinden elde edilen özellikleri ve kullanıcı-ürün tercih matrisini birleştiren bir hibrit yaklaşım önermişlerdir. Li vd. (2015) arıtan otokodlayıcılar (AO) ile çıkarılan özellikleri ve matris faktörizasyonu-tabanlı geleneksel OF yaklaşımını birleştirerek veri seyrekliği problemini çözmeye çalışmışlardır. Oord vd. (2013) tahmin üretirken KSA ile ses sinyallerinden elde edilen karmaşık ve gizli özellikleri kullanmışlardır. Wang ve Wang (2014) derin inanç ağları ile çıkarılan özellikler üzerinde olasılıksal matris faktörizasyonu yaklaşımını uygulayan hibrit bir yaklaşım önermişlerdir. Wei vd. (2017) içerik verisinden AOY'ler ile çıkarılan özellikleri timeSVD++ yaklaşımı ile entegre ederek veri seyrekliği problemini çözmeye çalışmışlardır. Shen vd. (2016) veri seyrekliği ile başa çıkabilmek için KSA ile elde edilen özellikler ile matris faktörizasyonu tekniğini entegre eden bir yaklaşım önermişlerdir. İçerik verisi bazı çalışmalarda doğrudan derin öğrenme teknikleri-tabanlı tahmin üreten yaklaşımlara entegre edilmiştir (Gunawardana ve Meek, 2008; Strub vd., 2016; Zhang vd., 2016; Bellini vd., 2017; Kim vd., 2017; Li ve She, 2017).

Tek-kriterli öneri sistemlerinde ölçeklenebilirlik problemi ile başa çıkabilmek için derin öğrenme teknikleri ile yüksek boyutlu kullanıcı/ürün profilleri daha düşük boyutlu bir uzaya eşlenmiştir (Truyen vd., 2009; Georgiev ve Nakov, 2013).

Derin öğrenme tekniklerinin farklı kaynaklardan bir araya getirilen büyük veriden daha düşük boyutlu ve kompleks özellikler elde edebilme yetenekleri geleneksel OF sistemlerinde doğruluk, veri seyrekliği ve ölçeklenebilirlik problemleri ile başa çıkmada sıklıkla kullanılmıştır. Her ne kadar derin öğrenme teknikleri-tabanlı yaklaşımlar OF tekniklerine dayalı sistemlerde öncü sonuçlar sağlasa da ÇKOF tekniklerinde henüz yeterince kullanılmamıştır. Derin öğrenme tekniklerini ÇKOF sistemlerine uyarlayan Tallapally vd.'nin çalışması sadece ÇKOF sistemlerinde önerilen tahminlerin doğruluğunu iyileştirmeyi hedeflemiştir (Tallapally vd., 2018). Dolayısı ile derin öğrenme tekniklerinin yetenekleri göz önünde bulundurulduğunda hala ÇKOF sistemlerinde doğruluk, veri seyrekliği ve ölçeklenebilirlik problemleri ile başa çıkabilecek yaklaşımlara ihtiyaç olduğu açıktır.

1.5.1. Otokodlayıcılar

Bir otokodlayıcı girdi katmanında aldığı girdi verisini çıktı katmanında tekrar elde etmek için eğitilmiş bir yapay sinir ağıdır (Ian ve Yoshua, 2016a). Şekil 1.2’de görüldüğü gibi, tipik bir otokodlayıcı, girdi katmanı, gizli katman ve çıktı katmanından oluşur. Bir otokodlayıcı, kodlayıcı ve kodçözücü adı verilen iki kısımdan oluşmaktadır. Girdi katmanından elde edilen girdi, kodlayıcı tarafından gizli katmanda Eşitlik 1.5 kullanılarak kodlanır. Gizli katmanın çıktısı, girdi katmanında alınan verinin daha gizli, kompleks ve boyutu indirgenmiş hali olduğundan özellik çıkarımı ve boyut indirgeme işlemleri için kullanılabilir. Eşitlik 1.6 kullanılarak gizli katmanın çıktısı kodçözücü ile çözülüp girdi verisi tekrar elde edilmeye çalışılır. Verilen bir x vektörü için, otokodlayıcı öğrenme işlemini Eşitlik 1.7’de verilen denklemi minimize ederek gerçekleştirir.



Şekil 1.2. Tipik bir otokodlayıcı

$$f(x) = \varphi (W_1x + b_1) \quad (1.5)$$

Burada x , φ , W_1 ve b_1 sırasıyla otokodlayıcının girdisini, lineer olmayan bir fonksiyonu, girdi katmanı ile gizli katman arasındaki ağırlık matrisini ve gizli katmanın bias vektörünü temsil eder.

$$g(f(x)) = \delta (W_2f(x) + b_2) \quad (1.6)$$

Burada δ lineer olmayan bir fonksiyonu temsil ederken W_2 ve b_2 sırasıyla gizli katman ile çıktı katmanı arasındaki ağırlık matrisini ve çıktı katmanındaki bias vektörünü göstermektedir.

$$\sum_{x \in X} \|x - g(f(x))\|_2^2 \quad (1.7)$$

1.6. Tezin Katkıları

Bu doktora tezi kapsamında çoklu-kriterli öneri sistemlerinin doğruluk, veri seyrekliği ve ölçeklenebilirlik problemleriyle başa çıkabilmek için derin öğrenme tabanlı lineer olmayan yaklaşımlar önerilmiştir. Tez kapsamında yapılan çalışmaların literatüre katkıları aşağıdaki gibi listelenebilir:

- Çoklu-kriterli öneri sistemlerinde üretilen tahminlerin doğruluğunu iyileştirmek için hem kullanıcılar ile ürünler arasındaki kriter bazındaki lineer olmayan, kompleks ilişkileri otokodlayıcılar ile çıkaran hem de kriter-tabanlı oylar ile genel kriter oyları arasındaki lineer olmayan ilişkileri ileri beslemeli sinir ağlarıyla çıkaran birleştirme fonksiyonu-tabanlı yeni bir ÇKOF tekniği önerilmiştir. Yapılan deneysel çalışmalarda elde edilen sonuçlar, hem ürünler ve kullanıcılar arasındaki kriter bazındaki ilişkilerin hem de kriter oyları ile genel kriter oyları arasındaki ilişkilerin lineer olmayan yöntemlerle çıkarılmasının çoklu-kriterli öneri sistemlerinin doğruluğunu iyileştirdiğini göstermiştir.
- Çoklu-kriterli öneri sistemlerinde veri seyrekliği ve ölçeklenebilirlik problemleriyle başa çıkabilmek için yeni bir otokodlayıcılara dayanan benzerlik-tabanlı ÇKOF tekniği önerilmiştir. Önerilen yaklaşımda kullanıcılar/ürünler arasındaki korelasyon değerleri, ham, seyrek ve yüksek boyutlu profiller yerine otokodlayıcılar ile çıkarılan kompleks, gizli, yoğun ve düşük boyutlu özellikler üzerinden hesaplanmıştır. Benzerlik hesaplamada yararlanılan bu özelliklerin boyutu ham kullanıcı/ürün profillerinin boyutlarına göre çok daha düşük olduğundan daha ölçeklenebilir bir yaklaşım elde edilmiştir. Aynı zamanda yapılan deneysel çalışmalar sonucunda elde edilen sonuçlar, önerilen yöntemin çoklu-kriterli öneri sistemlerinde veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini sönmlediğini göstermiştir.
- Çoklu-kriterli öneri sistemlerinde veri seyrekliği problemi ile başa çıkabilmek için oy verilerinin yanı sıra kullanıcıların ürünlere yapmış oldukları yorumlardan da yararlanan otokodlayıcılara dayalı yeni bir benzerlik-tabanlı yaklaşım önerilmiştir. Kullanıcılar/Ürünler arasındaki benzerlikler, hem kullanıcıların/ürünlerin ham oy verileri üzerinden otokodlayıcılar ile çıkarılan kompleks, lineer olmayan, yoğun ve düşük

boyutlu özelliklerden hem de kullanıcıların yapmış oldukları yorumlar üzerinden otokodlayıcılar ile çıkarılan kompleks özelliklerden yararlanılarak hesaplanmıştır. Yapılan deneysel çalışmalar sonucunda elde edilen kazanımlar, kullanıcılar/ürünler arasında benzerlik hesaplanırken yapılan yorumlardan çıkarılan özelliklerin de kullanılmasının çoklu-kriterli öneri sistemlerinde veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki negatif etkisini sönümlediğini açığa çıkarmıştır.

1.7. Tez Organizasyonu

Bu tez, organizasyon açısından beş ana bölümden oluşmaktadır. İlk bölümde tezin amacı, literatüre katkıları ve benzer çalışmalarla olan farkları açıklanmıştır. İkinci bölümde tez kapsamında önerilen otokodlayıcılara dayanan birleştirme-fonksiyonu tabanlı ÇKOF yaklaşımına yer verilmiştir. Tez kapsamında önerilen yöntemlerden otokodlayıcılara dayanan ve veri seyrekliği ile ölçeklenebilirlik problemini çözmeye odaklanan benzerlik-tabanlı ÇKOF yaklaşımı üçüncü bölümde anlatılmıştır. Dördüncü bölümde ise bu tez kapsamında önerilen yaklaşımlardan biri olan veri seyrekliği problemini çözmek için oy verilerinin yanı sıra yapılan yorumlardan da yararlanan otokodlayıcılara dayalı benzerlik-tabanlı ÇKOF yaklaşımı tanıtılmıştır. Son olarak tez kapsamında elde edilen kazanımlara ve gerçekleştirilmesi planlanan diğer çalışmalara beşinci bölümde yer verilmiştir.

2. OTOKODLAYICILARA DAYANAN YENİ BİR BİRLEŞTİRME-FONKSİYONU TABANLI ÇKOF YAKLAŞIMI

Bu bölümde, çoklu-kriterli öneri sistemlerinde üretilen tahminlerin doğruluğunu iyileştirmek için hem kullanıcılar ve ürünler arasındaki ilişkiyi hem de kriter bazındaki oylar ile genel kriter oyları arasındaki ilişkiyi lineer olmayan yöntemler ile çıkaran otokodlayıcılara dayalı yeni bir birleştirme fonksiyonu-tabanlı ÇKOF yaklaşımı (AE-MCCF) tanıtılmıştır. AE-MCCF, ham kullanıcı ve ürün profilleri arasındaki doğrusal olmayan, karmaşık ve gizli ilişkileri otomatik olarak keşfederek doğruluk açısından üretilen tahminlerin kalitesini artırır. AE-MCCF yararlandığı otokodlayıcılar ve ileri beslemeli sinir ağları sayesinde keşfettiği daha ayırt edici özelliklerin öneri üretme işlemine dahil olmasını sağlar. Bu nedenle, AE-MCCF, turizm, yemek sektörü, mobil bankacılık, e-öğrenme, vb. gibi çok yönlü değerlendirme gerektiren birçok sektörde hizmet sunan servis sağlayıcılar tarafından kullanılabilir.

Önerilen yaklaşımın doğruluk açısından performansını var olan mevcut öncü ÇKOF algoritmalarıyla kıyaslamak için iki gerçek veri seti üzerinde deneysel çalışmalar yapılmıştır. Yapılan deneysel çalışmalar sonucunda elde edilen kazanımlar, önerilen yaklaşımın mevcut öncü ÇKOF metotlarına göre üretilen tahminlerin doğruluğunu daha fazla iyileştirdiğini göstermiştir.

2.1. Motivasyon ve Önerilen Yaklaşımın Özgünlüğü

ÇKOF tekniklerine dayalı öneri sistemlerinin, kullanıcılarını memnun edecek seviyede doğruluk sağlayan tahminlerde bulunmaları sürdürülebilirliklerinin olumlu yönde etkilenmesini sağlar (Adomavicius vd., 2011; Shani ve Gunawardana, 2011). Bu sistemlerin devam edilebilirliği üretilen tahminlerin doğruluğu ile doğrudan ilişkili olduğundan daha önceki bölümde de belirtildiği üzere çoklu-kriterli öneri sistemlerinde üretilen tahminlerin doğruluğunu iyileştirmeye yönelik pek çok çalışma yapılmıştır. Benzerlik-tabanlı ÇKOF tekniklerine dayalı sistemlerde üretilen tahminlerin doğruluğunu iyileştirmek için kullanıcılar/ürünler arasındaki benzerlikleri hesaplayan yeni yaklaşımlar önerilmiştir (Naak vd., 2009; Hu, 2014a; Hu, 2014b; Hu vd., 2015; Wasid ve Ali, 2018). Ancak bu yöntemlerin hepsi lineer yaklaşımlara dayandığından ham veriden elde edilebilecek ayırt edici, kompleks özellikleri tespit edememektedir.

Giriş bölümünde bahsedildiği gibi birleştirme fonksiyonu-tabanlı yaklaşımlarda üretilen tahminlerin doğruluğunu hem kriter bazındaki üretilen tahminlerin doğruluğu hem de öğrenilen birleştirme fonksiyonu etkilemektedir. Bu nedenle bazı araştırmacılar


kriter bazında üretilen tahminlerin doğruluğunu iyileştirmeye yönelik çalışmalar yapmışlardır (Zhang vd., 2009; Farokhi vd., 2016; Majumder vd., 2017; Ashraf ve Hussain, 2018; Kant vd., 2018). Her ne kadar bu tip çalışmalar tez kapsamında önerilen çalışmaya doğruluğu iyileştirmeye yönelik izlenen yol açısından benzer olsa da bu çalışmalar kriter-tabanlı oyları üretmek için lineer yaklaşımlardan yararlanırken önerilen çalışma lineer olmayan yaklaşımlardan yararlanmaktadır. Birleştirme fonksiyonu-tabanlı çoklu-kriterli öneri sistemlerinde üretilen tahminlerin doğruluğunu iyileştirmek için bazı araştırmacılar birleştirme fonksiyonunu iyileştirmeyi amaçlayan çeşitli lineer ve lineer olmayan yöntemler önermişlerdir (Hwang, 2010; Jannach vd., 2012a; Jannach vd., 2012b; Fan ve Xu, 2013; Agathokleous ve Tsapatsoulis, 2014; Nilashi vd., 2015a; Nilashi vd., 2015b; Hassan ve Hamada, 2017; Hamada ve Hassan, 2018; Tallapally vd., 2018; Kaur ve Ratnoo, 2019). Giriş bölümünde de belirtildiği üzere derin öğrenme tekniklerinden ÇKOF sistemlerinde yararlanan bir diğer çalışma Tallapally vd. (2018) tarafından yapılan çalışmadır. Tallapally vd. otokodlayıcıları kullanarak genel kriter oyları ile kriter-bazındaki oylar arasındaki lineer olmayan, kompleks ilişkiyi çıkarmışlardır. Ancak önerilen yaklaşımda hem otokodlayıcılardan yararlanılarak kriter bazında kullanıcılar ve ürünler arasındaki lineer olmayan, kompleks ilişkiler hem de ileri beslemeli sinir ağları kullanılarak genel kriter oyları ve kriter bazındaki oylar arasındaki lineer olmayan, karmaşık ilişkiler çıkarılmıştır.

Her ne kadar pek çok makine öğrenmesi ve veri madenciliği teknikleri çoklu-kriterli öneri sistemlerinde önerilen tahminlerin doğruluğunu iyileştirmek için kullanılsa da kullanıcılar ve ürünler arasındaki lineer olmayan, gizli ve karmaşık ilişkileri çıkaran yaklaşımlar henüz önerilmemiştir. Derin öğrenme tekniklerinin geleneksel OF sistemlerinde ham veriden gizli ve karmaşık özellikleri lineer olmayan yöntemlerle çıkarmadaki başarısının ÇKOF sistemlerinde yararlanılmasının doğuracağı sonuçlar oldukça merak uyandırıcıdır.


2.2. AE-MCCF

Önerilen yöntem AE-MCCF, otokodlayıcıları ve ileri beslemeli sinir ağlarını kullanan bir birleştirme fonksiyonu-tabanlı ÇKOF algoritmasıdır. AE-MCCF tahmin üretmek için iki ana aşamadan yararlanır. İlk aşamada, her kriter için ayrı bir otokodlayıcı inşa edilerek, otokodlayıcılar tarafından kriter bazlı tahminler üretilir. Kullanıcıların tercihleri arasındaki gizli ve kompleks ilişkiler, otokodlayıcılar tarafından lineer olmayan bir şekilde çıkarılır ve bu ilişkiler kullanılarak kriter bazlı tahminler üretilir. İkinci

aşamada ise, her kullanıcı için genel kriter oyları ile kriter bazlı oylar arasındaki ilişkileri temsil eden birleştirme fonksiyonu öğrenilir. Her bir kullanıcının birleştirme fonksiyonunu öğrenebilmek amacıyla, her bir kullanıcı için yapısal olarak (Agathokleous ve Tsapatsoulis, 2014; Hamada ve Hassan, 2018)'daki ağlara benzer ancak farklı bir optimizasyon algoritması ile eğitilen lineer olmayan bir ileri beslemeli sinir ağından yararlanılmıştır. Ağlar eğitilirken Bayesian normalleştirme geri yayılımı kullanılmıştır. Her ileri beslemeli sinir ağı, girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmanlı bir yapıya sahiptir. Gizli katmandaki nöronlarda lineer olmayan bir aktivasyon fonksiyonu kullanılırken çıktı katmanındaki nöronlarda lineer bir aktivasyon fonksiyonu kullanılmıştır. Kullanıcının vermiş olduğu kriter-tabanlı oylar ağına girdisi iken genel kriter bazındaki oyları ise ağına üretmeye çalıştığı hedef çıktılarıdır. Son olarak, genel kriter bazındaki tahminler, kriter-tabanlı otokodlayıcılar tarafından üretilen tahminler ve birleştirme fonksiyonu kullanılarak üretilir. Şekil 2.1'de gösterilen işlem, her bir kriter bazlı otokodlayıcının eğitim sürecidir. Bu işlemde otokodlayıcı, hatayı minimize ederek kullanıcılar arasındaki gizli ilişkileri öğrenir. Tüm otokodlayıcıların eğitim süreci tamamlandıktan sonra, otokodlayıcılar ilgili eğitim verisi ile beslenir ve kriter bazlı tahminler üretilir. Daha sonra, öğrenilen birleştirme fonksiyonu üretilen kriter bazlı tahminler ile beslenir ve genel kriter bazındaki tahminler üretilir. AE-MCCF'in k kriter için genel gösterilişi Şekil 2.2'deki gibidir.




Şekil 2.1. Her bir kriter bazlı otokodlayıcı için eğitim süreci



Şekil 2.2. AE-MCCF yönteminin genel gösterilişi

Kullanıcıların bir ürünü dört kriter ve bir genel kriter altında değerlendirdikleri bir sistemde, u kullanıcısı tarafından oylanmamış bir ürün için tahmin üretme prosedürü, Şekil 2.3'te sunulmuştur. AE-MCCF algoritmasının sözde kodu ise Şekil 2.4'te verilmiştir.



Şekil 2.3. AE-MCCF ile tahmin üretme prosedürü

Girdi: $D_{k \times n \times m}$

Çıktı: $P_{n \times m}$

▷ k kriterli çok boyutlu kullanıcı-ürün matrisi

▷ genel kriter bazında üretilen tahminler

1: **İlk aşama:**

▷ İlk aşama, her bir kriter bazlı kullanıcı-ürün matrisi için bir otokodlayıcı eğitime ve kriter bazında tahminler üretme işlemlerini kapsar

2: Çok boyutlu D matrisini k adet $n \times m$ boyutlu kriter-tabanlı matrislere ayırıştır

3: Her bir $n \times m$ boyutlu kriter-tabanlı matris Z için

4: Z 'deki kayıp verileri 0 ile doldur

5: Z 'ye işaret fonksiyonunu uygula ve sonuçları Z' matrisine kaydet

▷ Z' , ağ eğitilirken kayıp verilerden ötürü ağır cezalandırılmasını önlemek için kullanılır

6: Z için bir otokodlayıcı A oluştur

▷ A otokodlayıcısı girdi ve çıktı katmanlarında m adet nöron içerir. Ağırlık matrisleri ve bias vektörleri için ilk değerler atanır

7: **Ağ eğitimi:**

8: Z 'deki her bir kullanıcı profilini A 'nın girdisi olarak kullan

9: Kullanıcı profilini Eşitlik 1.5'i kullanarak kodla

10: Kodlanmış veriyi Eşitlik 1.6'yı kullanarak çözümü

11: Hata değerlerini hesapla ve her birini Z' matrisindeki ilgili değer ile çarp

12: Eşitlik 2.1'de verilen kayıp fonksiyonunu ve seçilen optimizasyon fonksiyonunu kullanarak A 'nın ağırlık matrislerini ve bias vektörlerini güncelle

13: A 'yı eğitmeyi bitirdikten sonra, eğitilmiş otokodlayıcı A' 'yı elde et

14: A' 'dan yararlanarak kayıp veriler için kriter-tabanlı tahminler üret

15: **İkinci aşama:**

▷ İkinci aşama, birleştirme fonksiyonunu öğrenme ve P 'yi üretme işlemlerini kapsar

16: Her bir kullanıcıya ait kullanıcı-tabanlı f birleştirme fonksiyonunu öğrenmek için lineer olmayan bir ileri beslemeli sinir ağı eğit

17: f ve kriter bazında üretilen tahminleri kullanarak P 'yi üret

Şekil 2.4. AE-MCCF algoritmasının sözde kodu

n ; U ile temsil edilen kullanıcı kümesindeki kullanıcı sayısı ve m ; I ile gösterilen ürün kümesindeki ürün sayısı olmak üzere, k kriterli bir öneri probleminin boyutu $k \times n \times m$ şeklinde ifade edilebilir. Bu çok-kriterli öneri problemi k adet tek-kriterli öneri problemlerine ayrıştırıldığında k adet $n \times m$ boyutlu kriter-tabanlı kullanıcı-ürün matrisleri elde edilir. Her bir kriter-tabanlı kullanıcı-ürün matrisi için bir otokodlayıcı eğitilir ve ilgili kriter bazındaki kayıp veriler türetilir. Bir kriter-tabanlı kullanıcı-ürün matrisindeki, U kümesine ait her bir u kullanıcısı, $r_u = r_{u1}, r_{u2}, \dots, r_{um}$ şeklinde gösterilen seyrek bir vektör ile ifade edilir. Otokodlayıcı kullanıcı vektörlerini girdisi olarak alır ve Eşitlik 1.5'i kullanarak düşük boyutlu ve doğrusal olmayan forma dönüştürür. Eşitlik 1.6'yı kullanarak kullanıcı vektörlerini çıktı katmanında yeniden oluşturmaya çalışır. Kullanıcı-ürün matrisleri kayıp veriler içerdiğinden oluşturulan otokodlayıcıların bu kayıp verilerden kaynaklanan hatalardan dolayı eğitim aşamasında cezalandırılmamaları gerekir (Sedhain vd., 2015; Strub ve Mary, 2015). Dolayısı ile kayıp verilere karşılık üretilen çıktılardan elde edilen hata değerlerini göz ardı etmek gerekir. Kayıp veri hatalarını sıfırlayabilmek için kullanıcı-ürün matrisine uygulanan işaret fonksiyonundan yararlanır. Böylelikle, otokodlayıcıların sadece kullanıcı-ürün matrisindeki var olan oy değerlerine karşılık ürettiği tahminlerden doğan geri-yayılım verilerinden ötürü

cezalandırılması sağlanmış olur. Ayrıca, aşırı uymayı önlemek için L_2 düzenlileştirmesinden yararlanılmıştır. Tüm bu değişikliklerden sonra kayıp fonksiyonu Eşitlik 2.1'deki gibi ifade edilebilir.

$$\sum_{u_G \in U} \|u_G - g(f(u_G))\|_2^2 + \lambda(\|W_1\|_2^2 + \|W_2\|_2^2) \quad (2.1)$$

Burada λ L_2 düzenlileştirme katsayısını temsil ederken, u_G u kullanıcısının gözlemlenen oylarından oluşan oy vektörünü temsil eder.

2.3. Deneysel Çalışmalar

AE-MCCF algoritmasının doğruluk ve kapsama açısından performansını göstermek amacıyla iki gerçek veri seti üzerinde çeşitli deneysel analizler gerçekleştirilmiştir. Öncelikle, önerilen yöntemin performansının gizli katman sayısı, kullanılan aktivasyon fonksiyonu gibi değişen otokodlayıcı parametrelerinden nasıl etkilendiğini gösteren deneysel çalışmalar yapılmıştır. Daha sonra, kullanıcılar ve ürünler arasındaki ilişkiler ile genel kriter oyları ve kriter bazındaki oylar arasındaki ilişkileri lineer olmayan bir şekilde açığa çıkarmanın üretilen tahminlerin doğruluğu üzerindeki etkisini gösterebilmek için, önerilen metot çeşitli öncü ÇKOF algoritmaları ile kıyaslanmıştır. Kıyaslamada yararlanılan öncü ÇKOF algoritmaları aşağıdaki gibi listelenebilir:

- En kötü durum benzerliğine dayalı geleneksel ÇKOF yaklaşımı (TMCCF-MinSim) (Adomavicius ve Kwon, 2007)
- Ortalama benzerliğe dayalı geleneksel ÇKOF yaklaşımı (TMCCF-AvgSim) (Adomavicius ve Kwon, 2007)
- Lineer regresyona dayanan birleştirme-fonksiyonu tabanlı geleneksel ÇKOF yaklaşımı (TMCCF-LR) (Adomavicius ve Kwon, 2007)
- İleri beslemeli sinir ağlarına dayanan birleştirme-fonksiyonu tabanlı geleneksel ÇKOF yaklaşımı (TMCCF-FNN): TMCCF-LR algoritması birleştirme fonksiyonunu öğrenirken lineer regresyon yöntemini kullandığından, kriter-tabanlı üretilen tahminler açısından AE-MCCF ile kıyaslayabilmek için bu algoritma AE-MCCF algoritmasında kullanılan öğrenme fonksiyonu ile yeniden uyarlanmıştır.
- Tallapally vd.'nin çalışması (Tallapally vd., 2018): Tallapally vd.'nin çalışması her ne kadar sadece genel kriter tabanlı oylar üretse de

otokodlayıcılara dayalı bir çalışma olduğundan AE-MCCF ile kıyaslanmıştır. AE-MCCF ve Tallapally vd.'nin çalışmasının kıyaslanabilir olması için Tallapally vd.'nin çalışması AE-MCCF için yararlanılan veri setleri ve uygulanan deney metodolojisi ile yeniden uyarlanmıştır. AE-MCCF çalışmasında normalize edilmemiş veriler kullanıldığından Tallapally vd.'nin çalışmasında da en dış katmanda Üstel Lineer Birim (ÜLB) aktivasyon fonksiyonu iç katmanlarda ise sigmoid aktivasyonu kullanılmıştır.

2.3.1. Veri setleri ve değerlendirme ölçütleri

Deneysel çalışmalarda Jannach vd. (2012b) tarafından bir araya getirilen Yahoo!Movies (YM) veri seti ve Wang vd. (2011) tarafından toplanan TripAdvisor (TA) veri seti kullanılmıştır. Deneysel çalışmalar için, YM veri setinden hem kullanıcıların hem de filmlerin en az beşer oya sahip olduğu bir alt küme seçilmiştir. Bu alt küme, 4,377 kullanıcının 2,565 filme yapmış oldukları 63,027 çoklu-kriterli değerlendirmeyi içermektedir. YM veri setinde kullanıcılar filmleri değerlendirirken genel bir değerlendirmede bulunmanın yanı sıra senaryo, oyunculuk, yönetmenlik ve görsellik kriterleri açısından da değerlendirmelerde bulunurlar. YM veri setinde oylar 13-seviyeli ve harf bazlıdır (A+'dan F'ye). Bu oy ölçeği deneysel çalışmalar için 1'den 13'e kadar ayrık, sayısal 13-seviyeli oylama ölçeğine dönüştürülmüştür. Deneysel analizler için, TA veri setinden her kullanıcının en az üçer oya sahip olduğu bir alt küme seçilmiştir. Bu alt küme, 1,346 kullanıcının 1,289 otele yapmış oldukları 4,798 çoklu-kriterli değerlendirmeleri içermektedir. TA veri setinde kullanıcılar oteller hakkında 1'den 5'e ayrık ve sayısal 5-seviyeli oylama ölçeğine dayalı değerlendirmeler yaparken genel kriterin yanı sıra değer, odalar, lokasyon, temizlik, giriş, hizmet ve işletme kriterlerini de göz önünde bulundururlar. YM ve TA veri setinden oluşturulan alt kümeler için seyreklik oranları sırasıyla %99.4386 ve %99.7235'tir.

Ayrıca deneysel çalışmalar için, YM veri setindeki her bir kullanıcının oyları %80 ve %20 oranlarında sırasıyla eğitim ve test oyları olarak ikiye ayrılmıştır. TA veri setinde ise her bir kullanıcının en az üç oyu olduğundan tüm veri setindeki oylar %80 ve %20 oranlarında sırasıyla eğitim ve test oyları olarak gruplanmıştır. Her bir veri seti için bu prosedür beş kez tekrarlanarak beş farklı eğitim ve test kümeleri oluşturulmuştur. Ayrıca daha güvenilir sonuçlar elde edebilmek için her bir eğitim ve test seti için yapılan deney

üçer kez tekrarlanmıştır ve tüm sonuçların ortalaması genel bir sonuç olarak kullanılmıştır.

Yapılan deneysel çalışmalar sonucunda önerilen yöntemin doğruluk ve kapsama açısından öncü ÇKOF tekniklerine göre daha iyi olduğu ortalama mutlak hata (OMH), kök ortalama kare hata (KOMH) ölçütleri ve kapsama (coverage) ölçütü ile göstermiştir. Kapsama, mevcut ürünlerin ne kadarına tahmin üretilbildiği ile ilişkilidir (Ge vd., 2010). OMH, KOMH ve kapsama ölçütleri sırasıyla Eşitlik 2.2, 2.3 ve 2.4'te verilmiştir.

$$OMH = \frac{1}{|R_{tahmin}|} \sum_{(i,j) \in R_{tahmin}} |R_{test,ij} - R_{tahmin,ij}| \quad (2.2)$$

$$KOMH = \sqrt{\frac{1}{|R_{tahmin}|} \sum_{(i,j) \in R_{tahmin}} (R_{test,ij} - R_{tahmin,ij})^2} \quad (2.3)$$

$$Kapsama = \frac{|R_{tahmin}|}{|R_{test}|} \quad (2.4)$$

Burada R_{test} ve $|R_{test}|$ sırasıyla test ürünleri kümesini ve bu kümedeki test ürünlerinin sayısını belirtmektedir. R_{tahmin} ve $|R_{tahmin}|$ ise sırasıyla test ürünleri için üretilen tahminleri ve bu tahminlerin sayısını göstermektedir. AE-MCCF için R_{tahmin} kümesi, ağırları eğitim setiyle besleyerek elde edilmiştir.

2.3.2. Deneysel sonuçlar ve tartışma

2.3.2.1. Değişen otokodlayıcı parametrelerinin etkileri

Otokodlayıcıları gerçeklemek için arka planında tensorflow kullanan Keras 2.1.5'ten yararlanılmıştır. Her bir kriter için bir otokodlayıcı oluşturulmuştur. Öğrenme hızı, yığın boyutu ve λ gibi hiper-parametrelerin deneysel olarak belirlenmiş değerleri tüm otokodlayıcılar için tüm deneysel analizlerde sabit tutulmuştur. Ağırlık matrisleri ve bias vektörlerine sırasıyla homojen rastgele (uniformly randomly) ve birler (ones) olarak ilk değer atamaları yapılmıştır. Ağırlık matrislerini ve bias vektörlerini optimize edebilmek için Adam optimizasyon algoritması kullanılmıştır. Adam optimizasyon algoritması için Keras tarafından sağlanan varsayılan değerler (learning rate = 0.001, $\beta_1 = 0.9$, $\beta_2 = 0.999$, epsilon = None, decay = 0.0, amsgrad = False) korunmuştur. λ katsayısı deneysel olarak 0.001 olarak belirlenmiştir. Kayıp fonksiyonu olarak ortalama kare hata kullanılmıştır. Öğrenme aşamasında yığın öğrenmeden yararlanılmış olup yığın boyutu 30 olarak belirlenmiştir. Yararlanılan veri setlerindeki oy aralıkları YM ve TA için sırasıyla [1, 13] ve [1, 5] olduğundan otokodlayıcıların en dış katmanında girdinin

değer aralıklarıyla aynı aralıklarda çıktı üretebilecek olan aktivasyon fonksiyonlarından yararlanılmıştır.

Değişen aktivasyon fonksiyonlarının ve gizli katman sayılarının AE-MCCF algoritmasının performansı üzerindeki etkilerini gösterebilmek için çeşitli deneysel çalışmalar yapılmıştır. Öncelikle, kodlayıcı katman sayısının AE-MCCF algoritmasının doğruluk açısından performansına etkisini göstermek için kodlayıcı katman sayıları 1’den 4’e kadar değiştirilmiştir. Belirtilen her bir katman için belirlenen nöron sayıları sırasıyla girdi katmanındaki nöronların 1/5’i, 1/8’i, 1/10’u ve 1/12’si kadardır. İç katmanlarda sigmoid en dış katmanda ise ÜLB aktivasyon fonksiyonları kullanılmıştır.

Tablo 2.1 ve Tablo 2.2 sırasıyla YM ve TA veri setleri için değişen kodlayıcı katman sayılarının AE-MCCF algoritmasının doğruluk açısından performansına etkisini göstermektedir. Tablolarda da görüldüğü üzere YM veri seti için artan kodlayıcı katman sayısı ile birlikte algoritmanın doğruluk açısından performansı da iyileşmiştir. TA veri seti için ise önerilen yaklaşımın performansı 3 kodlayıcı katman sayısına kadar artmış daha sonra azalmıştır. Otokodlayıcıların derinliği arttıkça daha hassas, gizli ve kompleks özellikler elde edilmiştir böylelikle AE-MCCF yaklaşımı doğruluğu daha yüksek tahminler üretmeye başlamıştır. Artan katman sayıları ile birlikte doğruluktaki artış hızının azaldığı tablolarda açıktır. Bu durum ağın kapasitesi ile alakalıdır. Makine öğrenme algoritmalarının kapasitesi kullanılan veri seti, fonksiyonun karmaşıklığı, eğitilen verinin miktarı için uygunsa genellikle en iyi performanslarını sergilerler (Ian ve Yoshua, 2016b).

Tablo 2.1. YM veri seti için değişen kodlayıcı katman sayılarının AE-MCCF algoritmasının performansına etkileri

Kodlayıcı katman sayısı	OMH	KOMH
1 kodlayıcı katman	2.3502	2.5236
2 kodlayıcı katman	2.2616	2.4491
3 kodlayıcı katman	2.2597	2.4481
4 kodlayıcı katman	2.2553	2.4450

Tablo 2.2. TA veri seti için deęişen kodlayıcı katman sayılarının AE-MCCF algoritmasının performansına etkileri

Kodlayıcı katman sayısı	OMH	KOMH
1 kodlayıcı katman	0.8958	0.9327
2 kodlayıcı katman	0.8947	0.9319
3 kodlayıcı katman	0.8946	0.9318
4 kodlayıcı katman	0.8948	0.9321

Ayrıca, deęişen aktivasyon fonksiyonlarının AE-MCCF algoritmasının doğruluk açısından performansını nasıl etkilediğini göstermek için çeşitli deneysel çalışmalar gerçekleştirilmiş ve sonuçlar YM ve TA veri setleri için sırasıyla Tablo 2.3 ve Tablo 2.4’te sunulmuştur. Otokodlayıcıların girdileri normalize edilmediğinden girdi katmanında elde edilen verinin oy aralığı ile aynı aralıkta çıktılar üretebilecek çeşitli lineer ve lineer olmayan aktivasyon fonksiyonları en dış kodçözücü katmanında kullanılmıştır. En dış katmanda kullanılan aktivasyon fonksiyonları ÜLB, doğrultulmuş lineer birim (DLB), ölçeklendirilmiş üstel lineer birim (ÖÜLB) ve lineer fonksiyondur. İç katmanlarda ise hiperbolik tanjant (tanh), sigmoid ve ÜLB fonksiyonları kullanılmıştır. Sigmoid ve tanh fonksiyonları sırasıyla $[0, 1]$ ve $[-1, 1]$ aralıklarında çıktılar ürettiklerinden en dış katmanda kullanılmamışlardır. Tablolarda da görüldüğü üzere her iki veri setinde de doğruluk açısından en iyi performans değerlerini Sigmoid-ÜLB çifti sağlamıştır. ÜLB fonksiyonu negatif sonuçlar da üretebildiğinden elde edilen aktivasyonların ortalaması sıfıra yakın olur. Böylelikle ÜLB fonksiyonu DLB fonksiyonuna göre daha hızlı yakınsama sağlar ve gürültüye karşı daha fazla dayanıklıdır (Clevert vd., 2015). Ayrıca AE-MCCF algoritmasının performansının deęişen aktivasyon fonksiyonlarına göre her bir veri seti için farklılıklar göstermesi veri setlerinin doluluk oranları gibi özelliklerinin ve eğitim setlerinin boyutlarının farklı olmalarıyla açıklanabilir.

Tablo 2.3. YM veri seti için değişen aktivasyon fonksiyonlarının AE-MCCF algoritmasının performansına etkileri

İç katmanlardaki aktivasyon fonksiyonu	En dış katmandaki aktivasyon fonksiyonu	OMH	KOMH
Sigmoid	ÜLB	2.2553	2.4450
Sigmoid	DLB	2.2565	2.4460
Sigmoid	ÖÜLB	2.2610	2.4494
Sigmoid	Lineer	2.2571	2.4461
Tanh	ÜLB	2.2590	2.4473
ÜLB	ÜLB	2.4982	2.2767

Tablo 2.4. TA veri seti için değişen aktivasyon fonksiyonlarının AE-MCCF algoritmasının performansına etkileri

İç katmanlardaki aktivasyon fonksiyonu	En dış katmandaki aktivasyon fonksiyonu	OMH	KOMH
Sigmoid	ÜLB	0.8946	0.9318
Sigmoid	DLB	0.8949	0.9320
Sigmoid	ÖÜLB	0.8947	0.9319
Sigmoid	Lineer	0.8947	0.9320
Tanh	ÜLB	0.8947	0.9319
ÜLB	ÜLB	0.8955	0.9326

2.3.2.2. AE-MCCF algoritmasının öncü ÇKOF yaklaşımlarıyla karşılaştırılması

AE-MCCF algoritmasının doğruluk ve kapsama açısından üretilen tahminler üzerindeki etkisini gösterebilmek için önerilen algoritma, temel ÇKOF yaklaşımları ile kıyaslanmıştır ve sonuçlar YM ve TA veri setleri için sırasıyla Tablo 2.5 ve Tablo 2.6’da sunulmuştur. AE-MCCF kriter-tabanlı kullanıcı/ürün profillerini gizli ve lineer olmayan bir uzaya eşleyebildiğinden, kullanıcılar ve ürünler arasındaki kompleks ve gizli ilişkilerin çıkarılmasını sağlar. Ayrıca, AE-MCCF genel kriter oyları ile kriter bazlı oylar arasındaki ilişkileri de lineer olmayan yöntemlerle çıkarır. Bu yüzden tablolarda da görüldüğü üzere önerilen yöntem temel ÇKOF algoritmalarına göre doğruluk ve kapsama açısından daha iyi sonuçlar verir. Tallapally vd.’nin çalışması sadece genel kriter oyları ile kriter bazlı oylar arasındaki kompleks ve gizli ilişkileri lineer olmayan yöntemlerle çıkarır, kullanıcılar ve ürünler arasındaki kriter bazındaki gizli ve karmaşık ilişkileri göz ardı eder. Her iki veri seti de göz önünde bulundurulduğunda önerilen yöntemle sistemdeki tüm test ürünlerine tahmin üretilbildiği kapsama sonuçları ile gösterilmiştir.

Tablo 2.5. *YM veri seti için AE-MCCF algoritmasının öncü ÇKOF yaklaşımları ile kıyaslanması*

Algoritma	OMH	KOMH	Kapsama
AE-MCCF	2.2553	2.4450	1.0000
TMCCF-LR	2.6460	2.7660	0.4259
TMCCF-FNN	2.3279	2.4560	0.4259
TMCCF-AvgSim	2.5573	2.7382	0.5003
TMCCF-MinSim	2.5766	2.7373	0.5002
Tallapally vd.'nin çalışması	2.2780	2.4615	1.0000

Tablo 2.6. *TA veri seti için AE-MCCF algoritmasının öncü ÇKOF yaklaşımları ile kıyaslanması*

Algoritma	OMH	KOMH	Kapsama
AE-MCCF	0.8946	0.9318	1.0000
TMCCF-LR	0.9696	0.9718	0.0894
TMCCF-FNN	0.9113	0.9323	0.0894
TMCCF-AvgSim	0.9360	0.9412	0.0894
TMCCF-MinSim	0.9382	0.9435	0.0894
Tallapally vd.'nin çalışması	1.0095	1.0532	1.0000

2.4. Değerlendirmeler

Çoklu-kriterli öneri sistemlerinin devamlılığı ve kullanılabilirliği üretilen tahminlerin doğruluğuyla yakından ilişkilidir. Kullanıcıları memnun edecek doğrulukta tahminler üretmek bu sistemlerin kullanılabilirliğini ve sürekliliğini artıracaktır. Mevcut ÇKOF teknikleri hem kriter bazında kullanıcılar ve ürünler arasındaki gizli ve kompleks ilişkileri çıkarma hem de genel kriter oyları ile kriter bazlı oylar arasındaki karmaşık ve gizli ilişkileri çıkarmada yetersiz kalmaktadırlar. Bu tez kapsamında ÇKOF sistemlerinde üretilen tahminlerin doğruluğunu artırmak için hem otokodlayıcılar yardımıyla kullanıcılar ve ürünler arasındaki ilişkileri hem de ileri beslemeli sinir ağları yardımıyla kriter bazlı oylar ile genel kriter oyları arasındaki ilişkileri lineer olmayan bir şekilde çıkaran yeni bir birleştirme-fonksiyonu tabanlı ÇKOF metodu olan AE-MCCF önerilmiştir. AE-MCCF algoritmasının doğruluk ve kapsama açısından etkinliğini gösterebilmek için iki gerçek veri seti üzerinde çeşitli deneysel analizler yapılmıştır. Yapılan deneysel çalışmalar sonucunda, otokodlayıcıların derinliğinin artmasının kullanıcı profillerinden daha gizli ve kompleks özellikler çıkarılmasını sağladığından üretilen tahminlerin doğruluğunu olumlu yönde etkilediği gözlemlenmiştir. Önerilen

yöntem öncü ÇKOF teknikleriyle kıyaslandığında ise, önerilen yöntemin doğruluk açısından daha iyi sonuçlar verdiği görülmüştür. Ayrıca, kapsama sonuçlarına göre AE-MCCF algoritmasının sistemdeki tüm test ürünlerine tahmin üretebildiği gözlemlenmiştir.



3. OTOKODLAYICILARA DAYANAN YENİ BİR ÖLÇEKLENEBİLİR BENZERLİK-TABANLI ÇKOF YAKLAŞIMI

Bu bölümde, çoklu-kriterli öneri sistemlerinde veri seyrekliği ve ölçeklenebilirlik problemleri ile başa çıkabilmek için otokodlayıcılara dayanan yeni bir benzerlik-tabanlı ÇKOF algoritması (AE-simMCCF) önerilmiştir. AE-simMCCF otokodlayıcıları kullanarak ham, seyrek ve yüksek boyutlu kullanıcı/ürün profillerinden gizli, kompleks, yoğun ve düşük boyutlu özellikler çıkarır. Kullanıcılar/Ürünler arasındaki benzerlikleri çıkarılan bu özellikleri kullanarak hesaplar. Benzerlik hesaplamada seyrek ve yüksek boyutlu profiller yerine yoğun, kompleks ve düşük boyutlu özelliklerden yararlanıldığından hem veri seyrekliği probleminin üretilen tahminler üzerindeki negatif etkisi sönümlenmiş olur hem de daha ölçeklenebilir bir yaklaşım elde edilmiş olur. AE-simMCCF algoritması artan kriter sayısı ile birlikte daha etkin sorunlar haline gelen veri seyrekliği ve ölçeklenebilirlik problemleriyle başa çıkabildiğinden kullanıcılarına çoklu-kriter bazında değerlendirme yapmalarına olanak sağlayan turizm firmaları, restoranlar, e-ticaret firmaları gibi çeşitli pek çok ürün ve hizmet sağlayıcıları tarafından tercih edilebilir.

Önerilen yaklaşımın veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini mevcut öncü ÇKOF algoritmalarına göre daha fazla sönümleyebildiğini gösterebilmek için iki gerçek veri seti üzerinde deneysel çalışmalar yapılmıştır. Ayrıca önerilen yaklaşımın mevcut benzerlik-tabanlı ÇKOF yaklaşımlarına göre daha ölçeklenebilir olduğunu göstermek için zaman-karmaşıklık açısından analizler yapılmıştır. Yapılan deneysel ve teorik analizler sonucunda elde edilen çıktılar, önerilen yaklaşımın mevcut öncü ÇKOF metotlarına göre üretilen tahminlerin doğruluğu açısından veri seyrekliği problemi ile daha iyi başa çıkabildiğini ve mevcut öncü korelasyon hesaplamasına dayanan ÇKOF algoritmalarına göre daha ölçeklenebilir olduğunu göstermiştir.

3.1. Motivasyon ve Önerilen Yaklaşımın Özgünlüğü

ÇKOF tekniklerine dayalı öneri sistemleri tahminlerini çok boyutlu kullanıcı-ürün matrislerini kullanarak üretirler. Gerçek hayatta, tek-kriterli geleneksel öneri sistemlerinde dahi kullanıcılar sistemdeki ürünlerin çok azı hakkında değerlendirmelerde bulunurlar. Bu oran artan kriter sayısı ile birlikte ÇKOF'ye dayalı sistemlerde daha da azalmaktadır. Ayrıca artan kriter sayısı ile birlikte kullanıcılara makul zamanda tahminler

üretim işlemi de zorlaşmaktadır. Tüm bu durumlar veri seyrekliği ve ölçeklenebilirlik problemlerini çoklu-kriterli öneri sistemlerinin çözülmesi gereken temel sorunları haline getirmektedir.

Mevcut ÇKOF yaklaşımlarının pek çoğu üretilen genel kriter bazındaki tahminlerin doğruluğunu iyileştirmeye yöneliktir. Çoklu-kriterli öneri sistemlerinde veri seyrekliği problemi ile başa çıkabilmek için yapılan sınırlı sayıda çalışma mevcuttur. Giriş bölümünde de belirtildiği üzere araştırmacılar ÇKOF tekniklerine dayalı sistemlerde veri seyrekliği sorunu ile başa çıkabilmek için içerik verisi ve anlamsal veriden yararlanmışlardır (Shambour ve Lu, 2011; Fan ve Xu, 2013; Shambour vd., 2016; Kermany ve Alizadeh, 2017). Ayrıca, boyut indirgeme yaklaşımlarının yüksek boyutlu ve seyrek veriyi daha düşük boyutlu ve daha yoğun bir hale dönüştürmesi, bu yaklaşımların ÇKOF'ye dayalı öneri sistemlerinde hem veri seyrekliği hem de ölçeklenebilirlik problemiyle başa çıkmada yararlanılan yöntemlerden olmasını sağlamıştır (Kumar Bokde vd., 2015; Nilashi vd., 2015b; Nilashi vd., 2016; Nilashi vd., 2017). ÇKOF'ye dayalı sistemlerde ölçeklenebilirlik ve veri seyrekliği problemine odaklanan sınırlı sayıda çalışma mevcuttur ve bu çalışmalarda yararlanılan boyut indirgeme ve özellik çıkarma yöntemleri lineer yaklaşımlara dayanmaktadır. Dolayısı ile çoklu-kriterli öneri sistemlerinde belirtilen problemleri çözmeye odaklanan lineer olmayan yaklaşımlara olan ihtiyaç açıktır. Derin öğrenme tekniklerinin lineer olmayan bir şekilde boyut indirgeyebilmesi ve ham veriden gizli ve kompleks özellikleri lineer olmayan bir şekilde çıkarabilmesi bu alandaki ihtiyacı giderebilecektir.


Tallapally vd.'nin çalışması (Tallapally vd., 2018) ve AE-MCCF derin öğrenme tekniklerini ÇKOF sistemlerinde kullanan yöntemlerdir. Ancak önerilen yaklaşım odaklanılan ÇKOF problemi ve otokodlayıcıları kullanım amacı açısından bu iki çalışmadan da oldukça farklıdır. Tallapally vd.'nin çalışması ve AE-MCCF, genel kriter bazında üretilen tahminlerin doğruluğunu iyileştirmek amacıyla otokodlayıcılardan sırasıyla genel kriter-tabanlı tahminler üretmek ve alt kriter-tabanlı tahminler elde etmek için yararlanırlar. Ancak AE-simMCCF, çoklu-kriterli öneri sistemlerinde veri seyrekliği ve ölçeklenebilirlik problemini çözebilmek için otokodlayıcılardan yüksek boyutlu, ham ve seyrek kullanıcı/ürün profillerinden düşük boyutlu, gizli, karmaşık ve yoğun özellikler çıkarmak amacıyla yararlanmaktadır. Ayrıca AE-simMCCF, aşırı uymayı önlemek ve daha iyi öğrenme sağlamak için yığın normalizasyonu ve iletim sönümünden faydalanmaktadır. Ayrıca AE-MCCF algoritmasında otokodlayıcıların girdileri

normalize edilmediğinden AE-MCCF yaklaşımının en dış katmanında kullanılan aktivasyon fonksiyonlarının sayısı sınırlıdır. AE-simMCCF yaklaşımında ise otokodlayıcıların girdileri normalize edilerek herhangi bir aralığa eşlenebildiğinden herhangi bir aktivasyon fonksiyonu kullanılabilir.

3.2. AE-simMCCF

AE-simMCCF otokodlayıcılardan yararlanan benzerlik-tabanlı yeni bir ÇKOF algoritmasıdır. AE-simMCCF özellik çıkarma/boyut indirgeme ve tahmin üretme olmak üzere iki ana aşamadan oluşmaktadır. AE-simMCCF çoklu-kriterli öneri sistemlerinde veri seyrekliği ve ölçeklenebilirlik problemlerini çözebilmek amacıyla özellik çıkarma/boyut indirgeme aşamasında otokodlayıcılardan yararlanmaktadır. Bu aşamada AE-simMCCF, otokodlayıcıları kullanarak seyrek ve yüksek boyutlu kullanıcı/ürün profillerini yoğun ve karmaşık özelliklerin oluşturduğu daha düşük boyutlu bir uzaya eşler. Her bir kriter için bir otokodlayıcı oluşturulur ve her otokodlayıcı girdi katmanında elde ettiği veriyi kodlayıcı katmanlarıyla kodlar ve kodçözücü katmanlarıyla çözerek en dış katmanda yeniden oluşturmaya çalışır. Her bir otokodlayıcının eğitim süreci tamamlandığında yeniden kendi eğitim seti ile beslenerek en son kodlayıcı katmanından yoğun, düşük boyutlu, kompleks ve gizli özellikler çıkarılır. İkinci aşamada ise AE-simMCCF, çıkarılan bu kriter bazlı özellikleri kullanarak genel kriter bazında tahminler üretir. Bu amaçla, AE-simMCCF kullanıcılar/ürünler arasındaki kriter bazlı benzerlikleri bu özellikleri kullanarak hesaplar. Kullanıcılar/Ürünler arasındaki birleştirilmiş korelasyon değerleri, kriter bazında hesaplanan benzerlikler üzerinde en kötü durum veya ortalama benzerlik yaklaşımlarından biri kullanılarak hesaplanır. Son olarak genel kriter bazındaki tahminler, birleştirilmiş korelasyon değerleri ve geleneksel hafıza-tabanlı OF algoritması kullanılarak hesaplanır.

AE-simMCCF algoritması kullanıcı- ve ürün-tabanlı olarak tasarlanabilir. Şekil 3.1 kullanıcı-tabanlı AE-simMCCF algoritmasının (U-AE-simMCCF) genel görünümünü temsil etmektedir. Şekil 3.2’de ise U-AE-simMCCF algoritmasının sözde kodu verilmiştir. Ürün-tabanlı AE-simMCCF yaklaşımı (I-AE-simMCCF) için de kullanılan girdi verisi dışında tüm prosedür aynıdır. I-AE-simMCCF algoritmasındaki otokodlayıcılar için yararlanılan girdi verisi U-AE-simMCCF algoritmasındaki otokodlayıcıların girdi matrisinin devriğidir.



Şekil 3.1. U-AE-simMCCF algoritmasının genel görünümü

Girdi: $D_{k \times n \times m}$	$\triangleright k$ kriterli çok boyutlu kullanıcı-ürün matrisi
Çıktı: $P_{n \times m}$	$\triangleright$ genel kriter bazında üretilen tahminler
1: İlk aşama:	$\triangleright$ İlk aşama, her bir kriter bazlı kullanıcı-ürün matrisi için bir otokodlayıcı eğitime ve kriter bazında lineer olmayan, yoğun, karmaşık ve düşük boyutlu özellikler çıkarma işlemlerini kapsar
2:	Çok boyutlu D matrisini k adet $n \times m$ boyutlu kriter-tabanlı matrislere ayırıştır
3:	Her bir $n \times m$ boyutlu kriter-tabanlı matris Z için
4:	Z matrisindeki kayıp verilere 0 değerini ata
5:	Z 'ye işaret fonksiyonunu uygula ve sonuçları Z' matrisine kaydet $\triangleright Z'$, ağın eğitim aşamasında kayıp verilerden dolayı cezalandırılmasını önlemek amacıyla kullanılır
6:	Z 'deki oy değerlerini otokodlayıcılarda yararlanılacak olan aktivasyon fonksiyonunun çıktı aralığına bağlı olarak $[0, 1]$ veya $[-1, 1]$ aralıklarına eşle
7:	Z için bir otokodlayıcı A oluştur $\triangleright A$ otokodlayıcısı girdi ve çıktı katmanlarında m adet nöron içerir. Ağırlık matrisleri ve bias vektörleri için ilk değerler atanır
8:	Ağ eğitimi:
9:	A otokodlayıcısını Z 'deki her bir kullanıcı profili ile besle
10:	Eşitlik 1.5'i kullanarak kullanıcı profilini kodla
11:	Eşitlik 1.6'yı kullanarak kodlanmış veriyi çözümü
12:	Hata değerlerini hesapla ve her birini Z' matrisindeki ilgili değer ile çarp
13:	Eşitlik 2.1'de verilen kayıp fonksiyonunu ve seçilen optimizasyon fonksiyonunu kullanarak A 'nın ağırlık matrislerini ve bias vektörlerini güncelle
14:	A 'yı eğitmeyi tamamladıktan sonra A 'nın eğitilmiş hali olan A' otokodlayıcısını elde et
15:	Özellik çıkarma/Boyut indirgeme:
16:	Z 'deki her bir kullanıcı profilini A' otokodlayıcısının girdisi olarak kullan
17:	Yüksek boyutlu, seyrek ve ham kullanıcı profilini kodlamak amacıyla Eşitlik 1.5'i kullan. Kodlayıcı katmanının çıktısından düşük boyutlu, yoğun ve karmaşık özellikler elde et
18:	Z 'deki bütün kullanıcı profilleriyle A' otokodlayıcısını besleyerek $F_{n \times l}$ özellik matrisini oluştur $\triangleright l$ kodlayıcı katmanındaki nöron sayısını ifade eder. That l 'nin m 'den çok daha küçük olması ölçeklenebilir bir yaklaşım sağlar
19:	İkinci aşama: $\triangleright$ İkinci aşama P 'yi üretme işlemini içerir
20:	Her bir $n \times l$ kriter bazında özellik matrisi F için
21:	$F_{n \times l}$ ve cosine benzerlik ölçütünü kullanarak kullanıcılar arasındaki benzerlik $S_{n \times n}$ 'yi Eşitlik 3.1'deki gibi hesapla
22:	En kötü durum veya ortalama benzerlik yaklaşımlarını ve hesaplanan kriter bazındaki benzerlikleri kullanarak kullanıcılar arasındaki birleştirilmiş benzerlik $S_{o \times n \times n}$ 'yi hesapla
23:	S_o ve geleneksel hafıza-tabanlı OF algoritmasını kullanarak P 'yi oluştur

Şekil 3.2. *U-AE-simMCCF algoritmasının sözde kodu*

n adet kullanıcı içeren U kullanıcı kümesi ve m adet ürün içeren I ürün kümesi için k -boyutlu çok-kriterli öneri sisteminde kullanıcı-ürün matrisinin boyutu $k \times n \times m$ ile ifade edilir. Ham, seyrek ve yüksek boyutlu kullanıcı ürün profillerinden düşük boyutlu, yoğun ve karmaşık özellikleri çıkarabilmek için, bu çok boyutlu öneri problemi k adet tek-kriterli $n \times m$ boyutlu öneri problemlerine ayrıştırılır. Her bir kriter-tabanlı $n \times m$ boyutlu kullanıcı-ürün matrisi seyrek profiller içerir. Her bir kriter-tabanlı matris için bir otokodlayıcı eğitilir ve eğitilen otokodlayıcı sayesinde bu profillerden yoğun, karmaşık ve düşük boyutlu özellikler elde edilir. Bir kriter-tabanlı kullanıcı-ürün matrisinde, her bir u kullanıcısı ve i ürünü, sırasıyla $r_u = r_{u1}, r_{u2}, \dots, r_{um}$ ve $r_i = r_{i1}, r_{i2}, \dots, r_{in}$ şeklinde gösterilen seyrek vektörler ile ifade edilir. Bu matrise çeşitli önileme işlemleri uygulandıktan sonra, matristeki her bir r_u , kullanıcı-tabanlı bir otokodlayıcının girdisi

olur. Kriter-tabanlı bir kullanıcı-ürün matrisine uygulanan önişlemlerden biri matristeki kayıp verileri 0 ile doldurmaktır. Daha sonra bu matrise işaret fonksiyonunun uygulanması ile elde edilen yeni matris otokodlayıcının eğitim aşamasında profillerdeki kayıp verilerden dolayı cezalandırılmasını önlemek amacıyla kullanılır (Strub ve Mary, 2015). Böylelikle, otokodlayıcının sadece var olan oylardan elde edilen kayıp verilerinden dolayı cezalandırıldığı garanti altına alınmış olur. Ayrıca, kriter-tabanlı kullanıcı-ürün matrisindeki oyların seçilen aktivasyon fonksiyonunun ürettiği çıktılarının aralıklarına göre $[0, 1]$ veya $[-1, 1]$ aralıklarında uygun değerlere dönüştürülmeleri de bu matrise uygulanan önişlemler arasındadır. Otokodlayıcıyı r_u ile besledikten sonra, Eşitlik 1.5 kullanılarak bu profil daha yoğun, kompleks ve düşük boyutlu hale indirgenir. Daha sonra, Eşitlik 1.6 kullanılarak kodlayıcı katmanından elde edilen çıktı çözümlenir ve çıktı katmanında r_u tekrar oluşturulur. Aşırı uymayı önlemek için her bir kodlayıcı ve kodçözücü katmana iletim sönümü ve L_2 düzenlileştirmesi eklenmiştir. Ek olarak, hem aşırı uymayı önlemek hem de daha hassas özellikler elde etmek ve daha iyi öğrenme sağlamak için otokodlayıcının en dış katmanı hariç tüm yoğun katmanlarındaki aktivasyon fonksiyonlarının girdileri yığın normalizasyonu katmanları ile normalize edilmiştir (Ioffe ve Szegedy, 2015; Ian ve Yoshua, 2016b). Yığın normalizasyonu ayrıca daha hızlı öğrenme sağlar. AE-simMCCF için kayıp fonksiyonu Eşitlik 2.1'deki gibidir.

Otokodlayıcının eğitimi tamamlandığında, kriter-tabanlı kullanıcı ürün matrisindeki her bir r_u profili ile yeniden beslenir ve en dış kodlayıcı katmanının çıktısı bu profilden çıkarılan düşük boyutlu, yoğun ve karmaşık özellikleri temsil eder. Kodlayıcı katmanındaki nöron sayısı l girdi katmanındaki nöron sayısı m 'den çok daha küçük olduğundan üretilen özelliklerin r_u profiline göre çok daha düşük boyutlu olduğu garanti edilmiş olur. Her bir kriter c için kullanıcılar arasındaki benzerlikler, çıkarılan bu özellikler f_c ve cosine benzerliği kullanılarak Eşitlik 3.1'deki gibi hesaplanır. Kullanıcılar arasındaki birleştirilmiş benzerlik So ise en kötü durum veya ortalama benzerlik yaklaşımlarından biri kullanılarak hesaplanır. u kullanıcıasına i ürünü için tahmin ise So kullanılarak Eşitlik 3.2'deki gibi üretilir.

$$S_c(u, v) = \frac{\sum_{i=1}^l F_c(u, i) F_c(v, i)}{\sqrt{\sum_{i=1}^l F_c(u, i)^2} \sqrt{\sum_{i=1}^l F_c(v, i)^2}} \quad (3.1)$$

$$P(u, i) = \frac{\sum_{v \in N(u)} So(u, v) R(v, i)}{\sum_{v \in N(u)} |So(u, v)|} \quad (3.2)$$

Burada $N(u)$, u kullanıcısının top- n komşusunu temsil ederken $R(v, i)$ ise v kullanıcısının i ürününe vermiş olduğu oyu gösterir.

3.3. Deneysel Çalışmalar

AE-simMCCF algoritmasının doğruluk ve kapsama açısından veri seyrekliği problemiyle başa çıkmadaki etkinliğini göstermek amacıyla iki gerçek veri seti YM ve TA üzerinde deneysel çalışmalar yapılmıştır. İlk olarak aktivasyon fonksiyonları ve kodlayıcı katman sayısının AE-simMCCF algoritmasının performansını nasıl etkilediğine ilişkin deneysel analizler yapılmıştır. İkinci aşamada ise ham, yüksek boyutlu ve seyrek kullanıcı/ürün profilleri yerine karmaşık, düşük boyutlu ve yoğun özellikler kullanmanın veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini sönümleyebildiğini göstermek için AE-simMCCF, doğruluk ve kapsama açısından öncü benzerlik-tabanlı ve birleştirme-fonksiyonu tabanlı ÇKOF yaklaşımlarıyla kıyaslanmıştır. Kıyaslanan temel ÇKOF algoritmaları aşağıdaki gibi listelenebilir:

- Benzerlik-tabanlı yaklaşımlar
 - TMCCF-MinSim
 - TMCCF-AvgSim
- Birleştirme fonksiyonu-tabanlı yaklaşımlar
 - Destek vektör makinelerine dayanan geleneksel ÇKOF yaklaşımı (TMCCF-SVM) (Jannach vd., 2012b)
 - AE-MCCF
 - Tallapally vd.'nin çalışması (Tallapally vd., 2018): 2. Bölümde önerilen çalışmada kullanılan veri normalize edilmemiş halde olduğundan daha güvenilir bir kıyaslama yapabilmek için Tallapally vd.'nin çalışması da normalize edilmemiş veri ile uyumlu çalışabilmesi için uygun aktivasyon fonksiyonları kullanılarak ve yararlanılan deney metodolojisi göz önünde bulundurularak yeniden uyarlanmıştır. Bu bölümde yararlanılan veri normalize edilmiş halde olduğundan Tallapally vd.'nin çalışması sigmoid aktivasyonu kullanılarak yararlanılan deney metodolojisine uygun bir şekilde yeniden uyarlanmıştır.

3.3.1. Veri setleri ve değerlendirme ölçütleri

AE-simMCCF için gerçekleştirilen deneysel çalışmalarda da YM ve TA veri setlerinden oluşturulan alt kümelerden yararlanılmıştır. 2. bölümde detaylıca anlatıldığı üzere YM veri seti için oluşturulan alt kümede her kullanıcı ve ürün en az beşer oya sahipken TA veri seti için seçilen alt kümede sadece kullanıcılar en az üçer oya sahiptir.

Deneysel çalışmalarda kullanmak üzere kullanıcı-tabanlı yaklaşımlar için YM ve TA veri setlerinden beş farklı eğitim ve test kümeleri oluşturmak amacıyla 2. bölümde anlatılan prosedür tekrar edilmiştir. TA veri setindeki otellerin çoğu sadece birer oya sahip olduklarından ürün-tabanlı yaklaşımlar için deneyler sadece YM veri seti kullanılarak gerçekleştirilmiştir. Dolayısıyla ürün-tabanlı yaklaşımlar için eğitim ve test kümeleri oluşturmak amacıyla YM veri setindeki her bir filmin oyları %80 ve %20 oranlarında sırasıyla eğitim ve test oyları olarak gruplanmıştır. Bu işlem beş kez tekrarlanarak ürün-tabanlı yaklaşımlar için beş farklı eğitim ve test kümeleri elde edilmiştir. Ayrıca daha güvenilir sonuçlar elde edebilmek amacıyla hem kullanıcı-tabanlı hem de ürün-tabanlı yaklaşımlar için gerçekleştirilen deneysel çalışmalarda her bir eğitim ve test seti için yapılan deney üçer kez tekrarlanmış ve tüm sonuçların ortalaması genel bir sonuç olarak kullanılmıştır.

Ölçeklenebilirlik problemi çoklu-kriterli öneri sistemlerinde makul zamanda tahminler üretmeyi zorlaştırır. AE-simMCCF tahminler üretirken yüksek-boyutlu profiller yerine daha düşük boyutlu özelliklerden yararlandığından ölçeklenebilirlik problemiyle başa çıkabilir. Veri seyrekliği problemi, üretilen tahminlerin doğruluğunu olumsuz yönde etkiler ve hatta bazı durumlarda kapsama oranı ile ölçülen tahmin üretememeye dahi sebep olabilir. AE-simMCCF algoritmasının doğruluk ve kapsama açısından performansını ölçebilmek için OMH, KOMH ve kapsama ölçütlerinden yararlanılmıştır.

3.3.2. Deneysel sonuçlar ve tartışma

3.3.2.1. Ağ parametrelerinin etkileri

Her bir kriter için bir otokodlayıcı tasarlayabilmek amacıyla arka planında Tensorflow'dan yararlanan Keras 2.1.5 kullanılmıştır. Yığın boyutu, λ , öğrenme hızı, iletim sönümü katsayısı gibi bazı hiperparametreler her bir veri seti için deneysel olarak belirlenmiş olup tüm deneyler boyunca değerleri sabit tutulmuştur. Her iki veri seti için

de λ katsayısına deneysel olarak 0.001 değeri atanmıştır. Ağırlık matrisleri ve bias vektörlerine ilk değer atamaları yapabilmek için her iki veri setinde de He normal dağılımından yararlanılmıştır ve optimizasyon için Adam optimizasyonu algoritması kullanılmıştır. Adam optimizasyonu için öğrenme hızı ve decay değerleri hariç Keras tarafından sağlanan varsayılan değerler korunmuştur. Öğrenme hızı, yığın boyutu ve decay değerleri her iki veri seti için de deneysel olarak sırasıyla 0.0001, 30 ve 0.0001 olarak belirlenmiştir. İletim sönümü düzenleştirmesi için katsayı YM ve TA veri setleri için sırasıyla 0.2 ve 0.1 olarak belirlenmiştir.

Aktivasyon fonksiyonu ve kodlayıcı katman sayısı gibi değişen ağ parametrelerinin AE-simMCCF algoritmasının doğruluk ve kapsama açısından performansını nasıl etkilediğini gösterebilmek amacıyla çeşitli deneysel çalışmalar yapılmıştır. Bu doğrultuda kodlayıcı katman sayıları 1, 2 ve 4 olarak çeşitlendirilerek AE-simMCCF algoritmasının performansı üzerindeki etkisi analiz edilmiştir. Belirtilen her bir katman için belirlenen nöron sayıları sırasıyla girdi katmanındaki nöronların 1/5'i, 1/8'i, ve 1/12'si kadardır. Değişen aktivasyon fonksiyonlarının AE-simMCCF algoritmasının performansına etkilerini gösterebilmek için çeşitli lineer olmayan aktivasyon fonksiyonları kullanılmıştır. Bu amaçla en çok bilinen aktivasyon fonksiyonlarından sigmoid, tanh ve ÜLB fonksiyonları kullanılmıştır. Otokodlayıcıların girdileri sigmoid ve tanh fonksiyonları için sırasıyla $[0, 1]$ ve $[-1, 1]$ aralıklarında uygun değerlere dönüştürülmüştür. ÜLB fonksiyonu negatif değerler ile başa çıkabildiğinden ve aktivasyon değerlerinin ortalamasının 0'a yaklaşması daha hızlı yakınsama sağladığından (LeCun vd., 2012) ÜLB fonksiyonu için de otokodlayıcıların girdileri $[-1, 1]$ aralığında uygun değerlere eşlenmiştir.

YM veri seti için değişen aktivasyon fonksiyonlarının ve kodlayıcı katman sayılarının U-AE-simMCCF algoritmasının performansı üzerindeki etkisi Tablo 3.1'de gösterilmiştir. Tablodan da görüldüğü üzere doğruluk açısından en iyi performans değerleri ÜLB fonksiyonu hariç diğer aktivasyon fonksiyonları için 2 kodlayıcı katmana sahip otokodlayıcılarla sağlanmıştır. Bu durum şöyle açıklanabilir; yararlanılan parametrelerin karmaşıklığının, ağların girdilerinin yapısı ve miktarı açısından yeterince uygun olması ağların en iyi performanslarını sergilemelerini sağlar (Ian ve Yoshua, 2016b). Kapsama değerlerinin ise artan kodlayıcı katman sayıları ile iyileştiği görülmektedir. Tablo 3.1'de görüldüğü üzere doğruluk ve kapsama açısından en iyi

performans sonuçları tanh aktivasyonu ile elde edilmiştir. Bu durum hem aktivasyon fonksiyonunun yararlanılan veriye uygunluğuyla hem de tanh fonksiyonunun sigmoid fonksiyonuna göre daha hızlı öğrenme ve daha iyi genelleştirme sağlamasıyla açıklanabilir (LeCun vd., 2015). Hem doğruluk hem de kapsama açısından bakıldığında U-AE-simMCCF için en iyi performans değerlerinin tanh aktivasyonundan yararlanan ve 4 otokodlayıcı katmana sahip otokodlayıcılarla elde edildiği gözlemlenmektedir.

Tablo 3.1. *YM veri seti için değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının U-AE-simMCCF algoritmasının performansına doğruluk ve kapsama açısından etkileri*

Kodlayıcı sayısı	katman	Aktivasyon fonksiyonu	Birleştirme yöntemi	OMH	KOMH	Kapsama
1 kodlayıcı katman	Sigmoid		En kötü durum	2.4919	2.6540	0.2822
			Ortalama	2.5021	2.6626	0.2809
	Tanh		En kötü durum	2.1324	2.2730	0.3322
			Ortalama	2.1421	2.2812	0.3238
	ÜLB		En kötü durum	2.2037	2.3311	0.2803
			Ortalama	2.2267	2.3568	0.2871
2 kodlayıcı katman	Sigmoid		En kötü durum	2.3510	2.4912	0.2461
			Ortalama	2.3455	2.4912	0.2580
	Tanh		En kötü durum	2.0897	2.2497	0.4655
			Ortalama	2.0946	2.2291	0.4609
	ÜLB		En kötü durum	2.1695	2.3141	0.4153
			Ortalama	2.1732	2.3214	0.4179
4 kodlayıcı katman	Sigmoid		En kötü durum	2.4029	2.5548	0.2738
			Ortalama	2.4112	2.5683	0.2816
	Tanh		En kötü durum	2.0926	2.2680	0.5188
			Ortalama	2.0696	2.2411	0.5192
	ÜLB		En kötü durum	2.1643	2.3501	0.4821
			Ortalama	2.1624	2.3330	0.4552

TA veri seti için değişen aktivasyon fonksiyonlarının ve kodlayıcı katman sayılarının U-AE-simMCCF algoritmasının performansı üzerindeki etkisi Tablo 3.2’de sunulmuştur. Tablodan da görüldüğü üzere doğruluk açısından en iyi performans değerleri tüm aktivasyon fonksiyonları için 2 kodlayıcı katmana sahip otokodlayıcılarla sağlanmıştır. YM veri setine ilişkin sonuçlarla kıyaslandığında, eğitim setinin büyüklüğü, yapısı ve doluluk oranının ağırlık kapasitesini etkilediği görülmektedir. Kapsama

değerlerinin genellikle artan kodlayıcı katman sayısı ile birlikte arttığı gözlemlenmiştir. Tablo 3.2'deki sonuçlar göz önünde bulundurulduğunda TA veri seti için, U-AEsimMCCF en iyi doğruluk ve kapsama performanslarını tanh aktivasyonunu kullanan 2 otokodlayıcı katmana sahip otokodlayıcılarla sağlamıştır.

Tablo 3.2. TA veri seti için değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının U-AEsimMCCF algoritmasının performansına doğruluk ve kapsama açısından etkileri

Kodlayıcı katman sayısı	Aktivasyon fonksiyonu	Birleştirme yöntemi	OMH	KOMH	Kapsama
1 kodlayıcı katman	Sigmoid	En kötü durum	1.0385	1.0422	0.0639
		Ortalama	1.0870	1.0928	0.0661
	Tanh	En kötü durum	0.8822	0.8860	0.0976
		Ortalama	0.8944	0.8970	0.0983
	ÜLB	En kötü durum	0.9099	0.9148	0.0958
		Ortalama	0.9166	0.9193	0.0953
2 kodlayıcı katman	Sigmoid	En kötü durum	0.9694	0.9760	0.0543
		Ortalama	0.9795	0.9841	0.0581
	Tanh	En kötü durum	0.9461	0.9502	0.1025
		Ortalama	0.8485	0.8525	0.1034
	ÜLB	En kötü durum	0.9262	0.9313	0.1024
		Ortalama	0.8728	0.8773	0.1028
4 kodlayıcı katman	Sigmoid	En kötü durum	0.9641	0.9698	0.0523
		Ortalama	0.9106	0.9155	0.0603
	Tanh	En kötü durum	1.1321	1.2159	0.1026
		Ortalama	0.8602	0.9287	0.1022
	ÜLB	En kötü durum	1.1332	1.1476	0.1000
		Ortalama	0.8982	0.9025	0.0972

Tablo 3.3 YM veri seti için değişen aktivasyon fonksiyonlarının ve kodlayıcı katman sayılarının I-AE-simMCCF algoritmasının performansını doğruluk ve kapsama açısından nasıl etkilediğini göstermektedir. Tablodaki değerler göz önünde bulundurulduğunda I-AE-simMCCF için en iyi doğruluk ve kapsama değerlerinin tanh aktivasyonunu kullanan 4 kodlayıcı katmana sahip otokodlayıcılarla sağlandığı açıktır. Sigmoid aktivasyon fonksiyonu için en iyi doğruluk ve kapsama değerleri sırasıyla 2 kodlayıcı katmana ve 1 kodlayıcı katmana sahip otokodlayıcılarla sağlanmıştır. ÜLB aktivasyon fonksiyonu için ise en iyi doğruluk ve kapsama değerlerine sırasıyla 1 kodlayıcı katman ve 4 kodlayıcı katmana sahip otokodlayıcılarla erişilmiştir. I-AE-

simMCCF ile U-AE-simMCCF kıyaslandığında, I-AE-simMCCF algoritmasının doğruluk ve kapsama açısından U-AE-simMCCF algoritmasına göre daha iyi performans sergilediği görülmektedir. YM veri setinin doluluk oranı göz önünde bulundurulduğunda ürünlerin sayısı kullanıcıların sayısından daha fazla olduğundan ürün profilleri kullanıcı profillerine göre daha yoğundur. Bu durum I-AE-simMCCF algoritmasının U-AE-simMCCF algoritmasına göre daha iyi performans göstermesini açıklayabilir. Diğer yandan, I-AE-simMCCF için tasarlanan otokodlayıcıları eğitmek için kullanılan girdi örneklemelerinin sayısı U-AE-simMCCF için olanlardan daha az olduğundan kodlayıcı katman sayısını çok fazla artırmak algoritmanın performansını olumsuz yönde etkileyebilir. ÜLB aktivasyonunun doğruluk açısından performansının artan kodlayıcı katman sayısı ile birlikte azalması yararlanılan girdi örneklem sayısının yetersiz kalmasından kaynaklanabilir. Elde edilen sonuçların ağırlık kapasitesini etkileyen faktörlerden oldukça etkilendiği açıktır.

Tablo 3.3. YM veri seti için değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının I-AE-simMCCF algoritmasının performansına doğruluk ve kapsama açısından etkileri

Kodlayıcı katman sayısı	Aktivasyon fonksiyonu	Birleştirme yöntemi	OMH	KOMH	Kapsama
1 kodlayıcı katman	Sigmoid	En kötü durum	2.3496	2.6425	0.3818
		Ortalama	2.4023	2.6954	0.3837
	Tanh	En kötü durum	2.0143	2.2940	0.4792
		Ortalama	2.0077	2.2857	0.4790
	ÜLB	En kötü durum	2.0125	2.2785	0.4431
		Ortalama	2.0434	2.3104	0.4435
2 kodlayıcı katman	Sigmoid	En kötü durum	2.2590	2.5148	0.3146
		Ortalama	2.2516	2.5116	0.3319
	Tanh	En kötü durum	1.9999	2.2785	0.5269
		Ortalama	1.9865	2.2592	0.5275
	ÜLB	En kötü durum	2.0574	2.3278	0.4979
		Ortalama	2.0610	2.3324	0.5033
4 kodlayıcı katman	Sigmoid	En kötü durum	2.2708	2.5255	0.3407
		Ortalama	2.2725	2.5349	0.3529
	Tanh	En kötü durum	1.9933	2.2886	0.5554
		Ortalama	1.9832	2.2794	0.5613
	ÜLB	En kötü durum	2.0739	2.3748	0.5394
		Ortalama	2.0395	2.3375	0.5470

3.3.2.2. AE-simMCCF algoritmasının öncü ÇKOF yaklaşımlarıyla karşılaştırılması

AE-simMCCF algoritmasının veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini sönümlemedeki etkinliğini gösterebilmek amacıyla, AE-simMCCF öncü ÇKOF yaklaşımlarıyla doğruluk ve kapsama açısından kıyaslanmıştır. Tablo 3.4 ve Tablo 3.5 sırasıyla YM ve TA veri setleri üzerindeki kıyaslama sonuçlarını göstermektedir.

Doğruluk açısından AE-simMCCF temel ÇKOF yaklaşımlarıyla kıyaslandığında, tablolarda Tablo 3.4 ve Tablo 3.5'te sunulan sonuçlar her iki veri seti için de AE-simMCCF algoritmasının kıyaslanan temel algoritmalara göre veri seyrekliğinin sebep olduğu olumsuz etkilerle daha iyi başa çıkabildiğini göstermektedir. Bu durum AE-simMCCF algoritmasının tahmin üretirken ham ve seyrek kullanıcı/ürün profilleri yerine otokodlayıcılar tarafından çıkarılan kompleks, gizli ve yoğun özellikleri kullanmasından kaynaklanmaktadır. AE-simMCCF algoritması genel kriter tabanlı tahminleri üretirken çıkarılan özellikler üzerinden hesaplanan kullanıcılar/ürünler arasındaki benzerlikleri ve komşu kullanıcı/ürünlerin hedef ürüne ait oylarını kullandığından kapsama değerleri birleştirme-fonksiyonu tabanlı AE-MCCF ve Tallapally vd'nin çalışmasına göre daha düşüktür. AE-MCCF ve Tallapally vd'nin çalışması doğrudan komşuluk hesaplamaları yapmayan ve otokodlayıcıları direkt tahmin üretmede kullanan yöntemlerdir. AE-simMCCF ise otokodlayıcıları kullanarak ham, seyrek ve yüksek boyutlu kullanıcı/ürün profillerinden elde ettiği kompleks, yoğun ve düşük boyutlu özellikleri tahmin üretirken yararlanılacak komşuları bulmada kullandığından bu algoritmalara göre kapsama değerleri daha düşüktür. Ancak Tablo 3.4 ve Tablo 3.5'te görüldüğü üzere önerilen yaklaşımın diğer kıyaslanan tüm komşuluk hesaplaması yapan temel algoritmalara göre kapsama açısından daha iyi performans gösterdiği açıktır.

Tablo 3.4. *YM veri seti için AE-simMCCF algoritmasının öncü ÇKOF teknikleriyle kıyaslanması*

Algoritma	Birleştirme yöntemi	OMH	KOMH	Kapsama
U-AE-simMCCF	En kötü durum	2.0926	2.2680	0.5188
U-AE-simMCCF	Ortalama	2.0696	2.2411	0.5192
U-TMCCF-MinSim	En kötü durum	2.5766	2.7373	0.5002
U-TMCCF-AvgSim	Ortalama	2.5573	2.7382	0.5003
U-Tallapally vd.'nin çalışması	-	2.2505	2.4387	1.0000
U-TMCCF_SVM	-	2.3599	2.4899	0.4259
U-AE-MCCF	-	2.2553	2.4450	1.0000
I-AE-simMCCF	En kötü durum	1.9933	2.2886	0.5554
I-AE-simMCCF	Ortalama	1.9832	2.2794	0.5613
I-TMCCF-MinSim	En kötü durum	2.6061	2.8395	0.2865
I-TMCCF-AvgSim	Ortalama	2.6088	2.8425	0.2867
I-Tallapally vd.'nin çalışması	-	2.4644	2.7096	1.0000
I-TMCCF_SVM	-	2.5164	2.6974	0.2510
I-AE-MCCF	-	2.4430	2.6602	1.0000

Tablo 3.5. *TA veri seti için AE-simMCCF algoritmasının öncü ÇKOF teknikleriyle kıyaslanması*

Algoritma	Birleştirme yöntemi	OMH	KOMH	Kapsama
U-AE-simMCCF	En kötü durum	0.9461	0.9502	0.1025
U-AE-simMCCF	Ortalama	0.8485	0.8525	0.1034
U-TMCCF-MinSim	En kötü durum	0.9382	0.9435	0.0894
U-TMCCF-AvgSim	Ortalama	0.9360	0.9412	0.0894
I-Tallapally vd.'nin çalışması	-	0.8817	0.9175	1.0000
U-TMCCF_SVM	-	0.9348	0.9401	0.0894
U-AE-MCCF	-	0.8946	0.9318	1.0000

3.4. Tartışma

AE-simMCCF çevrimiçi ve çevrimdışı işlemlerden oluşan benzerlik-tabanlı bir MCCF algoritmasıdır. Çevrimdışı kısmında çevrimiçi işlemlerde kullanmak üzere bir model oluşturulur ve bu model belirli aralıklarla güncellenir. Çevrimiçi kısmında yapılan işlemler ise gerçek-zamanlı öneri sistemlerinde oluşturulan her tahmin isteği için çalıştırılır. Otokodlayıcılar tarafından yüksek boyutlu, seyrek ve ham kullanıcı/ürün profillerinden düşük boyutlu, yoğun ve kompleks özellikler çıkarma işlemi AE-

simMCCF algoritmasının çevrimdışı işlemler kısmını oluştururken çevrimdışı kısmında oluşturulan modeli kullanarak türetilen özellikler yardımıyla kullanıcılar/ürünler arasındaki benzerlikleri hesaplamak ve genel kriter tabanlı tahminler üretmek ise önerilen yaklaşımın çevrimiçi kısımlarını oluşturmaktadır.

Veri seyrekliği ve ölçeklenebilirlik çoklu-kriterli öneri sistemlerinin temel problemlerindendir. İki gerçek veri seti üzerinde yapılan deneysel analizler, tahminler üretirken ham ve seyrek profiller yerine karmaşık ve yoğun özelliklerden yararlanan AE-simMCCF algoritmasının öncü ÇKOF algoritmalarına göre veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki negatif etkisini daha iyi sönümlediğini ortaya çıkarmaktadır. Kullanıcılar/Ürünler arasında benzerlik hesaplamaya dayanan ÇKOF yaklaşımları bu benzerlikleri hesaplarken tüm veri seti üzerinde işlemler gerçekleştirirler. Bu sebeple ölçeklenebilirlik problemiyle karşılaşır. Bir diğer korelasyon hesaplamaya dayalı yaklaşım olan AE-simMCCF algoritması belirtilen diğer korelasyona dayalı ÇKOF algoritmalarına göre ölçeklenebilirlik probleminin olumsuz etkileriyle daha iyi başa çıkabilir. Model tabanlı yaklaşımlarda çevrimdışı kısımda model başlangıçta bir kere oluşturulduğundan ve gerçek-zamanlı sistemlerde her tahmin isteğine karşılık yeniden eğitilmediğinden AE-simMCCF algoritmasının çevrimdışı kısmını gerçeklemek için gereken süre zaman karmaşıklığı analizinde kullanılmamıştır. Korelasyon hesaplamasına dayanan diğer MCCF algoritmaları gerçek-zamanlı öneri sistemlerinde tahmin isteği geldiğinde kullanıcılar/ürünler arasında benzerlik hesaplaması yaparlar. n kullanıcı, m ürünlü ve k kriterli bir çoklu-kriterli öneri sistemi için korelasyon hesaplamasına dayalı kullanıcı-tabanlı MCCF yaklaşımlarının zaman karmaşıklığı $O(n \times n \times m \times k)$ şeklinde ifade edilir. AE-simMCCF kullanıcılar/ürünler arasındaki benzerlikleri yüksek boyutlu profiller yerine düşük boyutlu özellikler kullanarak hesapladığından kullanıcı-tabanlı AE-simMCCF algoritmasının zaman karmaşıklığı $O(n \times n \times l \times k)$ şeklinde ifade edilir. Burada $l \ll m$ olduğundan AE-simMCCF algoritmasının, diğer korelasyon hesaplamasına dayalı ÇKOF yaklaşımlarına göre daha ölçeklenebilir olduğu açıktır. Sayısal olarak ifade etmek gerekirse, korelasyon hesaplamaya dayalı ÇKOF yaklaşımlarıyla 16 GB RAM ve Intel Core i7-4600u CPU (2.10 GHz) özelliklerine sahip bir bilgisayarda kullanıcıların tüm test ürünleri için tahmin üretme işlemi YM ve TA veri setleri için sırasıyla 1918 s ve 119 s sürmektedir. AE-simMCCF algoritmasıyla aynı ürünler için tahmin üretme işlemi YM ve TA veri setleri için sırasıyla 629 s ve 57 s sürmektedir. Hem teorik olarak hem de bir uygulamayla gösterildiği üzere AE-simMCCF

diğer korelasyona-dayalı ÇKOF yaklaşımlarına göre çok daha düşük boyutlu veriler üzerinde işlemler gerçekleştirdiğinden bu yaklaşımlara göre daha ölçeklenebilirdir.

3.5. Değerlendirmeler

Artan kriter sayısı ile birlikte makul zamanda tahminler üretmeyi zorlaştıran ölçeklenebilirlik sorunu ve üretilen tahminlerin doğruluğunu olumsuz yönde etkileyen, hatta tahmin üretememeye sebep olabilen veri seyrekliği problemi çoklu-kriterli öneri sistemlerinde temel iki problem haline gelmektedir. Bu bölümde, veri seyrekliği ve ölçeklenebilirlik problemlerinin olumsuz etkilerini sönümleyebilmek için otokodlayıcılara dayanan benzerlik-tabanlı yeni bir ÇKOF yaklaşımı olan AE-simMCCF önerilmiştir. AE-simMCCF tahminler üretmek için yüksek boyutlu, ham ve seyrek kullanıcı profilleri yerine otokodlayıcılar tarafından çıkarılan düşük boyutlu, karmaşık ve yoğun özelliklerden yararlanır. AE-simMCCF algoritmasının ver seyrekliği problemini çözmedeki etkinliğini gösterebilmek amacıyla iki gerçek veri seti üzerinde yapılan deneysel çalışmalar, önerilen yaklaşımın öncü ÇKOF yaklaşımlarına göre veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki negatif etkisini daha iyi sönümlediğini göstermiştir. Ayrıca AE-simMCCF algoritması yüksek boyutlu kullanıcı/ürün profillerini daha düşük boyutlu formlara dönüştürdüğünden daha ölçeklenebilirdir.

4. OTOKODLAYICILARA DAYANAN YENİ BİR BENZERLİK-TABANLI HİBRİT ÇOKLU-KRİTERLİ ÖNERİ SİSTEMİ YAKLAŞIMI

Bu bölümde, çoklu-kriterli öneri sistemlerinde veri seyrekliği probleminin olumsuz etkileriyle daha iyi başa çıkabilmek için bir önceki bölümde tanıtılan AE-simMCCF algoritmasının geliştirilmiş bir versiyonu olan yeni bir benzerlik-tabanlı hibrit çoklu-kriterli öneri sistemi algoritması (AE-simMCCF++) önerilmiştir. Tek-kriterli öneri sistemlerinde tahminleri üretirken veri seyrekliği problemiyle başa çıkabilmek için kullanıcı-ürün tercih matrisinin yanı sıra içerik verisi veya yorum gibi çeşitli ekstra veriden yararlanmak sıklıkla rastlanılan bir durumdur. AE-simMCCF++ algoritması da otokodlayıcılar yardımıyla hem yüksek boyutlu, ham ve seyrek kullanıcı/ürün profillerinden çıkarılan düşük boyutlu, karmaşık ve yoğun özellikleri hem de ham kullanıcı yorumlarından çıkarılan gizli ve kompleks özellikleri kullanarak kullanıcılar/ürünler arasındaki benzerlikleri hesaplar ve bu benzerlikleri kullanarak tahminler üretir. Oy verisinden elde edilen özelliklerin yanı sıra yorum verisinden çıkarılan özelliklerin de kullanılmasıyla AE-simMCCF++ veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki negatif etkisini daha iyi sönümlemiş olur. AE-simMCCF++ yaklaşımı, veri seyrekliği probleminden zarar gören ve kullanıcılarına hem çoklu-kriter bazında değerlendirmelerde bulunmalarına hem de yorum yapmalarına olanak sağlayan turizm firmaları, restoranlar, e-öğrenme, e-ticaret siteleri gibi çeşitli pek çok ürün ve hizmet sağlayıcıları tarafından tercih edilebilir.

Önerilen yöntemin veri seyrekliği probleminin olumsuz etkilerini sönümlemedeki etkinliğini gösterebilmek için gerçek bir veri seti üzerinde çeşitli deneysel çalışmalar yapılmıştır. Yapılan deneysel analizler sonucunda elde edilen çıktılar oy verisinin yanında yorum verisinden elde edilen özelliklerinde kullanılmasının veri seyrekliği sorununun üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini mevcut öncü MCCF yaklaşımlarına göre daha fazla azalttığını göstermiştir.

4.1. Motivasyon ve Önerilen Yaklaşımın Özgünlüğü

Çoklu-kriterli öneri sistemlerinde artan kriter sayısı ile birlikte veri seyrekliği daha belirgin bir sorun haline gelmiştir. ÇKOF tekniklerine dayalı öneri sistemlerinde doğrudan veri seyrekliği problemini çözmeye odaklanan sınırlı sayıda çalışma mevcuttur. Mevcut çalışmaların çoğunluğu çoklu-kriterli öneri sistemlerinde veri seyrekliği problemini çözebilmek için boyut indirgemeden yararlanarak yüksek boyutlu ve seyrek

veriyi daha düşük boyutlu ve yoğun hale dönüştürmüşlerdir (Kumar Bokde vd., 2015; Nilashi vd., 2015b; Nilashi vd., 2016; Nilashi vd., 2017). Ayrıca, veri seyrekliği sorunu ile başa çıkabilmek amacıyla oy verisinin yanı sıra ürünlerin içerik verisinden çıkarılan taksonomi ve ontolojik özellikleri kullanan hibrit ÇKOF teknikleri de önerilmiştir (Shambour ve Lu, 2011; Shambour vd., 2016; Kermany ve Alizadeh, 2017). Daha önceki bölümlerde de belirtildiği üzere bu çalışmalarda yararlanılan boyut indirgeme ve özellik çıkarma işlemleri lineer yaklaşımlara dayanmaktadır.


Geleneksel OF tekniklerinde oy verisinin yanı sıra içerik veya yorum verisinden de yararlanmak veri seyrekliği problemiyle başa çıkmada sıklıkla yararlanılan yöntemlerden biridir (Batmaz vd., 2019). Özellikle derin öğrenme tekniklerinin metin, imge, sinyal gibi verilerden lineer olmayan yöntemlerle gizli ve karmaşık özellikleri çıkarabilmede ve bu özellikleri sistemlere entegre edebilmedeki başarısı bu tekniklerin tek-kriterli öneri sistemlerinde sıklıkla tercih edilmelerini sağlamıştır (Gunawardana ve Meek, 2008; Van den Oord vd., 2013; Wang ve Wang, 2014; Li vd., 2015; Wang vd., 2015; Shen vd., 2016; Kim vd., 2017; Wei vd., 2017; Zhang vd., 2017; Lee vd., 2018). Her ne kadar derin öğrenme teknikleri tek-kriterli öneri sistemlerinde veri seyrekliği ile başa çıkmada öncü sonuçlar sağlasa da çoklu-kriterli öneri sistemlerinde derin öğrenme tekniklerinin bu özelliklerden pek fazla yararlanılmamıştır. (Tallapally vd., 2018) ile tez kapsamında önerilen iki yöntem olan AE-MCCF ve AE-simMCCF derin öğrenme tekniklerinden çoklu-kriterli öneri sistemlerinde faydalanmışlardır. Daha önceki bölümlerde de belirtildiği üzere Tallapally vd.'nin çalışması ve AE-MCCF önerilen tahminlerin doğruluğunu iyileştirmeye odaklıyken AE-simMCCF ölçeklenebilirlik ve veri seyrekliği problemlerini çözmeye odaklı bir yaklaşımdır. Bu çalışmaların hepsi sadece ham kullanıcı-ürün tercih verisinden elde edilen özellikleri kullanarak tahminler üretirler. AE-simMCCF++ ise veri seyrekliği problemi ile başa çıkabilmek için ham, yüksek boyutlu ve seyrek kullanıcı/ürün profillerinden otokodlayıcılar tarafından çıkarılan kompleks, düşük boyutlu ve yoğun özelliklerin yanı sıra kullanıcıların yorumlarından otokodlayıcılarca çıkarılan karmaşık ve gizli özellikleri de kullanarak tahmin üreten hibrit bir çoklu-kriterli öneri sistemi yöntemidir.

4.2. AE-simMCCF++

AE-simMCCF++ veri seyrekliği problemi ile başa çıkabilmek için otokodlayıcılardan yararlanan benzerlik-tabanlı hibrit bir çoklu-kriterli öneri sistemi

yaklaşımıdır. AE-simMCCF++, kullanıcı/ürün tercih profillerinden ve kullanıcı yorumlarından özellik çıkarma aşaması ve bu çıkarılan özellikleri kullanarak tahmin üretme aşaması olmak üzere iki temel kısımdan oluşmaktadır. İlk aşamada kullanıcı/ürün profillerinden 3. bölümde tanıtılan AE-simMCCF yaklaşımındaki otokodlayıcılarca çıkarılan düşük boyutlu, kompleks ve yoğun özelliklere ek olarak kullanıcıların yapmış oldukları yorumlardan da otokodlayıcılar tarafından gizli ve karmaşık özellikler çıkarılır. Kullanıcı/Ürün profillerinden özellik çıkarımı yapabilmek amacıyla her bir kriter için bir otokodlayıcı oluşturulur. Kullanıcı yorumlarından özellik çıkarımı yapabilmek için ise öncelikle kullanıcıların/ürünlerin yorum-tabanlı profilleri oluşturulur. Yorum-tabanlı kullanıcı/ürün profillerinin oluşturduğu koleksiyon için bir otokodlayıcı oluşturulur. Otokodlayıcıların girdisini oluşturacak olan yapılandırılmamış formdaki yorum-tabanlı kullanıcı/ürün profilleri yapılandırılmış öznitelik vektörlerine dönüştürülür. Otokodlayıcı eğitim aşamasında girdi olarak elde ettiği öznitelik vektörünü kodlayıcı katmanlarıyla kodlar ve kodçözücü katmanlarıyla çözerek çıktı katmanında yeniden oluşturmaya çalışır. Otokodlayıcının eğitimi tamamlandığında eğitim için kullanılan öznitelik vektörleri ile yeniden beslenerek en dıştaki kodlayıcı katmanının çıktısından bu öznitelik vektörlerine ait düşük boyutlu, kompleks ve gizli özellikler çıkarılır. Tahmin üretme aşamasında ise AE-simMCCF++, kullanıcılar/ürünler arasındaki birleştirilmiş benzerlikleri hesaplamak için ortalama benzerlik yaklaşımını hem kriter bazında oy-tabanlı kullanıcı/ürün profillerinden elde edilen özelliklerden hesaplanan kriter bazındaki benzerlikler hem de yorum tabanlı kullanıcı/ürün profillerinden çıkarılan özellikler kullanılarak hesaplanan yorum-tabanlı benzerlikler üzerinde kullanır. Birleştirilmiş benzerlikler ve geleneksel hafıza-tabanlı OF algoritması kullanılarak genel kriter bazında tahminler üretilir.

AE-simMCCF++ kullanıcı-tabanlı veya ürün-tabanlı olarak tasarlanabilir. Tez kapsamında bu yaklaşım sadece kullanıcı-tabanlı olarak tasarlanmıştır. Şekil 4.1 ve Şekil 4.2 sırasıyla AE-simMCCF++ algoritmasının genel görünümünü ve sözde kodunu göstermektedir.



Şekil 4.1. AE-simMCCF++ algoritmasının genel görünümü

Girdi: $D_{k \times n \times X \times m}, Y_{n \times X \times y} \triangleright D_{k \times n \times X \times m}$ k kriterli çok boyutlu kullanıcı-ürün matrisini $Y_{n \times X \times y}$ kullanıcı yorumlarından elde edilen öznitelik vektörlerinin oluşturduğu $n \times X \times y$ boyutlu matrisi temsil eder

Çıktı: $P_{n \times X \times m} \triangleright$ genel kriter bazında üretilen tahminler

- 1: **İlk aşama:** $\triangleright$ İlk aşama, kriter bazında oy-tabanlı kullanıcı profillerinden ve yorum-tabanlı kullanıcı profillerinden otokodlayıcılar ile özellik çıkarma işlemlerini kapsar
- 2: **Oy-tabanlı profillerden özellik çıkarma:** $\triangleright$ Bu kısımda her bir kriter bazlı kullanıcı-ürün matrisi için bir otokodlayıcı eğitime ve, kriter bazında lineer olmayan, yoğun, karmaşık ve düşük boyutlu özellikler çıkarma işlemleri gerçekleştirilir
- 3: Çok boyutlu D matrisini k adet $n \times X \times m$ boyutlu kriter-tabanlı matrislere ayırıştır
- 4: Her bir $n \times X \times m$ boyutlu kriter-tabanlı matris Z için
- 5: Z matrisindeki kayıp verilere 0 değerini ata
- 6: Z' 'ye işaret fonksiyonunu uygula ve sonuçları Z' matrisine kaydet $\triangleright Z'$, ağız eğitim aşamasında kayıp verilerden dolayı cezalandırılmasını önlemek amacıyla kullanılır
- 7: Z' 'deki oy değerlerini otokodlayıcılarda yararlanılacak olan aktivasyon fonksiyonunun çıktı aralığına bağlı olarak $[0, 1]$ veya $[-1, 1]$ aralıklarına eşle
- 8: Z için bir otokodlayıcı A oluştur $\triangleright A$ otokodlayıcısı girdi ve çıktı katmanlarında m adet nöron içerir. Ağırlık matrisleri ve bias vektörleri için ilk değerler atanır
- 9: **Ağ eğitimi:**
- 10: A otokodlayıcısını Z' 'deki her bir kullanıcı profili ile besle
- 11: Eşitlik 1.5'i kullanarak kullanıcı profilini kodla
- 12: Eşitlik 1.6'yı kullanarak kodlanmış veriyi çözümle
- 13: Hata değerlerini hesapla ve her birini Z' matrisindeki ilgili değer ile çarp
- 14: Eşitlik 2.1'de verilen kayıp fonksiyonunu ve seçilen optimizasyon fonksiyonunu kullanarak A 'nın ağırlık matrislerini ve bias vektörlerini güncelle
- 15: A 'yı eğitmeyi tamamladıktan sonra A 'nın eğitilmiş hali olan A' otokodlayıcısını elde et
- 16: **Özellik çıkarma/Boyut indirgeme:**
- 17: Z' 'deki her bir kullanıcı profilini A' otokodlayıcısının girdisi olarak kullan
- 18: Yüksek boyutlu, seyrek ve ham kullanıcı profilini kodlamak amacıyla Eşitlik 1.5'i kullan. Kodlayıcı katmanının çıktısından düşük boyutlu, yoğun ve karmaşık özellikler elde et
- 19: Z' 'deki bütün kullanıcı profilleriyle A' otokodlayıcısını besleyerek $F_{n \times l}$ özellik matrisini oluştur $\triangleright l$ kodlayıcı katmanındaki nöron sayısını ifade eder. l 'nin m 'den çok daha küçük olması ölçeklenebilir bir yaklaşım sağlar
- 20: **Yorum-tabanlı profillerden özellik çıkarma:** $\triangleright$ Bu kısım, yorum-tabanlı kullanıcı profilleri için bir otokodlayıcı eğitime ve bu profillerden düşük boyutlu, gizli ve kompleks özellikler çıkarma işlemlerini kapsar
- 21: $n \times X \times y$ boyutlu yorum-tabanlı profil matrisi Y' 'deki ağırlık değerlerini otokodlayıcılarda yararlanılacak olan aktivasyon fonksiyonunun çıktı aralığına uygun olarak $[0, 1]$ veya $[-1, 1]$ aralıklarına eşle
- 22: R için bir otokodlayıcı A oluştur $\triangleright A$ otokodlayıcısı girdi ve çıktı katmanlarında y adet nöron içerir. Ağırlık matrisleri ve bias vektörleri için ilk değerler atanır
- 23: **Ağ eğitimi:**
- 24: A otokodlayıcısını R' 'deki her bir yorum-tabanlı kullanıcı profilini temsil eden öznitelik vektörü ile besle
- 25: Eşitlik 1.5'i kullanarak öznitelik vektörünü kodla
- 26: Eşitlik 1.6'yı kullanarak kodlanmış veriyi çözümle
- 27: Hata değerlerini hesapla
- 28: Eşitlik 4.2'de verilen kayıp fonksiyonunu ve seçilen optimizasyon fonksiyonunu kullanarak A 'nın ağırlık matrislerini ve bias vektörlerini güncelle
- 29: A 'yı eğitmeyi tamamladıktan sonra A 'nın eğitilmiş hali olan A' otokodlayıcısını elde et
- 30: **Özellik çıkarma/Boyut indirgeme:**
- 31: R' 'deki her bir öznitelik vektörünü A' otokodlayıcısının girdisi olarak kullan ve Eşitlik 1.5'i kullanarak kodla. Kodlayıcı katmanının çıktısından düşük boyutlu, yoğun ve kompleks özellikler elde et
- 32: R' 'deki bütün kullanıcı profilleriyle A' otokodlayıcısını besleyerek $F_{y \times n \times t}$ özellik matrisini oluştur $\triangleright t$ kodlayıcı katmanındaki nöron sayısını ifade eder. t, y 'den çok daha küçüktür
- 33: **İkinci aşama:** $\triangleright$ İkinci aşama P 'yi üretme işlemini içerir
- 34: Her bir $n \times X \times l$ kriter bazında özellik matrisi F için
- 35: $F_{n \times l}$ ve cosine benzerlik ölçütünü kullanarak kullanıcılar arasındaki oy-tabanlı benzerlik $S_{n \times n}$ 'yi Eşitlik 3.1'deki gibi hesapla
- 36: $n \times X \times t$ yorum-tabanlı özellik matrisi F_y ve cosine benzerlik ölçütünü kullanarak kullanıcılar arasındaki yorum-tabanlı benzerlik $S_{y \times n \times n}$ 'yi Eşitlik 4.3'deki gibi hesapla
- 37: Ortalama benzerlik yaklaşımını ve hesaplanan kriter bazındaki oy-tabanlı benzerlikler ile yorum-tabanlı benzerlikleri kullanarak kullanıcılar arasındaki birleştirilmiş benzerlik $S_{o \times n \times n}$ 'yi hesapla
- 38: S_o ve geleneksel hafıza-tabanlı OF algoritmasını kullanarak P 'yi oluştur

Şekil 4.2. AE-simMCCF++ algoritmasının sözde kodu

AE-simMCCF++ yaklaşımının ilk aşaması kriter bazındaki oy-tabanlı kullanıcı profillerinden özellik çıkarımı ve yorum-tabanlı kullanıcı profillerinden özellik çıkarımı olmak üzere iki temel adımdan oluşur. n adet kullanıcıya sahip U ile ifade edilen kullanıcılar kümesi ve m adet ürüne sahip I ile ifade edilen ürünler kümesi için, k -boyutlu çok-kriterli öneri sisteminde kullanıcı-ürün tercihleri ve kullanıcı-ürün yorumları $k \times n \times m$ ve $n \times m$ boyutlu matrislerle ifade edilir. Kullanıcı-ürün tercih matrisinde her bir hücre bir kullanıcının bir ürüne vermiş olduğu kriter-bazlı oyu temsil ederken kullanıcı-ürün yorum matrisinde her bir hücre bir kullanıcının bir ürüne yapmış olduğu yorumu gösterir. AE-simMCCF++ algoritmasının ilk aşamasının temel adımlarından biri olan ham, seyrek ve yüksek boyutlu kriter bazındaki oy-tabanlı kullanıcı profillerinden kompleks, yoğun ve düşük boyutlu özellikler çıkarma işlemi için 3. bölümde detaylıca anlatılan AE-simMCCF algoritmasının otokodlayıcılar tarafından özellik çıkarmak için yararlanılan adımları uygulanır.

Ham kullanıcı-ürün yorum matrisinden otokodlayıcılardan yararlanarak gizli ve kompleks özellikleri çıkarabilmek için öncelikle yapılandırılmamış formda olan kullanıcı-ürün yorum matrisi yapılandırılmış öznitelik vektörleriyle ifade edilen yorum-tabanlı kullanıcı profillerinin oluşturduğu y öznitelik sayısı olmak üzere $n \times y$ boyutlu bir matrise dönüştürülür. Bu amaçla bir kullanıcının yapmış olduğu tüm yorumlar birleştirilerek o kullanıcıya ait yapılandırılmamış yorum-tabanlı kullanıcı profili oluşturulur ve bu profil doküman ile ifade edilir. Tüm dokümanların oluşturduğu koleksiyona ise doküman koleksiyonu adı verilir. Bu dokümanları yapılandırılmış bir formata dönüştürmek ve anlamlı sayısal verilerle ifade edebilmek için metin madenciliğinin temel adımlarından olan ön işleme, öznitelik çıkarımı ve öznitelik seçimi işlemleri uygulanır (Uysal ve Gunal, 2012). Tüm bu işlemleri uygulamak için Python'ın nltk kütüphanesinden yararlanılmıştır.

- **Ön işleme:** Metin dokümanlarına ön işleme işlemlerini uygulamanın metin sınıflandırma problemlerinde sınıflandırıcının doğruluğu üzerinde olumlu yönde önemli bir etkisi olduğu yapılan çalışmalarca gösterilmiştir (Uysal ve Gunal, 2014). Bu tez kapsamında da yorum-tabanlı kullanıcı profillerinin temsil edildiği tüm dokümanlara küçük harfe dönüştürme, dizgelerine/terimlerine ayırma, terimleri köklerine indirgeme ve durak-kelimeleri ayıklama ön işlemleri uygulanmıştır.

- **Öznitelik çıkarımı:** Doküman koleksiyonundaki her bir farklı terim için her bir dokümandan sayısal bilgiler çıkarılarak terim ağırlıklandırma işlemi yapılır ve dokümanlar terim ağırlıklarıyla ifade edilen öznitelik vektörlerine dönüştürülür. Böylelikle dokümanlar, terimlerin doküman içerisindeki sıralamalarının önemsenmediği sadece terim frekanslarının göz önünde bulundurulduğu kelime çantası (bag of words) tekniğiyle ifade edilmiş olur (Joachims, 1997). Terim ağırlıklandırma yöntemi olarak metin madenciliğinde sıklıkla yararlanılan en temel çalışmalardan biri olan terim frekansı-ters doküman frekansı (TF-TDF) kullanılmıştır (Sparck Jones, 1972). Doküman koleksiyonundaki her bir terimin bir dokümandaki TF-TDF ağırlığı, terimin terim frekans (TF) değeri ile ters doküman frekansı (TDF) değerinin çarpımı şeklinde ifade edilir. t teriminin d_i dokümanı için TF-TDF ağırlığı Eşitlik 4.1'deki gibi hesaplanır.

$$TF - TDF(t) = TF(t, d_i) * \log \frac{D}{d(t)} \quad (4.1)$$

Burada, D , $d(t)$ ve $TF(t, d_i)$ sırasıyla doküman koleksiyonunu, t terimini içeren doküman sayısını ve d_i dokümanında t teriminin kaç kere geçtiğini gösterir.

- **Öznitelik seçimi:** Metin madenciliğinin doğası gereği çoğunlukla doküman koleksiyonundaki öznitelik sayısı fazla olur ve bu durum da hem hesaplamalar için gereken zamanın artmasına hem de doğruluğun azalmasına sebep olur. Bu durumdan kaçınmak için öznitelik seçimi yapılır (Uysal ve Gunal, 2012). Bu tez kapsamında öznitelik seçimi yapabilmek için nltk kütüphanesindeki max_df ve max_features parametrelerinden yararlanılmıştır. Burada max_df [0.1, 1.0] aralığında bir eşik değer alır ve doküman frekansı bu eşik değerden büyük olan terimler göz ardı edilir. max_features parametresine ise pozitif bir tam sayı değeri atanır ve koleksiyon bazındaki TF değerlerine göre sıralanan terimlerden en yüksek TF skorlarına sahip max_features parametresi ile belirlenen sayı kadar terim seçilir.

Tüm bu metin madenciliğinin temel adımları uygulandığında yapılandırılmamış formdaki her bir yorum-tabanlı kullanıcı profili TF-TDF ile ağırlıklandırılmış öznitelik

vektörüne dönüştürülür. n adet kullanıcının y adet özniteliğe dair öznitelik vektörlerinin oluşturduğu matris $Y_{n \times y}$ şeklinde ifade edilebilir. Bu matristeki her biri öznitelik vektörüyle ifade edilen yorum-tabanlı bir kullanıcı/ürün profilinden düşük boyutlu, kompleks ve gizli özellikler çıkarabilmek amacıyla $Y_{n \times y}$ matrisi için girdi ve çıktı katmanında y adet nöron içeren bir otokodlayıcı tasarlanır. Öznitelik vektörü ile temsil edilen her bir yorum-tabanlı kullanıcı profili otokodlayıcının girdisini oluşturur. Kodlayıcı katmanlar tarafından Eşitlik 1.5 kullanılarak kodlanan girdi Eşitlik 1.6 kullanılarak kodçözücü katmanlar tarafından çözülür ve çıktı katmanında yeniden oluşturulmaya çalışılır. Aşırı uymayı önlemek için her bir kodlayıcı ve kodçözücü katmana iletim sönümü ve L_2 düzenlileştirmesi eklenmiştir. Ayrıca daha ayırt edici özellikler elde etmek, daha iyi öğrenme saptamak ve aşırı uymayı önlemek amacıyla otokodlayıcının en dış katmanı hariç tüm yoğun katmanlardaki aktivasyon fonksiyonlarının girdileri yığın normalizasyonu katmanları ile normalize edilmiştir. Otokodlayıcının ağırlık matrisi ve bias vektörleri Eşitlik 4.2’de verilen kayıp fonksiyonu ve seçilen optimizasyon algoritmasına göre güncellenir.

$$\sum_{u_y \in U} \|u_y - g(f(u_y))\|_2^2 + \lambda (\|W_1\|_2^2 + \|W_2\|_2^2) \quad (4.2)$$

Burada u_y , u kullanıcısının öznitelik vektörü ile temsil edilen yorum-tabanlı profilini göstermektedir. Otokodlayıcının eğitimi tamamlandığında, otokodlayıcı Y matrisindeki öznitelik vektörüyle temsil edilen her bir yorum-tabanlı kullanıcı profiliyle beslenir ve en dış kodlayıcı katmanının çıktısı bu profilden çıkarılan düşük boyutlu, kompleks ve gizli özellikleri oluşturur. u ve v kullanıcıları arasındaki yorum-tabanlı cosine benzerliği $S_y(u, v)$, kullanıcılarının yorum-tabanlı kullanıcı profillerinden çıkarılan özellikleri $F_y(u)$ ve $F_y(v)$ kullanılarak Eşitlik 4.3’teki gibi hesaplanır. Bu iki kullanıcı arasındaki birleştirilmiş benzerlik ise, AE-simMCCF tarafından oy-tabanlı kullanıcı profillerinden çıkarılan özellikler üzerinden hesaplanan k adet kriter-tabanlı benzerlikler ve yorum-tabanlı kullanıcı profillerinden çıkarılan özellikler kullanılarak hesaplanan benzerlikler kullanılarak Eşitlik 4.4’deki gibi hesaplanır. u kullanıcısına i ürünü için tahmin ise Eşitlik 3.2’deki gibi hesaplanır.

$$S_y(u, v) = \frac{\sum_{i=1}^t F_y(u, i) F_y(v, i)}{\sqrt{\sum_{i=1}^t F_y(u, i)^2} \sqrt{\sum_{i=1}^t F_y(v, i)^2}} \quad (4.3)$$

$$S_O(u, v) = \frac{\sum_{c=1}^{c=k} (S_c(u, v)) + S_y(u, v)}{k+1} \quad (4.4)$$

4.3. Deneysel Çalışmalar

AE-simMCCF++ algoritmasının doğruluk ve kapsama açısından veri seyrekliği probleminin üretilen oyların doğruluğu üzerindeki olumsuz etkisini gidermedeki etkinliğini gösterebilmek amacıyla gerçek bir veri seti olan TA üzerinde çeşitli deneysel çalışmalar gerçekleştirilmiştir. Bu amaçla öncelikle aktivasyon fonksiyonları ve kodlayıcı katman sayısı gibi değişen otokodlayıcı parametrelerinin AE-simMCCF++ algoritmasının performansını nasıl etkilediğine ilişkin deneysel analizler yapılmıştır. Daha sonra tahminler üretirken oy verilerinin yanı sıra yorum verilerinden elde edilen bilgilerinde kullanılmasının veri seyrekliği problemini çözmedeki etkinliğini gösterebilmek için AE-simMCCF++ algoritması AE-simMCCF ile kıyaslanmıştır. AE-simMCCF algoritmasının diğer öncü ÇKOF tekniklerine göre veri seyrekliği problemiyle başa çıkmada daha etkin olduğu bir önceki bölümde yapılan deneysel analizlerle kanıtlandığından bu bölümde sadece AE-simMCCF algoritması ile kıyaslama yapılmıştır.

4.3.1. Veri setleri ve değerlendirme ölçütleri

AE-simMCCF++ için yapılan deneysel çalışmalarda kullanıcıların ürünlere yapmış oldukları kriter-bazındaki oy değerlendirmelerinin yanı sıra yorum verisini de içerdiği için TA veri seti kullanılmıştır. Daha önceki bölümlerde de belirtildiği gibi TA veri seti için seçilen alt kümedeki otellerin çoğu sadece birer oya sahip olduklarından AE-simMCCF++ sadece kullanıcı-tabanlı olarak tasarlanabilmiştir.

Kullanıcı-tabanlı eğitim ve test setleri oluşturabilmek için TA veri setindeki oylar %80 ve %20 oranlarında eğitim ve test oyları olarak ikiye ayrılmıştır. Kullanıcıların eğitim setinde oy değerlendirmelerinde bulundukları ürünler için yaptıkları yorumlar ise yorum-tabanlı kullanıcı profillerinden özellik çıkarmak için yararlanılacak olan otokodlayıcının eğitiminde kullanılacak eğitim setini oluşturmak amacıyla kullanılır. Kullanıcıların test setinde oy değerlendirmelerinde bulundukları ürünler için yaptıkları yorumlar ise belirtilen otokodlayıcının eğitim aşamasında yararlanılacak olan validasyon setini oluşturmak için kullanılır. Yorum-tabanlı eğitim ve validasyon setindeki her bir kullanıcı dokümanı, doküman koleksiyonundan elde edilen 500 öznitelik için normalleştirilmiş TF-TDF değerleri içermektedir. Bu prosedür beş kez tekrarlanarak beş farklı oy-tabanlı eğitim ve test setleri ile yorum-tabanlı eğitim ve validasyon setleri elde edilmiştir. Elde edilen sonuçların daha güvenilir olmasını sağlamak amacıyla her bir

eğitim ve test seti için yapılan deney üçer kez tekrarlanmıştır ve tüm sonuçların ortalaması genel bir sonuç olarak kullanılmıştır.

Veri seyrekliği problemine bağlı olarak üretilen tahminlerin doğruluğu azalabilir ve hatta tahmin üretememeye bile sebep olabilir. Bu nedenle AE-simMCCF++ algoritmasının veri seyrekliği probleminin belirtilen olumsuz yönleriyle başa çıkabilmedeki doğruluk ve kapsama açısından performansını ölçebilmek amacıyla OMH, KOMH ve kapsama ölçütleri kullanılmıştır.

4.3.2. Deneysel sonuçlar ve tartışma

4.3.2.1. Ağ parametrelerinin etkileri

AE-simMCCF++ algoritması tahminler üretirken hem oy-tabanlı kullanıcı profillerinden hem de yorum-tabanlı kullanıcı profillerinden otokodlayıcılar tarafından çıkarılan özellikleri kullanır. Bu otokodlayıcıları tasarlayabilmek amacıyla arka planında Tensorflow'dan yararlanan Keras 2.1.5 kullanılmıştır. AE-simMCCF++ ham, seyrek ve yüksek boyutlu oy-tabanlı kullanıcı profillerinden kompleks, yoğun ve düşük-boyutlu özellikler çıkarmak için AE-simMCCF algoritmasından yararlanır. Dolayısı ile TA veri seti için AE-simMCCF algoritmasının doğruluk ve kapsama açısından en iyi performansını sağlayan oy-tabanlı özellikler çıkarmada yararlanılan otokodlayıcı parametreleri AE-simMCCF++ için yapılan deneysel çalışmalarda korunmuştur. Yorum-tabanlı kullanıcı profillerinden gizli ve kompleks özellikleri çıkarabilmek amacıyla tasarlanan otokodlayıcı için yığın boyutu, λ , öğrenme hızı, iletim sönümü katsayısı gibi bazı hiperparametreler deneysel olarak belirlenmiş olup tüm deneyler boyunca değerleri korunmuştur. λ , yığın boyutu ve iletim sönümü katsayısı sırasıyla 0.001, 30 ve 0.2 olarak belirlenmiştir. He normal dağılımı kullanılarak otokodlayıcının ağırlık matrisleri ve bias vektörlerine ilk değer atamaları yapılmıştır. Optimizasyon algoritması olarak Adam optimizasyonundan yararlanılmıştır. Öğrenme hızı ve decay parametreleri hariç Adam optimizasyonunun diğer parametreleri için Keras tarafından sağlanan varsayılan değerler korunmuştur. Öğrenme hızı ve decay değerleri sırasıyla 0.0001 ve 0.0001 olarak belirlenmiştir.

Değişen aktivasyon fonksiyonlarının ve kodlayıcı katman sayılarının AE-simMCCF++ algoritmasının performansı üzerindeki etkilerini gösterebilmek amacıyla çeşitli deneysel analizler gerçekleştirilmiştir. Bu amaçla kodlayıcı katman sayıları 2, 3 ve

4 olarak çeşitlendirilmiş ve AE-simMCCF++ algoritmasının performansına etkisi analiz edilmiştir. Belirtilen her bir katman için belirlenen nöron sayıları sırasıyla girdi katmanındaki nöronların 1/8'i, 1/10'u, ve 1/12'si kadardır. İlk kodlayıcı katmanı için kullanılan nöron sayısı ise girdi katmanındaki nöronların 1/5'i kadardır. Değişen aktivasyon fonksiyonlarının AE-simMCCF++ algoritmasının performansını nasıl etkilediğini göstermek için lineer olmayan aktivasyonlar olan ÜLB, DLB ve tanh aktivasyon fonksiyonlarından yararlanılmıştır. Normalleştirilmiş TF-TDF skorları bazlı vektörler $[0, 1]$ aralığında değerler içerdiğinden ÜLB ve tanh aktivasyon fonksiyonları için bu değerler $[-1, 1]$ aralığında uygun değerlere eşlenmiştir.

Değişen aktivasyon fonksiyonlarının ve kodlayıcı katman sayılarının AE-simMCCF++ algoritmasının performansı üzerindeki etkileri Tablo 4.1'de sunulmuştur. Tablodaki sonuçlar göz önünde bulundurulduğunda yararlanılan her aktivasyon fonksiyonu için doğruluk ve kapsama açısından en iyi sonuç veren kodlayıcı katman sayısının değiştiği kanısına varılmaktadır. Bu durum daha önceki bölümlerde de ifade edildiği gibi ağıın kapasitesiyle alakalıdır. Eğitim için kullanılan verinin miktarı, yapısı, doluluk oranı, yararlanılan aktivasyon fonksiyonu gibi parametreler ağıın kapasitesini etkiler (Ian ve Yoshua, 2016a). Tablo 4.1'deki sonuçlara göre AE-simMCCF++ algoritması doğruluk açısından en iyi performansını ÜLB aktivasyonunu kullanan 2 kodlayıcı katmana sahip otokodlayıcı ile sağlamıştır. Kapsama açısından değerlendirildiğinde ise en iyi performans değerleri tanh fonksiyonunu kullanan 3 kodlayıcı katmana sahip otokodlayıcı ile elde edilmiştir. Hem doğruluk hem de kapsama açısından en dengeli performans sonuçları ise tanh aktivasyon fonksiyonundan yararlanan 2 kodlayıcı katmana sahip otokodlayıcı ile sağlanmıştır.

Tablo 4.1. Değişen aktivasyon fonksiyonları ve kodlayıcı katman sayılarının AE-simMCCF++ algoritmasının performansına doğruluk ve kapsama açısından etkileri

Kodlayıcı katman sayısı	Aktivasyon fonksiyonu	OMH	KOMH	Kapsama
2 kodlayıcı katman	DLB	0.8535	0.8559	0.1008
	ÜLB	0.8427	0.8468	0.1025
	Tanh	0.8441	0.8487	0.1042
3 kodlayıcı katman	DLB	0.8483	0.8508	0.1006
	ÜLB	0.8473	0.8512	0.1023
	Tanh	0.8449	0.8491	0.1044
4 kodlayıcı katman	DLB	0.8550	0.8578	0.0999
	ÜLB	0.8434	0.8470	0.1023
	Tanh	0.8560	0.8599	0.1025

4.3.2.2. AE-simMCCF++ algoritmasının AE-simMCCF ile kıyaslanması

AE-simMCCF algoritması tahminleri üretirken ham, seyrek ve yüksek boyutlu kullanıcı profillerinden otokodlayıcılar tarafından çıkarılan kompleks, yoğun ve düşük boyutlu özellikleri kullanır. 3. bölümde AE-simMCCF algoritmasının doğruluk ve kapsama açısından diğer öncü MCCF yaklaşımlarına göre veri seyrekliğiyle daha iyi başa çıkabildiği yapılan deneysel çalışmalarca gösterilmiştir. Ancak AE-simMCCF algoritması tahminleri üretirken sadece oy verisinden yararlanmaktadır. AE-simMCCF++ algoritması ise tahminleri üretirken AE-simMCCF algoritması tarafından sağlanan oy-tabanlı kullanıcı profillerinden çıkarılan özelliklerin yanı sıra kullanıcıların yapmış oldukları yorum verisinden de otokodlayıcı tarafından çıkarılan özellikleri kullanarak veri seyrekliği problemiyle daha iyi başa çıkabilmeyi amaçlar. Oy-tabanlı kullanıcı profillerinden çıkarılan özelliklere ek olarak yorum-tabanlı kullanıcı profillerinden de çıkarılan özelliklerin tahmin üretiminde kullanılmasının veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini daha iyi sönmüleyebildiğini göstermek amacıyla doğruluk ve kapsama açısından AE-simMCCF++ algoritması AE-simMCCF ile kıyaslanmıştır ve sonuçlar Tablo 4.2’de sunulmuştur. Tablodan da görüldüğü üzere yorum verisinden otokodlayıcılar tarafından elde edilen özelliklerin tahmin üretiminde kullanılması OMH, KOMH ve kapsama değerlerinde 0.0044, 0.0038 ve 0.0008 miktarlarında iyileştirme sağlamıştır.

Tablo 4.2. Doğruluk ve kapsama açısından AE-simMCCF++ algoritmasının AE-simMCCF ile kıyaslanması

Algoritma	OMH	KOMH	Kapsama
AE-simMCCF	0.8485	0.8525	0.1034
AE-simMCCF++	0.8441	0.8487	0.1042

4.4. Değerlendirmeler

Çoklu-kriterli öneri sistemlerinde artan kriter sayısı ile birlikte veri seyrekliği problemi de daha belirgin bir sorun haline dönüşür. Veri seyrekliği problemi üretilen tahminlerin doğruluğunu düşürmekle beraber tahmin üretememeye dahi sebep olabilir. Bu bölümde çoklu-kriterli öneri sistemlerinin temel problemlerinden olan veri seyrekliği problemiyle başa çıkabilmek için otokodlayıcılara dayanan benzerlik tabanlı hibrit bir çoklu-kriterli öneri sistemi algoritması olan AE-simMCCF++ önerilmiştir. AE-simMCCF++ tahminler üretirken otokodlayıcılardan yararlanarak kullanıcıların oylarından çıkardığı karmaşık, yoğun ve düşük boyutlu özelliklere ek olarak kullanıcı yorumlarından da türettiği kompleks ve gizli özellikleri kullanır. Gerçek bir veri seti üzerinde yapılan deneysel çalışmalar, tahminleri üretirken kullanıcıların oy-tabanlı tercihlerinin yanı sıra yorumlarının da kullanılmasının veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkilerini daha iyi sönümleyebildiğini göstermiştir.

5. DEĞERLENDİRMELER VE GERÇEKLEŞTİRİLMESİ PLANLANAN DİĞER ÇALIŞMALAR

ÇKOF tekniklerine dayalı öneri sistemlerinde de geleneksel öneri sistemlerinde olduğu gibi kullanıcıların memnuniyeti bu sistemlerin sürdürülebilirliğini ve kullanılabilirliğini artırır. Kullanıcıların memnuniyeti sunulan tahminlerin doğruluğunun iyileşmesiyle artar. Ayrıca gerçek zamanlı geleneksel OF uygulamalarında kullanıcılar oldukça az sayıda ürünler/hizmetler hakkında değerlendirmelerde bulunurlar. ÇKOF tekniklerine dayalı gerçek zamanlı öneri sistemlerinde ise kullanıcılar birden fazla kriteri göz önünde bulundurarak ürünler/hizmetler hakkında değerlendirmelerde bulunduklarından değerlendirme yapılan ürün/hizmet sayısı daha da azalmaktadır. Bu sebeple artan kriter sayısı ile birlikte doğruluğa ek olarak ölçeklenebilirlik ve veri seyrekliği de çoklu-kriterli öneri sistemlerinde karşılaşılan temel problemlerden olmuştur.

Bu doktora tezi kapsamında 2. bölüm, çoklu-kriterli öneri sistemlerinde üretilen tahminlerin doğruluğunu iyileştirmek için otokodlayıcılardan yararlanan yeni bir birleştirme fonksiyonu tabanlı ÇKOF algoritmasını sunmaktadır. Önerilen yaklaşım her bir kriter bazlı kullanıcı-ürün matrisi için bir otokodlayıcı tasarlar. Otokodlayıcılar, kullanıcılar ve ürünler arasındaki lineer olmayan, gizli ve karmaşık ilişkileri çıkararak kriter-bazlı tahminler üretirler. Önerilen yöntem, kriter bazındaki oylar ve genel kriter oyları arasındaki lineer olmayan ilişkileri çıkarmak için ise ileri beslemeli sinir ağlarından yararlanır. İki gerçek veri seti üzerinde yapılan deneysel çalışmalar, otokodlayıcıların artan kodlayıcı katman sayılarıyla birlikte daha gizli ve kompleks ilişkileri çıkarabilmesinden dolayı önerilen yöntem kullanılarak üretilen tahminlerin doğruluğunun genellikle iyileştiğini göstermiştir. Ayrıca yapılan deneysel analizler önerilen yöntemin öncü ÇKOF algoritmalarına göre doğruluk açısından daha iyi performans sergilediğini göstermiştir.

3. bölümde çoklu-kriterli öneri sistemlerinin temel problemlerinden olan veri seyrekliği ve ölçeklenebilirlik sorunlarıyla başa çıkabilmek için otokodlayıcılardan yararlanan yeni bir benzerlik-tabanlı ÇKOF algoritması tanıtılmıştır. Önerilen yaklaşım geleneksel hafıza-tabanlı OF algoritması ile tahminler üretmek amacıyla kullanıcılar/ürünler arasındaki birleştirilmiş benzerlikleri otokodlayıcılar tarafından kriter bazındaki kullanıcı/ürün profillerinden çıkarılan özellikleri kullanarak hesaplar. Bu amaç

doğrultusunda önerilen yöntem her bir kriter bazındaki kullanıcı-ürün matrisi için bir otokodlayıcı tasarlar ve bu otokodlayıcılar sayesinde ham, seyrek ve yüksek boyutlu kullanıcı/ürün profillerinden gizli, karmaşık, yoğun ve düşük boyutlu özellikler çıkarır. İki gerçek veri seti üzerinde gerçekleştirilen deneysel çalışmalar önerilen yöntemin doğruluk ve kapsama açısından veri seyrekliği problemini çözmedeki etkinliğinin yararlanılan otokodlayıcıların kapasiteleriyle yakından ilişkili olduğunu göstermiştir. Yapılan deneysel analizler önerilen yaklaşımın yararlanılan verinin miktarı ve yapısına uygun aktivasyon fonksiyonuna ve kodlayıcı katmanına sahip otokodlayıcılardan yararlandığında öncü ÇKOF algoritmalarına göre veri seyrekliği probleminin üretilen tahminlerin doğruluğu üzerindeki olumsuz etkisini daha iyi sönümlendiğini göstermiştir. Ayrıca gerçekleştirilen zaman karmaşıklığı analizleri, önerilen yöntemin tahminler üretirken yüksek boyutlu profiller yerine düşük boyutlu özelliklerden yararlanmasından dolayı mevcut korelasyona dayanan ÇKOF algoritmalarına göre daha ölçeklenebilir olduğunu göstermektedir.

Geleneksel öneri sistemlerinde veri seyrekliği problemi ile başa çıkmada sıklıkla yararlanılan yöntemlerden birisi de oy verisinden yararlanan sistemlere ürün içerikleri, kullanıcı yorumları gibi ekstra verileri entegre etmektir. 4. bölümde de çoklu-kriterli öneri sistemlerinde veri seyrekliği problemini çözmek için oy verisinin yanı sıra kullanıcıların yorumlarından da yararlanan otokodlayıcılara dayalı yeni, hibrit bir çoklu-kriterli öneri sistemi algoritması tanıtılmıştır. Önerilen yöntem, tahminler üretirken kullanıcılar/ürünler arasındaki benzerlikleri hesaplamak için 3. bölümde önerilen yöntemin oy-tabanlı kullanıcı profillerinden çıkardığı özelliklerin yanı sıra yorum-tabanlı kullanıcı/ürün profillerinden otokodlayıcılar tarafından çıkarılan gizli ve karmaşık özellikleri de kullanır. Gerçek bir veri seti üzerinde gerçekleştirilen deneysel çalışmalar üzerinde çalışılan veri setinin yapısına ve miktarına uygun parametrelere sahip otokodlayıcı kullanıldığında önerilen yöntem ile entegre edilen yorum-tabanlı karmaşık özelliklerin üretilen tahminlerin doğruluğunu iyileştirdiğini göstermiştir. Yapılan deneysel analizler önerilen yöntemin öncü ÇKOF algoritmalarına göre veri seyrekliği problemiyle başa çıkmada daha etkili olduğunu göstermektedir.

Bu tez kapsamında önerilen yaklaşımların tümü otokodlayıcılardan yararlanmaktadır. Diğer derin öğrenme tekniklerinin geleneksel öneri sistemlerinde ortaya koydukları öncü performansları göz önünde bulundurulduğunda çoklu-kriterli

öneri sistemlerinin temel problemlerinden olan doğruluk, ölçeklenebilirlik ve veri seyrekliği sorunları ile başa çıkabilmek için bu tekniklerden yararlanan yeni yaklaşımlar önerilebilir.



KAYNAKÇA

- Adomavicius, G. and Kwon, Y. (2007). New recommendation techniques for multicriteria rating systems, *IEEE Intelligent Systems*, 22(3), 48-55.
- Adomavicius, G., Manouselis, N. and Kwon, Y. (2011). Multi-criteria recommender systems, *Recommender Systems Handbook*, 769-803.
- Adomavicius, G. and Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions, *IEEE Transactions on Knowledge & Data Engineering*, 17(6), 734-749.
- Agathokleous, M. and Tsapatsoulis, N. (2014). Learning user models in multi-criteria recommender systems, In: *Proceedings of the 15th International Conference on Engineering Applications of Neural Networks*. Sofia, Bulgaria. pp 205-216.
- Ashraf, M. and Hussain, M. Z. (2018). Multi-criteria decision based recommender system using fuzzy linguistics model for e-commerce, *Int. J. Sci. Res. Sci. Technol*, 4(5), 61-67.
- Batmaz, Z., Yurekli, A., Bilge, A. and Kaleli, C. (2019). A review on deep learning for recommender systems: challenges and remedies, *Artificial Intelligence Review*, 52(1), 1-37.
- Bellini, V., Anelli, V. W., Di Noia, T. and Di Sciascio, E. (2017). Auto-encoding user ratings via knowledge graphs in recommendation scenarios, In: *Proceedings of the 2nd Workshop on Deep Learning for Recommender Systems*. Como, Italy. pp 60-66.
- Bilge, A. and Kaleli, C. (2014). A multi-criteria item-based collaborative filtering framework, In: *Proceedings of the 11th International Joint Conference on Computer Science and Software Engineering*. Chonburi, Thailand. pp 18-22.
- Breese, J. S., Heckerman, D. and Kadie, C. (1998). Empirical analysis of predictive algorithms for collaborative filtering, In: *Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence*. Madison, Wisconsin, USA. pp 43-52.
- Clevert, D.-A., Unterthiner, T. and Hochreiter, S. (2015). Fast and accurate deep network learning by exponential linear units (elus), *arXiv preprint arXiv:1511.07289*.
- Dai, H., Wang, Y., Trivedi, R. and Song, L. (2016). Deep coevolutionary network: Embedding user and item features for recommendation, *arXiv preprint arXiv:1609.03675*.

- Di Bitonto, P., Laterza, M., Roselli, T. and Rossano, V. (2010). Multi-criteria retrieval in cultural heritage recommendation systems, In: *Proceedings of the International Conference on Knowledge-Based and Intelligent Information and Engineering Systems*. Cardiff, UK. pp 64-73.
- Du, Y.-p., Yao, C.-q., Huo, S.-h. and Liu, J.-x. (2017). A new item-based deep network structure using a restricted Boltzmann machine for collaborative filtering, *Frontiers of Information Technology & Electronic Engineering*, 18(5), 658-666.
- Fan, J. and Xu, L. (2013). A robust multi-criteria recommendation approach with preference-based similarity and support vector machine, In: *Proceedings of the 10th International Symposium on Neural Networks*. Dalian, China. pp 385-394.
- Farokhi, N., Vahid, M., Nilashi, M. and Ibrahim, O. (2016). A multi-criteria recommender system for tourism using fuzzy approach, *Journal of Soft Computing and Decision Support Systems*, 3(4), 19-29.
- Ge, M., Delgado-Battenfeld, C. and Jannach, D. (2010). Beyond accuracy: evaluating recommender systems by coverage and serendipity, In: *Proceedings of the 4th ACM Conference on Recommender Systems*. Barcelona, Spain. pp 257-260.
- Georgiev, K. and Nakov, P. (2013). A non-iid framework for collaborative filtering with restricted Boltzmann machines, In: *Proceedings of the 30th International Conference on Machine Learning*. Atlanta, GA, USA. pp 1148-1156.
- Gunawardana, A. and Meek, C. (2008). Tied Boltzmann machines for cold start recommendations, In: *Proceedings of the 2nd ACM Conference on Recommender Systems*. Lausanne, Switzerland. pp 19-26.
- Hamada, M. and Hassan, M. (2018). Artificial neural networks and particle swarm optimization algorithms for preference prediction in multi-criteria recommender systems, *Informatics*, 5(2), 25.
- Hassan, M. and Hamada, M. (2017). A neural networks approach for improving the accuracy of multi-criteria recommender systems, *Applied Sciences*, 7(9), 868.
- Hu, Y.-C. (2014a). Neighborhood-based collaborative filtering using grey relational analysis, *Journal of Grey System*, 26(1), 99-114.
- Hu, Y.-C. (2014b). Recommendation using neighborhood methods with preference-relation-based similarity, *Information Sciences*, 284, 18-30.

- Hu, Y.-C., Chiu, Y.-J., Liao, Y.-L. and Li, Q. (2015). A fuzzy similarity measure for collaborative filtering using nonadditive grey relational analysis, *Journal of Grey System*, 27(2), 93.
- Hu, Y.-C., Chiu, Y.-J. and Tsai, J.-F. (2018). Establishing grey criteria similarity measures for multi-criteria recommender systems, *Journal of Grey System*, 30(1), 194-207.
- Hwang, C.-S. (2010). Genetic algorithms for feature weighting in multi-criteria recommender systems, *Journal of Convergence Information Technology*, 5(8), 126-136.
- Ian, G. and Yoshua, B. (2016a), Deep learning, MIT Press.
- Ian, G. and Yoshua, B. (2016b). Deep learning: Adaptive computation and machine learning, MIT Press, Cambridge.
- Ioffe, S. and Szegedy, C. (2015). Batch normalization: accelerating deep network training by reducing internal covariate shift, In: *Proceedings of the 32nd International Conference on Machine Learning*. Lille, France. pp 448-456.
- Jannach, D., Gedikli, F., Karakaya, Z. and Juwig, O. (2012a). Recommending hotels based on multi-dimensional customer ratings, In: *Proceedings of the International Conference on Information and Communication Technologies in Tourism*. Helsingborg, Sweden. pp 320-331.
- Jannach, D., Karakaya, Z. and Gedikli, F. (2012b). Accuracy improvements for multi-criteria recommender systems, In: *Proceedings of the 13th ACM Conference on Electronic Commerce*. Valencia, Spain. pp 674-689.
- Joachims, T. (1997). A Probabilistic analysis of the Rocchio algorithm with TFIDF for text categorization, In: *Proceedings of the 14th International Conference on Machine Learning*. Nashville, Tennessee, USA. pp 143-151.
- Kant, V., Jhalani, T. and Dwivedi, P. (2018). Enhanced multi-criteria recommender system based on fuzzy Bayesian approach, *Multimedia Tools and Applications*, 77(10), 12935-12953.
- Kaur, G. and Ratnoo, S. (2019). Adaptive genetic algorithm for feature weighting in multi-criteria recommender systems, *Pertanika Journal of Science & Technology*, 27(1), 306-314.

- Kermany, N. R. and Alizadeh, S. H. (2017). A hybrid multi-criteria recommender system using ontology and neuro-fuzzy techniques, *Electronic Commerce Research and Applications*, 21, 50-64.
- Kim, D., Park, C., Oh, J. and Yu, H. (2017). Deep hybrid recommender systems via exploiting document context and statistics of items, *Information Sciences*, 417, 72-87.
- Kumar Bokde, D., Girase, S. and Mukhopadhyay, D. (2015). An item-based collaborative filtering using dimensionality reduction techniques on Mahout framework, In: *Proceedings of the 4th Post Graduate Conference for Information Technology Sangamner*, Maharashtra, India. pp 2394-0905.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning, *Nature*, 521(7553), 436-444.
- LeCun, Y. A., Bottou, L., Orr, G. B. and Müller, K.-R. (2012). Efficient backprop, *Neural networks: Tricks of the trade*, 9-48.
- Lee, J., Lee, K., Park, J., Park, J. and Nam, J. (2018). Deep content-user embedding model for music recommendation, *arXiv preprint arXiv:1807.06786*.
- Li, S., Kawale, J. and Fu, Y. (2015). Deep collaborative filtering via marginalized denoising auto-encoder, In: *Proceedings of the 24th ACM International on Conference on Information and Knowledge Management*. Melbourne, VIC, Australia. ACM. pp 811-820.
- Li, X. and She, J. (2017). Collaborative variational autoencoder for recommender systems, In: *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, NS, Canada. pp 305-314.
- Majumder, G. S., Dwivedi, P. and Kant, V. (2017). Matrix factorization and regression-based approach for multi-criteria recommender system, In: *Proceedings of the International Conference on Information and Communication Technology for Intelligent Systems*. Ahmedabad, India. Springer. pp 103-110.
- Naak, A., Hage, H. and Aimeur, E. (2009). A multi-criteria collaborative filtering approach for research paper recommendation in papyres, In: *Proceedings of the 4th International Conference on E-Technologies*. Ottawa, Canada. pp 25-39.
- Nilashi, M., Bagherifard, K., Rahmani, M. and Rafe, V. (2017). A recommender system for tourism industry using cluster ensemble and prediction machine learning techniques, *Computers & Industrial Engineering*, 109, 357-368.

- Nilashi, M., bin Ibrahim, O., Ithnin, N. and Sarmin, N. H. (2015a). A multi-criteria collaborative filtering recommender system for the tourism domain using Expectation Maximization (EM) and PCA–ANFIS, *Electronic Commerce Research and Applications*, 14(6), 542-562.
- Nilashi, M., Esfahani, M. D., Roudbaraki, M. Z., Ramayah, T. and Ibrahim, O. (2016). A multi-criteria collaborative filtering recommender system using clustering and regression techniques, *Journal of Soft Computing and Decision Support Systems*, 3(5), 24-30.
- Nilashi, M., Ibrahim, O. B., Ithnin, N. and Zakaria, R. (2015b). A multi-criteria recommendation system using dimensionality reduction and neuro-fuzzy techniques, *Soft Computing*, 19(11), 3173-3207.
- Ricci, F., Rokach, L. and Shapira, B. (2015), *Recommender systems handbook*, Springer.
- Salakhutdinov, R., Mnih, A. and Hinton, G. (2007). Restricted Boltzmann machines for collaborative filtering, In: *Proceedings of the 24th International Conference on Machine Learning*. Corvallis, Oregon, USA. pp 791-798.
- Sanchez-Vilas, F., Ismoilov, J., Sanchez, E. and Lama, M. (2011). Applying multicriteria algorithms to restaurant recommendation, In: *Proceedings of the IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology*. Lyon, France. pp 87-91.
- Sarwar, B. M., Karypis, G., Konstan, J. A. and Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms, In: *Proceedings of the 10th international conference on world wide web*. Hong Kong, China. pp 285-295.
- Schafer, J. B., Konstan, J. A. and Riedl, J. (2001). E-commerce recommendation applications, *Data Mining and Knowledge Discovery*, 5(1-2), 115-153.
- Sedhain, S., Menon, A. K., Sanner, S. and Xie, L. (2015). Autorec: autoencoders meet collaborative filtering, In: *Proceedings of the 24th International Conference on World Wide Web*. Florence, Italy. pp 111-112.
- Shambour, Q., Hourani, M. and Fraihat, S. (2016). An item-based multi-criteria collaborative filtering algorithm for personalized recommender systems, *International Journal of Advanced Computer Science and Applications*, 7(8), 274-279.
- Shambour, Q. and Lu, J. (2011). A hybrid multi-criteria semantic-enhanced collaborative filtering approach for personalized recommendations, In: *Proceedings of the 2011*

- IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology*. de la Doua, Lyon, France. pp 71-78.
- Shani, G. and Gunawardana, A. (2011). Evaluating recommendation systems, *Recommender Systems Handbook*, 257-297.
- Shen, X., Yi, B., Zhang, Z., Shu, J. and Liu, H. (2016). Automatic recommendation technology for learning resources with convolutional neural network, In: *Proceedings of the International Symposium on Educational Technology*. Beijing, China. pp 30-34.
- Sparck Jones, K. (1972). A statistical interpretation of term specificity and its application in retrieval, *Journal of Documentation*, 28(1), 11-21.
- Strub, F., Gaudel, R. and Mary, J. (2016). Hybrid recommender system based on autoencoders, In: *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*. Boston, MA, USA. pp 11-16.
- Strub, F. and Mary, J. (2015). Collaborative filtering with stacked denoising autoencoders and sparse inputs, In: *Proceedings of the e NIPS Workshop on Machine Learning for eCommerce*. Montreal, Canada. pp.
- Tallapally, D., Sreepada, R. S., Patra, B. K. and Babu, K. S. (2018). User preference learning in multi-criteria recommendations using stacked auto encoders, In: *Proceedings of the 12th ACM Conference on Recommender Systems*. Vancouver, BC, Canada. pp 475-479.
- Truyen, T., Phung, D. Q. and Venkatesh, S. (2009). Ordinal Boltzmann machines for collaborative filtering, In: *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence*. Montreal, QC, Canada. pp 548-556.
- Uysal, A. K. and Gunal, S. (2012). A novel probabilistic feature selection method for text classification, *Knowledge-Based Systems*, 36, 226-235.
- Uysal, A. K. and Gunal, S. (2014). The impact of preprocessing on text classification, *Information Processing & Management*, 50(1), 104-112.
- Van den Oord, A., Dieleman, S. and Schrauwen, B. (2013). Deep content-based music recommendation, In: *Proceedings of the 26th International Conference on Neural Information Processing Systems*. Lake Tahoe, NV, USA. pp.
- Van Meteren, R. and Van Someren, M. (2000). Using content-based filtering for recommendation, In: *Proceedings of the Workshop on Machine Learning in the New Information Age*. Barcelona, Spain. pp 47-56.

- Wang, H., Lu, Y. and Zhai, C. (2011). Latent aspect rating analysis without aspect keyword supervision, In: *Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Diego, CA, USA. pp 618-626.
- Wang, H., Wang, N. and Yeung, D.-Y. (2015). Collaborative deep learning for recommender systems, In: *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Sydney, NSW, Australia. pp 1235-1244.
- Wang, X. and Wang, Y. (2014). Improving content-based and hybrid music recommendation using deep learning, In: *Proceedings of the 22nd ACM International Conference on Multimedia*. Orlando, Florida, USA. pp 627-636.
- Wasid, M. and Ali, R. (2018). An improved recommender system based on multi-criteria clustering approach, *Procedia Computer Science*, 131, 93-101.
- Wei, J., He, J., Chen, K., Zhou, Y. and Tang, Z. (2017). Collaborative filtering and deep learning based recommendation system for cold start items, *Expert Systems with Applications*, 69, 29-39.
- Yang, C., Bai, L., Zhang, C., Yuan, Q. and Han, J. (2017). Bridging collaborative filtering and semi-supervised learning: a neural approach for poi recommendation, In: *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, NS, Canada. pp 1245-1254.
- Zhang, F., Yuan, N. J., Lian, D., Xie, X. and Ma, W.-Y. (2016). Collaborative knowledge base embedding for recommender systems, In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco, CA, USA. pp 353-362.
- Zhang, S., Yao, L. and Xu, X. (2017). Autosvd++: an efficient hybrid collaborative filtering model via contractive auto-encoders, In: *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Shinjuku, Tokyo, Japan. pp 957-960.
- Zhang, Y., Zhuang, Y., Wu, J. and Zhang, L. (2009). Applying probabilistic latent semantic analysis to multi-criteria recommender system, *Ai Communications*, 22(2), 97-107.
- Zheng, Y., Tang, B., Ding, W. and Zhou, H. (2016). A neural autoregressive approach to collaborative filtering, In: *Proceedings of the 33rd International Conference on*

International Conference on Machine Learning. New York, NY, USA. pp 764-773.



ÖZGEÇMİŞ

Adı Soyadı : Zeynep BATMAZ
Yabancı Dil : İngilizce, Almanca
Doğum Yeri ve Yılı : Erzincan / 26.09.1990
E-Posta : zozdemir@eskisehir.edu.tr

Eğitim Geçmişi:

- Doktora (2018-) : Eskişehir Teknik Üniversitesi, Fen Bil. Ens., Bilgisayar Mühendisliği A.B.D.
- Doktora (2015-2018) : Anadolu Üniversitesi, Fen Bil. Ens., Bilgisayar Mühendisliği A.B.D.
- Yüksek Lisans (2013-2015) : Anadolu Üniversitesi, Fen Bil. Ens., Bilgisayar Mühendisliği A.B.D.
- Lisans (2008-2013) : Anadolu Üniversitesi, Bilgisayar Mühendisliği Bölümü

Meslek Geçmişi:

- Araştırma Görevlisi (2018-) : Eskişehir Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü
- Araştırma Görevlisi (2013-2018) : Anadolu Üniversitesi, Bilgisayar Mühendisliği Bölümü

SCI ve SCI-Expanded kapsamındaki dergilerde yayınlanan makaleler:

****Batmaz, Z., Yurekli, A., Bilge, A., and Kaleli, C. (2019). A review on deep learning for recommender systems. *Artificial Intelligence Review*, 52(1), 1-37.**

****Batmaz, Z., and Kaleli, C. (2019). AE-MCCF: an autoencoder-based multi-criteria recommendation algorithm. *Arabian Journal for Science and Engineering*, 44(11), 9235-9247.**

Batmaz, Z., Yilmazel, B., and Kaleli, C. (2019). Shilling attack detection in binary data: a classification approach. *Journal of Ambient Intelligence and Humanized Computing*, 1-11.

****Batmaz, Z., and Kaleli, C. (2019).** A new similarity-based multi-criteria recommendation algorithm based-on autoencoders. *Information Processing & Management*. (submitted)

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler:

Batmaz, Z., and Kaleli, C. (2017). Methods of privacy preserving in collaborative filtering. In: *Proceedings of 2017 International Conference on Computer Science and Engineering*. pp. 261-266.

Batmaz, Z., and Polat, H. (2016). Randomization-based privacy preserving frameworks for collaborative filtering. *Procedia Computer Science*, 96, 33-42.

Bilge, A., **Ozdemir, Z., and Polat, H. (2014).** A novel shilling attack detection method. *Procedia Computer Science*, 31, 165-174.

Alan endeksleri kapsamındaki dergilerde ve uluslararası hakemli dergilerde yayınlanan çalışmalar:

***Batmaz, Z., and Polat, H. (2017).** Designing shilling attacks on disguised binary data. *International Journal of Data Mining, Modelling and Management*, 9(3), 185-200.

Bilge, A., **Batmaz, Z., and Polat, H. (2016).** Maskelenmiş veriler için kümeleme-tabanlı şilin atak tespit yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 28(2), 207-216.

******: Doktora tezinden üretilmiş yayınlar.

*****: Yüksek lisans tezinden üretilmiş yayınlar.