



**ÖZELLİK TABANLI GÖRÜŞ MADENCİLİĞİNDE
YAPAY ZEKA TEKNİKLERİ KULLANARAK
GÖRÜŞ HEDEFİ ÇIKARIMI VE KATEGORİ
TESPİTİ**

Kürşat Mustafa KARAOĞLAN

**2022
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Prof. Dr. Oğuz FINDIK**

**ÖZELLİK TABANLI GÖRÜŞ MADENCİLİĞİNDE YAPAY ZEKA
TEKNİKLERİ KULLANARAK GÖRÜŞ HEDEFİ ÇIKARIMI VE
KATEGORİ TESPİTİ**

Kürşat Mustafa KARAOĞLAN

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Prof. Dr. Oğuz FINDIK**

**KARABÜK
Mart 2022**

Kürşat Mustafa KARAOĞLAN tarafından hazırlanan “ÖZELLİK TABANLI GÖRÜŞ MADENCİLİĞİNDE YAPAY ZEKA TEKNİKLERİ KULLANARAK GÖRÜŞ HEDEFİ ÇIKARIMI VE KATEGORİ TESPİTİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Prof. Dr. Oğuz FINDIK

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 04/03/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Erkan ÜLKER (KTÜN)

.....

Üye : Prof. Dr. Oğuz FINDIK (KBÜ)

.....

Üye : Prof. Dr. Mustafa Servet KIRAN (KTÜN)

.....

Üye : Doç. Dr. İlker TÜRKER (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Yüksel ÇELİK (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Kürşat Mustafa KARAOĞLAN

ÖZET

Doktora Tezi

ÖZELLİK TABANLI GÖRÜŞ MADENCİLİĞİNDE YAPAY ZEKA TEKNİKLERİ KULLANARAK GÖRÜŞ HEDEFİ ÇIKARIMI VE KATEGORİ TESPİTİ

Kürşat Mustafa KARAOĞLAN

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Prof. Dr. Oğuz FINDIK

Mart 2022, 102 sayfa

Son zamanlarda, çevrimiçi inceleme platformları kullanıcıların satın alma kararlarını destekleyen önemli bilgi kaynakları haline gelmiştir. Kullanıcılar bir ürünü ya da hizmeti satın almadan önce olası deneyimlere ulaşmada bu bilgi kaynaklarına başvurmaktadır. İşletmeler ise pazarladıkları ürünlerin kullanıcılar üzerindeki etkilerini keşfedebilmek için bu kaynakların potansiyel gücünden yararlanmayı hedeflemektedir. Ancak bu kaynakların hacimsel büyüklüğü düşünüldüğünde; kullanıcıların tüm incelemeleri okuyarak etkin bir şekilde değerlendirmesi neredeyse imkânsız hale gelmektedir. Diğer bir taraftan büyük kullanıcı popülasyonu karşılıklı olarak karşı karşıya kalan işletmeler, verilerin işlenmesi ve analizi gibi süreçlerde otomatikleştirilmiş yaklaşımlara ihtiyaç duymaktadır. Bu sebeple araştırmacılar, yukarıda bahsedilen problemleri ele alarak daha etkin ve detaylı analizlere olanak sağlayan Özellik Tabanlı Görüş (Fikir) Madenciliği çalışmalarına ilgi göstermektedir.

Bu tez çalışmasında ilk olarak, örüntü tabanlı metin ön işleme yöntemine, yardımcı bileşenlerle genişletilmiş sözdizimsel tabanlı ilişki kuralları algoritmalarına ve model çıktılarında performans optimizasyonu sağlamak amacıyla uygulanan çoğunlukla seçim yöntemine sahip Görüş Hedefi Çıkarımı (Opinion Target Extraction, OTE) yaklaşımı önerilmiştir. Önerilen bu yaklaşımla, kullanıcılar tarafından öznel nitelikli görüş sözcükleriyle yorumlanan varlığa ilişkin ayırt edici özellikleri temsil eden açık ifadelerin (görüş hedefleri) çıkarılması sağlanmıştır. Önerilen OTE yaklaşımının etkinliğini test etmek amacıyla, restoran incelemeleri içeren veri seti üzerinde deneysel çalışmalar gerçekleştirilmiştir. Deneysel çalışmaların sonuçları analiz edildiğinde, önerilen yaklaşımın literatürdeki denetimli yaklaşımlarla karşılaştırılabilir sonuçlar ürettiği, denetimsiz diğer yaklaşımlara göre ise daha yüksek performans gösterdiği sonucuna ulaşılmıştır.

İkinci olarak, belirli özellik kategorileriyle çoklu ve hiyerarşik yapıda etiketlenmiş inceleme cümlelerinin sınıflandırılması amacıyla derin öğrenme tabanlı Özellik Kategorisi Tespiti (Aspect Category Detection, ACD) yaklaşımları önerilmiştir. Önerilen ACD yaklaşımlarında, girdilerinde bağlamsal bilgiyi dikkate alarak zengin vektör temsilleri üretebilen önceden eğitilmiş Dönüştürücülerden Çift Yönlü Kodlayıcı Temsilleri (BERT) ve Anlamsal Katlama Teorisi (SFT) kelime temsil modellerinin (word embedding model, WEM) uygulandığı Evrişimsel Sinir Ağı ve Derin Sinir Ağı tabanlı çok etiketli metin sınıflandırma yaklaşımları geliştirilmiştir. Geliştirilen ACD yaklaşımlarının etkinliklerini ve uygulanan WEM'lerin sınıflandırma performanslarına olan katkılarını analiz etmek için, dizüstü bilgisayar ve restoran inceleme veri setleri üzerinde deneysel çalışmalar gerçekleştirilmiştir. Deneysel çalışmaların sonuçları analiz edildiğinde, önerilen yaklaşımlarla literatürdeki diğer yaklaşımlara göre daha yüksek veya rekabetçi performans sonuçları elde edilmiştir. Ayrıca bu çalışmada uygulanan WEM'lerin performanslarının birlikte değerlendirilmesi, literatürde ilkler arasında yer almaktadır.

Anahtar Sözcükler : Doğal Dil İşleme, Görüş (Fikir) Madenciliği, Özellik Tabanlı Görüş Madenciliği, Görüş hedefi çıkarımı, Özellik kategorisi tespiti, Metin ön işleme, Kelime temsil modelleri.

Bilim Kodu : 92416

ABSTRACT

Ph. D. Thesis

OPINION TARGET EXTRACTION AND CATEGORY DETECTION USING ARTIFICIAL INTELLIGENCE TECHNIQUES IN ASPECT-BASED OPINION MINING

Kürşat Mustafa KARAOĞLAN

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Prof. Dr. Oğuz FINDIK

March 2022, 102 pages

Recently, online review platforms have become significant data sources that support users' purchasing decisions. Users refer to these information sources to reach possible experiences before purchasing a product or service. On the other hand, businesses aim to benefit from the potential power of these resources to investigate the effects of the products they market on users. However, considering the volumetric size of these resources, it becomes almost impossible for users to evaluate them effectively by reading all the reviews. On the other hand, businesses that face large user populations need automated approaches in processes such as data processing and analysis. For this reason, researchers are interested in Aspect-based Opinion Mining studies, which enable more effective and fine-grained analysis by addressing the problems mentioned above.

In this thesis, firstly, the Opinion Target Extraction (OTE) approach, including the pattern-based text pre-processing method, algorithms of extended syntactic-based relation rules with auxiliary components, and the majority voting method applied to provide performance optimization in model outputs, is proposed. It was provided to extract explicit expressions (opinion targets) representing distinctive entity aspects interpreted by users with subjective opinion words with this proposed approach. In order to test the effectiveness of the proposed OTE approach, experimental studies were carried out on a data set containing restaurant reviews. When the results of experimental studies were analyzed, it was reached that the proposed approach produced results comparable to supervised approaches in the literature and performed higher than other unsupervised approaches.

Secondly, deep learning-based Aspect Category Detection (ACD) approaches are proposed to classify multi-label and hierarchically tagged review sentences with specific aspect categories. In the proposed ACD approaches, Convolutional Neural Network (CNN) and Deep Neural Network (DNN) based in which pre-trained Bidirectional Encoder Representations from Transformers (BERT) and Semantic Folding Theory (SFT) word embedding models (WEMs) that generate rich vector representations by considering contextual information are applied in their inputs multi-label text classification approaches have been developed. In order to analyze the effectiveness of the developed ACD approaches and their contribution to the classification performance of the implemented WEMs, experimental studies were carried out on laptop and restaurant review datasets. When the results of experimental studies were analyzed, higher or competitive performance results were obtained with the proposed approaches compared to other approaches in the literature—in addition, evaluating the performances of applied WEMs together is among the firsts in the literature.

Key Word : Natural Language Processing, Opinion Mining, Aspect-Based Opinion Mining, Opinion target extraction, Aspect category detection, Text pre-processing, Word embedding models.

Science Code : 92416

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini hiçbir zaman esirgemeyen, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren, engin bilgi ve tecrübelerinden oka istifade ettięim danıőman hocam Sayın Prof. Dr. Oęuz FINDIK'a sonsuz teőekkürlerimi sunarım.

Ayrıca doktora sürecimde ilgi, bilgi ve destekleriyle alıőmalarına ışık tutan tez izleme kurulu üyeleri Sayın Prof. Dr. Erkan ÜLKER ve Sayın Do. Dr. İlker Türker'e, engin bilgi ve tecrübeleriyle alıőmalarımı her zaman destekleyen Sayın Dr. Öğr. Üyesi Rafet DURGUT, Sayın Dr. Öğr. Üyesi Volkan TEMİZKAN ve Sayın Do. Dr. Serhat Orkun TAN'a, her konuda sabırla yanımda olan haklarını hiçbir zaman ödeyemeyeceęim sevgili eşim Dr. Öğr. Üyesi Nursel KARAOĞLAN, biricik oęlum Ahmet Tarık KARAOĞLAN ve biricik kızım Nevőin KARAOĞLAN'a aynı zamanda dua ve destekleriyle hep yanımda hissettięim anneme, babama ve kardeőlerime en kalbi duygularıyla teőekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiii
KISALTMALAR DİZİNİ.....	xiv
BÖLÜM 1	17
GİRİŞ	17
1.1. TEZİN AMACI.....	20
1.1.1. Teorik Açıdan Önerilen Yaklaşımların Özel Amaçları	21
1.1.2. Pratik Açıdan Önerilen Yaklaşımların Özel Amaçları	21
1.2. TEZİN KATKILARI	21
1.2.1. Önerilen OTE yaklaşımının katkıları	22
1.2.2. Önerilen ACD yaklaşımlarının katkıları	22
1.3. TEZİN ORGANİZASYONU	23
BÖLÜM 2	24
LİTERATÜR ARAŞTIRMASI	24
BÖLÜM 3	27
GÖRÜŞ MADENCİLİĞİ.....	27
3.1. GÖRÜŞ MADENCİLİĞİ TERMİNOLOJİSİ.....	28
3.2. GÖRÜŞ MADENCİLİĞİ PROBLEM TANIMI	33
3.3. GÖRÜŞ MADENCİLİĞİ ÖN AŞAMALARI.....	35
3.3.1. Veri Toplama Teknikleri.....	36

3.3.2.	Metin Ön İşleme Teknikleri	36
3.3.3.	Metin Temsil Modelleri	38
3.3.3.1.	BERT modeli	40
3.3.3.2.	SFT modeli	40
3.4.	GÖRÜŞ MADENCİLİĞİ GÖREVLERİ	42
3.4.1.	Doküman Seviyesi Görevleri	42
3.4.2.	Cümle Seviyesi Görevleri	43
3.4.3.	Varlık ve Özellik Seviyesi Görevleri	44
3.4.4.	Konsept Seviyesi Görevleri	46
BÖLÜM 4		47
GÖRÜŞ HEDEFİ ÇIKARIMI (OTE) YAKLAŞIMI		47
4.1.	OTE YAKLAŞIMI GENEL MİMARİSİ VE BİLEŞENLERİ	47
4.2.	METODOLOJİ	48
4.2.1.	Örüntü Tabanlı Metin Ön İşleme Yöntemi (PBP)	48
4.2.2.	Genişletilmiş Sözdizilimsel Tabanlı Bağlılık İlişki Kuralları	50
4.2.3.	Çoğunlukla Seçim (MV)	54
BÖLÜM 5		56
ÖZELLİK KATEGORİSİ TESPİTİ (ACD) YAKLAŞIMI		56
5.1.	ACD YAKLAŞIMI GENEL MİMARİSİ VE BİLEŞENLERİ	56
5.2.	METODOLOJİ	58
5.2.1.	Derin Öğrenme Modelleri (CNN, DNN)	58
5.2.2.	Kelime Temsil Modelleriyle Metin Temsillerinin Üretilmesi	58
5.2.3.	Çıktı Etiketlerinin Kodlanması	60
BÖLÜM 6		62
DENEYSEL ÇALIŞMALAR VE PERFORMANS KARŞILAŞTIRMALARI		62
6.1.	DENEYSEL ORTAM	62
6.1.1.	Veri Setleri	62
6.1.2.	Performans Metrikleri	63
6.1.3.	Görüş Sözlükleri	64
6.1.4.	Derin Öğrenme Modelleri (CNN ve DNN)	66

6.1.4.1. Derin Öğrenme Modelleri Hiperparametre Değerleri.....	66
6.2. OTE YAKLAŞIMI DENEYSEL ÇALIŞMALAR VE PERFORMANS KARŞILAŞTIRMALARI	68
6.3. ACD YAKLAŞIMLARI DENEYSEL ÇALIŞMALAR VE PERFORMANS KARŞILAŞTIRMALARI.....	72
BÖLÜM 7	78
BULGULAR VE TARTIŞMA	78
7.1. ÖNERİLEN OTE YAKLAŞIMI BULGULARI VE SONUÇLARI	78
7.1.1. OTE Yaklaşımı Bulguları	78
7.1.2. OTE Yaklaşımı Sonuçları	79
7.2. ÖNERİLEN ACD YAKLAŞIMLARI BULGULARI VE SONUÇLARI	80
7.2.1. ACD Yaklaşımları Bulguları.....	80
7.2.2. ACD Yaklaşımları Sonuçları	81
BÖLÜM 8	82
SONUÇLAR VE GELECEKTEKİ ÇALIŞMALAR	82
KAYNAKLAR	84
ÖZGEÇMİŞ	101

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. GM'nin mevcut araştırma alanları arasındaki konumu.	28
Şekil 3.2. İnceleme cümlesi üzerinde görüş hedefleri, özellik kategorileri ve polarite çıkarımları.....	30
Şekil 3.3. Yönetici ve bağımlı arasındaki birebir bağıllık ilişkisi temsili.....	32
Şekil 3.4. İki boyutlu semantik uzay üzerinde, cortical.io Retina sunucusu üzerinde üretilen kelime temsilleri ve bu temsiller üzerinde uygulamalar, (a) "apple" kelimesinin SF temsili, (b) "computers" kelimesinin SF temsili, (c) "apple" ve "computers" kelimeleri arasındaki vektörel mesafe/benzerlik hesaplamaları, SF'ler arasında (d) veya ve (e) çıkarma operatörlerinin uygulanması.....	41
Şekil 4.1. Geliştirilen OTE yaklaşımına ilişkin genel mimari.	47
Şekil 4.2. Dilbilgisel tamlama kuralları örüntüleriyle geliştirilen metin ön işleme yöntemi (PBP).	49
Şekil 4.3. Metin ön işleme için geliştirilen PBP yöntemi algoritması.	50
Şekil 4.4. Bileşenleriyle birlikte geliştirilen OTE mimarisi.....	50
Şekil 4.5. Çok kelimeli OT ve OW içeren örnek bir cümle üzerinde bağıllık ayrıştırıcı çıktıları.	51
Şekil 4.6. Genişletilmiş sözdizim tabanlı ilişki kurallarını yöneten algoritma.....	52
Şekil 4.7. İnceleme cümlesi (üstte) ve görüş hedefi etiketi (koyu yeşil renkli ifade), cümle ayrıştırma işlemi uygulanmadan önce NBCR çıkarımları, cümle ayrıştırma işlemi sonrası NBCR çıkarımları.	54
Şekil 5.1. Çoklu ve hiyerarşik yapıda etiketlenmiş inceleme metinleri üzerinde ACD görevlerine ilişkin önerilen yaklaşımlar.	57
Şekil 5.2. Önerilen ACD yaklaşımlarına ilişkin genel mimari ve bileşenler.	57
Şekil 5.3. SFT kelime temsil modeliyle cümle temsili süreçleri.....	59
Şekil 5.4. Örnek bir cümle üzerinde BERT ve SFT kelime temsil modeliyle üretilen cümle temsilleri.	60
Şekil 5.5. Çıktı etiketlerin bir one-hot vektörüne kodlanması 61	61
Şekil 6.1. SenticNet, Vader ve TextBlob polarite analizörlerinin tekil ve ikili kombinasyonlarıyla ölçülen doğruluk skorları ve MV yönteminden sonra hesaplanan genel doğruluk skoru.	71

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Evrensel nitelikli açık ve kapalı POS etiketleri.....	31
Çizelge 3.2. Evrensel bağıllık ilişki tipleri.....	33
Çizelge 4.1. Temel bağıllık ilişkisi türleri (d_i) ve genişletilmiş sözdizimsel tabanlı kurallar için tanımlanan yardımcı ilişki türleri ve açıklamaları.....	52
Çizelge 4.2. L sayıda bağımsız sınıflandırıcı için münferit doğruluk skorlarına göre MV için hesaplanan maksimum doğruluk skorları.....	55
Çizelge 6.1. Kullanılan veri setlerine ilişkin tanımlayıcı istatistiksel bilgiler.....	63
Çizelge 6.2. CNN modeli için eğitimde kullanılan hiperparametreler.....	67
Çizelge 6.3. DNN modeli için eğitimde kullanılan hiperparametreler.....	67
Çizelge 6.4. Restoran veri seti için SemEval16-ÖTGM’de Görev 5 için raporlanan çalışmaların öğrenme yöntemleri, metin ön işleme teknikleri, öğrenme modelleri, mikro-f skor metriğinde ölçülen performans sonuçları ve önerilen yaklaşımın denetimli yaklaşımlar arasındaki konumu.	69
Çizelge 6.5. Restoran veri seti için ilgili diğer çalışmaların, öğrenme yöntemleri, metin ön işleme teknikleri, eğitim modelleri, mikro-f skor metriğinde ölçülen performans sonuçları ve önerilen yaklaşımın denetimsiz yaklaşımlar arasındaki konumu.	70
Çizelge 6.6. BERT ve SFT WEM’lerini girdi olarak kullanan CNN ve DNN derin öğrenme tabanlı ACD yaklaşımlarının deneysel çalışmalar sonucu elde edilen ortalama ve maksimum sınıflandırma performansı skorları.	72
Çizelge 6.7. Restoran ve dizüstü bilgisayar incelemeleri için SemEval-ÖTGM 2016 bildiri kitapçığında raporlanan ACD yaklaşımlarının mikro-f metriğine göre ölçülen sınıflandırma performansı sonuçları.	74
Çizelge 6.8. Restoran ve dizüstü bilgisayar incelemeleri üzerinde literatürde sunulan diğer ilgili ACD yaklaşımların WEM’leri, öğrenme modelleri ve f-skor metriğine göre ölçülen sınıflandırma performansı sonuçları.....	76

KISALTMALAR DİZİNİ

ACD	: Aspect Category Detection (Özellik Kategorisi Tespiti)
ADVMOD	: Adverbial modifier (Zarf değiştirici)
AMOD	: Adjectival modifier (Sıfat değiştirici)
API	: Application Programming Interface (Uygulama Programlama Arabirimleri)
ATE	: Aspect Term Extraction (Özellik Terimi Çıkarımı)
BERT	: Bidirectional Encoder Representations from Transformers (Dönüştürücülerden Çift Yönlü Kodlayıcı Temsilleri)
BoW	: Bag-of-words (Kelime torbası)
CNN	: Convolutional Neural Network (Evrışimsel Sinir Ağı)
CRF	: Conditional Random Fields (Koşullu Rastgele Alanlar)
Deprel	: Dependency relation (Bağlılık ilişkisi)
DNN	: Deep Neural Network (Derin Sinir Ağı)
eWOM	: Electronic Word-of-Mouth (Elektronik ağızdan ağıza iletişim)
FN	: False-negative (Yanlış-negatif)
FP	: False-positive (Yanlış-pozitif)
GM	: Görüş Madenciliği
GRU	: Gated Recurrent Unit (Geçitli Tekrarlayan Birim)
HMM	: Hidden Markov Model (Saklı Markov Model)
HTM	: Hierarchical Temporal Memory (Hiyerarşik Geçici Bellek)
IE	: Information Extraction (Bilgi Çıkarımı)
IR	: Information Retrieval (Bilgi Erişimi)
KNN	: k-Nearest Neighbors (k-En Yakın Komşu)
LDA	: Latent Dirichlet Allocation (Gizli Dirichlet Ayırımı)
LSI	: Latent Semantic Indexing (Gizli Anlamsal Dizinleme)
LSTM	: Long Short-Term Memory (Uzun-Kısa Süreli Bellek Ağları)
MLP	: Multilayer perceptron (Çok katmanlı algılayıcı)
MLTC	: Multi-Label Text Classification (Çok Etiketli Metin Sınıflandırması)

MV	: Majority Voting (Çoğunlukla Seçim)
NBCR	: Neural-based Coreference Resolution (Sinir Ağı tabanlı Eşgönderge Çözümlemesi)
NER	: Name Entity Recognition (Varlık İsmi Tanıma)
NLP	: Natural Language Processing (Doğal Dil İşleme)
NMOD	: Nominal modifier (Nominal değiştirici)
NSUBJ	: Nominal subject (Nominal özne)
OBJ	: Object (Nesne)
OBL	: Oblique nominal (Yalın olmayan hal)
OT	: Opinion target expression (Görüş hedefi ifadesi)
OTE	: Opinion Target Extraction (Görüş Hedefi İfadesi Çıkarımı)
OW	: Opinion word (Görüş sözcüğü/ifadesi)
ÖTGM	: Özellik Tabanlı Görüş (Fikir) Madenciliği
PBP	: Pattern-based text pre-processing (Örüntü tabanlı metin ön işleme)
pLSA	: Probabilistic Latent Semantic Analysis (Olasılıksal Gizli Anlamsal Analiz)
PMI	: Pointwise Mutual Information (Noktasal Karşılıklı Bilgi Katsayısı)
POS	: Part-of-speech (Sözcük türü)
ReLU	: Rectified Linear Unit (Doğrultulmuş lineer birim)
REST	: Representational State Transfer (Temsili Durum Aktarımı)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
SA	: Sentiment Analysis (Duygu Analizi)
SDR	: Sparse Distributed Representation (Seyrek Dağıtık Temsil)
SemEval16	: International Workshop on Semantic Evaluation 2016 (Uluslararası Anlamsal Değerlendirme Çalıştayı 2016)
SF	: Semantic Fingerprint (Anlamsal Parmak İzi)
SFT	: Semantic Folding Theory (Anlamsal Katlama Teorisi)
STGSA	: Sözlük Tabanlı Görüş (Fikir) Sözcüğü Analizi
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TF-IDF	: Term Frequency-Inverse Document Frequency (Terim Frekansı-Ters Doküman Frekansı)
TN	: True-negative (Doğru-negatif)
TP	: True-positive (Doğru-pozitif)

- VADER : Valence Aware Dictionary and sEntiment Reasoner (Değerlik Farkındalıklı Sözlük ve Duygu Akıl Yürütücü)
- WEM : Word embedding model (Kelime temsil modeli)
- XML : Extensible Markup Language (Genişletilebilir Biçimlendirme Dili)

BÖLÜM 1

GİRİŞ

Günümüzde artan internet kullanımıyla birlikte, kullanıcılar sosyal medya ve elektronik ticaret platformlarında öznel görüşlerini ve deneyimlerini ifade edebilmektedir [1]. Bu platformlarda kullanıcıların ürünler, hizmetler, kuruluşlar veya çalışanlarla ilgili oluşturdukları yorumlar elektronik ağızdan ağıza iletişim (Electronic Word-of-Mouth, eWOM) kavramını ortaya çıkarmıştır [2]. Bu bağlamda eWOM, potansiyel, mevcut veya eski tüketiciler arasındaki dinamik bilgi alışverişi sürecini ifade etmektedir [3]. eWOM insanlar arası etkileşimde geleneksel ağızdan ağıza iletişime göre daha fazla etki ve erişim yeteneğine sahiptir [4].

eWOM'un bir formu olan çevrimiçi inceleme siteleri elektronik platformlarda ürünlerini pazarlayan işletmelere pazar tabanlarını genişletmek için önemli bir fırsat sunarken [5], tüketicilerin satın alma kararlarını destekleyen büyük bilgi kaynakları haline dönüşmüştür [6]. Bu sebeple tüketiciler, geri bildirim içerikli bu kaynakları kullanarak, bir ürünü ya da hizmeti satın almadan önce olası deneyimler hakkında bilgi edinmek amacıyla başkalarının potansiyel görüşlerini aramaya yönelmektedir [7]. İşletmeler ise, verdikleri hizmetleri iyileştirmek, pazarladıkları ürünlerin müşteriler üzerindeki etkilerini keşfedebilmek için bu bilgi kaynaklarının potansiyel gücünden yararlanmayı amaçlamaktadır [8]. Ancak işletmelerin büyük kullanıcı popülasyonlarıyla karşı karşıya kalmaları [9] ve kullanıcılar tarafından oluşturulan inceleme kaynaklarının hacimsel büyüklüğü düşünüldüğünde [10], verilerin işlenmesinde pratik ve verimli olmayan manuel yaklaşımlar yerine [11] otomatikleştirilmiş yaklaşımlara ihtiyaç duyulmaktadır [12].

Görüş (Fikir) Madenciliği (GM) arařtırmacılar tarafından Doğal Dil İşleme (Natural Language Processing, NLP), Bilişimsel Dilbilim, Metin Madenciliği ve Bilgi Erişimi (IR) gibi bilimsel alanlar altında çalışılmaktadır [13]. Ayrıca GM, endüstrideki uygulanabilirliği açısından bilgisayar bilimleri dışında yönetim bilimleri ve sosyal bilimler alanlarında çalışan birçok arařtırmanın da ilgisini çekmektedir [14].

GM kavramı, veri kaynaklarında ifade edilen görüşlerin, duyguların ve tutumların tespitini, çıkarımını ve sınıflandırılmasını [8,15] ve bu sayede çeşitli seviyelerde analizlerin gerçekleştirilmesini amaçlayan bilişimsel bir metin analizi türüdür [16] [17]. Bu bağlamda GM, insanların ürünler, hizmetler, organizasyonlar, bireyler, problemler, olaylar ve konular hakkında yorumladıkları varlıklara yönelik görüşlerin, duyguların değerlendirmelerin ve tutumların analizlerinin gerçekleştirilmesine olanak sağlamaktadır [14,18,19]. Bu sayede GM, ticari ürünlerin değerlendirilmesi [16], piyasa istihbaratı [20], müşteri memnuniyeti ölçümü [21], film gelir tahminleri [22], hisse senedi tahmini [23], siyasal hareket [24,25] gibi çeşitli daha birçok alanda kamuoyu gözlemlerine ve karar verme süreçlerine yardımcı olmaktadır [8,15]. Yapısal olarak güçlü bir GM sistemi anketlere duyulan ihtiyacı ortadan kaldırabilir ve geleneksel pazar arařtırmalarının yapıma şeklini değiştirebilmektedir [26].

GM stratejilerinde, büyük hacimli yapılandırılmış ve/veya yapılandırılmamış veriler kullanılarak dönüşüm, çıkarım, sınıflandırma ve analiz gibi görevlerin yürütülmesi Veri Madenciliği, Web Madenciliği ve Metin Madenciliği tekniklerinin kombinasyonlarıyla otomatikleştirilmiş yaklaşımlarla gerçekleştirilmektedir [8,27]. Bu sayede GM stratejileri, duygu yönelimi (polarite) belirleme ve polarite tabanlı sınıflandırma [28], öznellik sınıflandırması [29], görüş özetleme [30], doküman/cümle [31,32] ve özellik tabanlı [14,33,34] seviyelerde çıkarım yapma ve ayrıca özellik kategorisi tespiti [12,35] gibi spesifik alt görevlerin gerçekleştirilmesine olanak sağlamaktadır [36].

GM stratejileri, temel olarak doküman, cümle, özellik ve konsept seviyelerinde ele alınmaktadır [37,38]. Doküman ve cümle seviyesi stratejileri, genel polarite destekli hesaplamaları hedeflediğinden, metnin konusunun kullanıcılar tarafından nasıl değerlendirildiğini ölçmeyi mümkün kılamamaktadır [33]. Özellik seviyesi (varlık ve

özellik) stratejilerinde ise, dokümanı genel polarite üzerinden ilişkilendirmekten daha karmaşık bir süreç söz konusudur. Özellik seviyesi, öznel içeriğe sahip inceleme metinlerinde yorumlanan varlığın özelliklerini niteleyen polaritelerin bağımsız olarak bulunma potansiyeli düşünüldüğünde, daha gerçekçi ve ayrıntılı analizlere imkan sağlayan yaklaşımlar sunmaktadır [39]. Konsept seviyesinde ise, bir varlığın tamamıyla ilişkili ayrı ayrı görüşler toplamak yerine, farklı varlıkların belirli özellik ya da alt özelliklerinin karşılaştırmalı analizleriyle, semantik olarak görüşlerin ve ilgili duygusal yönelimlerin değerlendirilmesi amaçlanmaktadır. Bu sayede konsept seviyesinde, özellik tabanlı görüşsel analizler daha detaylı olarak gerçekleştirilebilmektedir [40,41].

Bu tez çalışmasında, Özellik Tabanlı Görüş Madenciliği (ÖTGM)'nde yer alan Görüş Hedefi İfadesi Çıkarımı (Opinion Target Extraction, OTE) ve Özellik Kategorisi Tespiti (Aspect Category Detection, ACD) görevlerinin gerçekleştirilmesine yönelik yaklaşımlar önerilmektedir. OTE yaklaşımıyla, inceleme metinlerinde yorumlanan varlık özelliklerine ilişkin açık ifadelerin denetimsiz (kural tabanlı) yaklaşımlarla çıkarılması gerçekleştirilmiştir. Önerilen OTE yaklaşımında ilk olarak, yapılandırılmamış girdi metinleri üzerinde, geleneksel NLP ön işleme teknikleri (etkisiz kelimeleri kaldırma, gövdeleme, kök çözümleme gibi) yerine, örüntü tabanlı metin ön işleme (pattern-based text pre-processing, PBP) yöntemi geliştirilerek çıkarım performansı iyileştirilmiştir. Geliştirilen PBP yöntemiyle, girdi metinlerinde anlam ve yapının korunabilmesi amacıyla sadece dilbilgisel tamlama kurallarına uygun olmayan noktalama işaretlerinin kaldırılması sağlanmıştır. Daha sonra bağıklık ayrıştırıcısı çıktıları-grafı üzerinde, sözdizimsel tabanlı ilişki kuralları uygulanarak, görüş sözcüğü (opinion word, OW) ve görüş hedefi (opinion target, OT) çıkarımları gerçekleştirilmiştir. Uygulanan sözdizimsel tabanlı ilişki kuralları doğru ve çok kelimeli ifadeleri yakalamak için yeni bileşenlerle genişletilmiştir. Ayrıca, girdi metinlerinde aynı referansa sahip kelimeleri tespit etmek için, diğer eşgönderge çözümleme modellerine göre daha yüksek bir performans gösteren Sinir Ağı Tabanlı Eşgönderge Çözümlemesi (Neural-based Coreference Resolution, NBCR) modeli kullanılmıştır. Böylece çözümleyici çıktılarıyla çıkarılan OT'ler birleştirilerek, birbirleri yerine yazılabilecek doğru ifadeler belirlenmiştir. Son olarak, model çıktılarında Çoğunlukla Seçim (Majority Voting, MV) yöntemi uygulanarak, çıktılarının

birleřtirilmesi sađlanmıř ve bu sayede önerilen OTE yaklaşımı üzerinde performans optimizasyonu gerçekleştirilmiştir. Gerçekleştirilen deneysel çalışmaların sonuçları, çalışmanın etkinliğini ve geliştirilen yöntemlerin OTE performansına katkıda bulunduđunu göstermiştir.

Önerilen ACD yaklaşımlarıyla, derin öğrenme tabanlı çok etiketli metin sınıflandırma (Multi-Label Text Classification, MLTC) teknikleri kullanılarak, inceleme metinlerinde öznel bir biçimde yorumlanan varlıklara ilişkin alana özgü ve global nitelikli belirli özellik kategorilerinin tespiti gerçekleştirilmiştir. Bu yaklaşımlarda, önceden eğitilmiş Dönüřtürücülerden Çift Yönlü Kodlayıcı Temsilleri (Bidirectional Encoder Representations from Transformers, BERT) ve Anlamsal Katlama Teorisi (Semantic Folding Theory, SFT) kelime temsil modellerinin (word embedding model, WEM) çıktılarını ayrı ayrı girdi olarak kullanan Evriřimsel Sinir Ađı (Convolutional Neural Network, CNN) ve Derin Sinir Ađı (Deep Neural Network, DNN) modelleri kullanılmıştır. Önerilen ACD yaklaşımlarına (BERT+DNN, BERT+CNN, SFT+DNN, SFT+CNN) ilişkin deneysel çalışmaların sonuçları, yaklaşımların etkinliğini ve uygulanan WEM'lerin sınıflandırma performansına katkı sağladığını göstermiştir.

Bu tez çalışmasında yer alan deneysel çalışmalar, 2016 yılında düzenlenen Uluslararası Anlamsal Deđerlendirme Sempozyumu'nda (International Workshop on Semantic Evaluation 2016, SemEval16) ÖTGM görevleri için hazırlanmış, bilgisayar ve restoran incelemelerini içeren toplamda 4500 inceleme cümlesine ve özelleřtirilmiş etiketlere sahip açık erişimli, zengin veri setleri [42] üzerinde gerçekleştirilmiştir.

1.1. TEZİN AMACI

Bu tez çalışmasının genel amacı, ÖTGM'nin önemli görevleri arasında yer alan OTE ve ACD görevlerini yeni yaklaşımlarla gerçekleřtirmek ve bu yaklaşımlarda uygulanan yöntemlerin etkinliklerini deneysel çalışmalarla test ederek deđerlendirmektir. Geliřtirilen OTE ve ACD yaklaşımlarının teorik ve pratik açıdan özel amaçları ise bu bölüm içerisinde ayrı ayrı başlıklar altında detaylandırılmaktadır.

1.1.1. Teorik Açıdan Önerilen Yaklaşımların Özel Amaçları

Önerilen OTE yaklaşımının teorik açıdan özel amacı: Mevcut yaklaşımların sınırlılıklarını ele alarak, denetimsiz tekniklerle özellik ifadelerinin daha etkin bir şekilde çıkarılması ve bu yaklaşımda uygulanan PBP yönteminin, genişletilmiş sözdizimsel tabanlı bağlılık ilişki kurallarının ve MV yönteminin çıkarım performanslarına olan katkılarının değerlendirilmesidir.

Önerilen ACD yaklaşımlarının teorik açıdan özel amacı: çoklu ve hiyerarşik yapıda etiketlenmiş inceleme metinleri üzerinde, önceden eğitilmiş WEM'leri girdi olarak kullanan derin öğrenme modelleriyle inceleme metinlerinin sınıflandırılması ve uygulanan WEM'lerin sınıflandırma performanslarına olan katkılarının değerlendirilmesidir.

1.1.2. Pratik Açıdan Önerilen Yaklaşımların Özel Amaçları

Önerilen OTE yaklaşımının pratik açıdan özel amacı: İşletmelere ve araştırmacılara inceleme metinlerini analiz etme ve tüketicilerin satın alma tercihlerini etkileyen ürün özelliklerini etkin bir şekilde belirleme ve keşfetme imkânının sağlanmasıdır.

Önerilen ACD yaklaşımlarının pratik açıdan özel amacı: Sınırlı raporlama imkânı sunan geleneksel sınıflandırma yaklaşımları yerine, girdilerinde son teknoloji ve önceden eğitilmiş WEM'lerin uygulandığı derin öğrenme tabanlı modeller kullanılarak; özellikle pazarlama yöneticilerinin tüketicilerin satın alma tercihlerini etkileyen global ürün kategorilerini tespit edebilmeleri için detaylı ve etkin çıktıların üretilmesi ve bu sayede inceleme kaynaklarının potansiyel gücünden yararlanma imkânının sağlanmasıdır.

1.2. TEZİN KATKILARI

Bu bölümde, tez çalışmasının katkılarının detaylandırılması amacıyla önerilen OTE ve ACD yaklaşımlarının katkıları ayrı başlıklar altında maddeler halinde sunulmaktadır.

1.2.1. Önerilen OTE yaklaşımının katkıları

1. OTE çıktı performansını iyileştirmek amacıyla, ÖTGM görevlerinde uygulanabilir özgün bir metin ön işleme yöntemi (PBP) geliştirilmiştir. Geliştirilen PBP yöntemiyle, el yordamı mühendislik gerektiren ve geleneksel NLP metin ön işleme teknikleri yerine, bağlılık ayrıştırma grafi üzerinde yürütülen örüntü kurallarıyla, yalnızca dilbilgisel tamlama kurallarına uygun olmayan noktalama işaretlerinin kaldırılması sağlanmıştır. Bu sayede cümlelerin anlamına, yapısına ve analizine etki edebilecek orijinal noktalama işaretlerine ve etkisiz kelimelere (stopwords) dokunulmamıştır.
2. Çok kelimeli ifadeleri çıkarabilen etkin bir özellik çıkarımı algoritması geliştirmek amacıyla OTE’de uygulanan mevcut sözdizimsel tabanlı bağlılık ilişki kurallarına yeni yardımcı ilişki bileşenler entegre edilerek ilişki kural tabanı genişletilmiştir.
3. Model çıktılarının Kolektif Öğrenme (Ensemble Learning) stratejilerinden biri olan MV yöntemiyle birleştirilmesiyle çıktı performansında optimizasyon gerçekleştirilmiştir.

1.2.2. Önerilen ACD yaklaşımlarının katkıları

1. Çoklu ve hiyerarşik yapıda özellik kategorileriyle etiketlenmiş inceleme metinlerinin sınıflandırılması, bağlama dayalı zengin temsil vektörleri oluşturabilen önceden eğitilmiş WEM’lerin girdi olarak kullanan CNN ve DNN tabanlı ACD yaklaşımlarıyla gerçekleştirilmiştir.
2. Hiyerarşik Geçici Bellek (Hierarchical Temporal Memory, HTM) modeli tabanlı bir WEM olan SFT’nin ACD performansına olan katkısı literatürde ilk kez değerlendirilmiştir.
3. BERT ve SFT WEM’lerin ACD performansına olan katkıları birlikte değerlendirmesi literatürde ilkler arasında yer almaktadır.

1.3. TEZİN ORGANİZASYONU

Bu tez çalışmasının organizasyonu genel itibariyle; Giriş, Literatür Araştırması, Görüş Madenciliği, Görüş Hedefi Çıkarımı (OTE), Özellik Kategorisi Tespiti (ACD), Deneysel Çalışmalar ve son olarak da Bulgular ve Sonuçlar olmak üzere yedi ana bölümden oluşmaktadır.

Tez çalışmasının ilk bölümünde önerilen yaklaşımları ve önemini özetleyen bilgiler, tez çalışmasının amaçları ve katkılarıyla birlikte “Giriş” başlığı altında sunulmaktadır. Tez çalışmasının ikinci bölümü literatür araştırmasına ayrılmıştır. Tez çalışmasının üçüncü bölümünde, GM’ ye ilişkin terminoloji, problem tanımları, ön aşamalar ve görevler detaylandırılmaktadır. Tez çalışmasının dördüncü bölümünde, önerilen OTE yaklaşımının genel mimarisi ve metodolojisi sunulmaktadır. Beşinci bölümde; önerilen ACD yaklaşımlarına ilişkin genel mimari ve metodoloji sunulmaktadır. Tez çalışmasının altıncı bölümünde, gerçekleştirilen deneysel çalışmaların temelini oluşturan veri setleri, performans metrikleri, kullanılan görüş sözlükleri ve derin öğrenme modellerinin eğitiminde kullanılan hiperparametrelere ilişkin deneysel ortam bilgileri Deneysel Çalışmalar bölümü altında verilmektedir. Ayrıca “Deneysel Çalışmalar” bölümünde, önerilen OTE ve ACD yaklaşımlarıyla gerçekleştirilen deneysel çalışmalardan elde edilen sonuçların performans değerlendirilmesi ve önerilen yaklaşımların literatürdeki diğer çalışmalarla kıyaslanma sonuçları da sunulmaktadır. Bu tez çalışmasının son bölümünde, deneysel çalışmalardan elde edilen tüm bulgular ve sonuçlar teorik ve pratik açılarından değerlendirilmiş ve çalışmanın amacına uygun bir biçimde yorumlanarak tez çalışması sonuçlandırılmıştır.

BÖLÜM 2

LİTERATÜR ARAŞTIRMASI

GM, genel olarak “doküman”, “cümle” ve “varlık ve özellik” tabanlı seviyelerde çalışılmaktadır [14,43]. Doküman [32,44] ve cümle tabanlı [45,46] seviyelerde işlevsel olarak yararlı sonuçlar elde edilse de, metinler içerisinde yorumlanan varlığa ilişkin bağımsız görüşler dikkate alındığında, varlıkların nitelenen özelliklerini elde etmek için daha hassas analiz imkanı sağlayan varlık ve özellik seviyesi yaklaşımlarına (ÖTGM) başvurulmaktadır [8,36,47,48]. ÖTGM yaklaşımlarıyla, metinlerdeki öznel bilgilerin tanımlanması, çıkarılması ve çıkarılan bilgilerin polarite temelinde zekice sınıflandırması ve böylece çeşitli seviyelerde özellik tabanlı analizlerin gerçekleştirilmesi amaçlanmaktadır [16]. Literatürde ÖTGM ile ilgili çalışmalar, OTE ve Özellik Terimi Çıkarımı (ATE) [10,11,33,49,50], görüş sözlüğü analizi [36], ACD [12,35], polarite belirleme [28] ve sınıflandırma [51] gibi önemli alt görevlere odaklanmaktadır.

ATE ve OTE, ÖTGM’de ayrıntılı analizlerin ve yöntemlerin uygulandığı önemli görevleri tanımlamaktadır [42]. ATE göreviyle, metinlerde varlıklardan ziyade varlık özellikleriyle ilgili terimlerin tanımlanması amaçlanırken, OTE ile esas olarak varlıkları niteleyen açık ifadelerin çıkarımı gerçekleştirilmektedir [50]. Literatürde OTE amacıyla denetimli, denetimsiz ve yarı denetimli yaklaşımlara yer verilmektedir [36]. Bu yaklaşımlarda; kural tabanlı [1,33,52], Makine Öğrenimi [53,54], Derin Öğrenme [43,55,56,57] ve hibrit [11,50] modeller uygulanmaktadır.

OTE ile ilgili ilk çalışmalarda, bağlılık ilişkisi tabanlı çıkarımların ya da dizgelerin sözcük türü (Part-of-speech, POS) frekanslarını kullanan yaklaşımlar önerilmektedir [58,59,60]. Ancak bu yaklaşımlar, sık geçmeyen ve değerli özellik terimlerinin tespitinde bazı sınırlamalara sebep olabilmektedir. OTE için Makine Öğrenmesi modellerinin uygulandığı denetimli ilk yaklaşımlarda ise, girişinde sıralı etiketlemeyle

oluşturulmuş verileri kullanan Koşullu Rastgele Alanlar (Conditional Random Fields, CRF) [61], Saklı Markov Model (Hidden Markov Model, HMM) [62], Destek Vektör Makinesi (Support Vector Machine, SVM) [53] tabanlı modeller önerilmektedir [18]. Bu denetimli yaklaşımlar geleneksel ve kural tabanlı sistemlere göre daha iyi performans sunabilmektedir [50]. Ancak HMM’de her kelimenin bağlamdan bağımsız bir varsayımla ele alınması çıkarımlarda ve özelliklerin temsilinde sınırlılıklara sebep olmaktadır [18]. Bu nedenle araştırmacılar özellik çıkarımı başarısını arttırabilmek için HMM’den daha yetenekli sahip CRF’ye yönelmektedir. Doğrusal bir model olan CRF’nin performansı ise, büyük eğitim verilerine ve dilbilimsel ve spesifik özelliklerin çıkarımlarına bağlıdır [11,55]. Literatürde CRF yaklaşımına, Uzun-Kısa Süreli Bellek Ağları (Long Short-Term Memory, LSTM) ve Çift yönlü LSTM ve Tekrarlayan Sinir Ağı (Recurrent Neural Network, RNN) gibi modellerin entegrasyonunun OTE performansına katkı sağladığı belirtilmektedir [63]. Ayrıca literatürde, istatistiksel, Maksimum Entropi ve Gizli Dirichlet Ayırımı (Latent Dirichlet Allocation, LDA) destekli model tabanlı yarı denetimli yaklaşımlara da yer verilmektedir [64,65]. OTE görevlerinde CNN [55,66,67] ve RNN [53,68] gibi derin öğrenme yaklaşımları başarılı bir şekilde uygulanmaktadır [43]. Bu yaklaşımlara dil bilimsel kural tabanlı yöntemler de entegre edilebilmektedir [55]. RNN, CNN modeline göre daha esnek ve hafızalı yapıya sahiptir ve bu sayede bağlamsal bilgileri daha performanslı bir şekilde yakalayabilmektedir [11,43]. RNN, girdilerin yapılandırılmamış özelliklerini göz ardı etmeden, rastgele boyutlandırılmış sıralı girdilerin sabit boyutlu girdilerle temsilini gerçekleştirir [69,70]. Özellikle LSTM [71] ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit, GRU) [72] gibi RNN mimarileri, sıralı girdilerdeki istatistiksel yapıları yakalayabilme yetenekleri sayesinde NLP çalışmalarına yüksek performanslı bir katkı sağlamaktadır [70].

ÖTGM’nin ilk denetimsiz yaklaşımları arasında yer alan Minqing Hu ve arkadaşlarının çalışmasında, isim nitelikli kelimeler potansiyel özellikler olarak ele alınmıştır ve her özelliğin frekans değerleri hesaplanmıştır [58]. Söz konusu çalışmada, özelliklerin çıkarılması için her bir ismin cümledeki konumu dikkate alınmadan sık kullanılan isim öbekleri üreten birliktelik kuralları yaklaşımına ve özellik budama yöntemlerine yer verilmektedir. Daha sonraki çalışmalarda, çıkarım performansı yükseltmek amacıyla, kelimelerin frekanslarını hesaplayarak budama

yapmak yerine Noktasal Karşılıklı Bilgi Katsayısı (Pointwise Mutual Information, PMI) skorları kullanılmıştır [73,74].

Literatürdeki kural tabanlı yaklaşımlar, tek başına veya diğer yaklaşımlara entegrasyonundaki başarısıyla OTE görevlerinde tamamlayıcı ve önemli bir görev üstlenmektedir [31,33,52]. Bu yaklaşımlarda, özellik ve görüş terimleri arasındaki ilişkileri keşfetmek için bağlılık ayrıştırması tabanlı yöntemlere yer verilmektedir [1] [75]. Bağlılık ayrıştırmasının görevi, cümledeki farklı kelimeler arasındaki ilişkileri temsil eden bir graf üretmektedir [36]. Üretilen bu graf sayesinde, görüş sözcükleri ile özellikler arasındaki ilişkiler incelenebilmektedir [33,76,77]. Literatürdeki bağlılık ayrıştırması analizlerinin çoğunda isimler/isim tamlamaları bir cümledeki potansiyel OT'ler olarak değerlendirilmektedir [11,43,75]. OT'leri niteleyen öznel görüş sözcüklerinin çıkarımında ise Sözlük Tabanlı Görüş (Fikir) Sözcüğü Analizi (STGSA)'ne başvurulmaktadır. OT'leri niteleyen görüş sözcüklerinin polaritelerin hesaplanması veya duygu durumlarının olumlu, olumsuz veya nötr olarak sınıflandırılması STGSA aşamasının görevidir [1,14]. Literatürde STGSA aşamasında, sözlük tabanlı [33,78] ve külliyat tabanlı yaklaşımlar [79,80] sunulmaktadır [14].

ACD görevlerinde ise, inceleme metinlerinde yorumlanan varlıklar ve ilişkili yönlerini temsil eden niteliklerle belirlenen açık veya örtülü kategorilere göre metinlerin sınıflandırılması amaçlanmaktadır [35]. Metin sınıflandırmalarında kategoriler birbirini dışlayan ya da dışlamayan yapılarda karşımıza çıkmaktadır. Birbirini dışlamayan yapıda olan sınıflandırmalar MLTC olarak adlandırılmaktadır [81]. MLTC, geleneksel çok sınıflı sınıflandırmanın devamıdır [82]. MLTC problemlerinin çözümünde, k-En Yakın Komşu (k-Nearest Neighbors, KNN), Algılayıcılar (Perceptrons), Rank-SVM, Naive Bayes, Kolektif Öğrenme ve Lojistik Regresyon gibi makine öğrenimi sınıflandırıcı modellerinin varyasyonlarına başvurulmaktadır [83,84]. İleri seviyelerde ise Çok Katmanlı Algılayıcı (Multilayer perceptron, MLP), RNN [85], CNN [86,87] ve hibrit (RNN, CNN, vb.) [88,89] gibi çeşitli derin öğrenme yaklaşımları kullanılmaktadır.

BÖLÜM 3

GÖRÜŞ MADENCİLİĞİ

İnternet, web kullanıcılarını ortak küresel ortamlara katılmalarına, kullanıcıların çevrimiçi web içerikleri oluşturmasına ve bu içeriklerin erişilebilir olmasına olanak sağlarken [90], kişisel deneyimlerini ve görüşlerini çevrimiçi platformlarda (elektronik ticaret, forum ve blog gibi.) kolayca ifade edebilen kullanıcılar geri bildirimleriyle büyük metinsel veri kaynaklarının oluşmasına sebep olmuştur [10]. Ayrıca günümüzde endüstrilerin dijital dönüşüme yönelik eğilimleri, bu verilerin hacminin yanı sıra kalitesini de arttırmıştır [91]. Ancak bu verilerden yararlı bilgilerin çıkarılması ve manuel analizlerdeki verimsizlik ve zorluklar araştırmacıları otomatikleştirilmiş yaklaşımlara yöneltmiştir [92]. Bu sebeple bahsedilen problemlerin üstesinden gelebilmek için; metinsel veri kaynaklarından yararlı bilgilerin otomatik olarak çıkarmak ve kullanıcı görüşlerinin, değerlendirmelerinin ve tutumlarının ayrıntılı analizlerini gerçekleştirmek amacıyla NLP'nin aktif araştırma alanları arasında yer GM yaklaşımlarına başvurulmaktadır [14].

GM, Veri Madenciliği, Web Madenciliği, Metin Madenciliği ve IR araştırma alanlarında da geniş çapta çalışılmaktadır [14,16,30]. Ayrıca GM, Metin Madenciliği tekniklerinin kullanıldığı web içerik madenciliğinin bir alt kümesi olarak da kabul edilmektedir [16]. Şekil 3.1'de GM'nin araştırma alanları arasındaki konumu gösterilmektedir [16,93].



Şekil 3.1. GM'nin mevcut araştırma alanları arasındaki konumu.

GM ile ilgili araştırmalar 2000'li yılların başlarından itibaren literatürde yer almaktadır, ancak “görüş madenciliği” tabiri ilk kez 2003 yılında Dave ve ark. [94] tarafından kullanılmıştır [14,16]. Literatürde GM, duygu analizi [95], görüş çıkarımı, öznellik analizi [15,96], etki analizi, duygu analizi [97] ve inceleme madenciliği [98] gibi birçok isimlendirme varyasyonunu ve çeşitli alt görevleri içeren büyük bir problem alanını temsil etmektedir [14]. Özellikle GM ile Duygu Analizi (SA) kavramları çoğu araştırmacı tarafından literatürde benzer amaçlar için kullanılsa da bazı araştırmacılar bu kavramları birbirlerinden işlevsel olarak ayrılabilirler [14,99]. SA, bir metinde görüş sahibinin tutumuna ilişkin polaritelerin çıkarılmasına yönelik analizleri veya sınıflandırılmaları ele alırken [100], GM ise bilgi erişimine, metinlerde yorumlanan varlıklara ilişkin görüşlerin çeşitli seviyelerde detaylı analizine imkân sağlamaktadır [90].

3.1. GÖRÜŞ MADENCİLİĞİ TERMINOLOJİSİ

Görüş Kavramı: Bu kavram, belirli bir ürün veya hizmetlerle ilgili duyguların veya gerçeklerin yorumlanmasının öznel sonucudur ve bu tez çalışmasında bu kavram pazarlama araştırmasının bir parçası olarak ele alınmaktadır. Genel olarak görüşlere yönelik araştırmalar, anketlere dayalı veri toplama ile başlamıştır. Daha sonra geleneksel nitel ve nicel yöntemlerle bu veriler analiz edilmektedir [101]. Ancak

görüşleri bir bütün olarak ele almak için, sınırlı erişilebilirliğe sahip özel veya özne topluluk görüşlerinin kullanılması; veri toplama için gereken zaman, oluşabilecek yüksek maliyetler, veri miktarlarındaki kısıtlar ve bulguların temsil yeteneğindeki sınırlılıklar, çıkarımlarda güvenilirlik ve doğruluk sorunlarına daha fazla yol açmaktadır [102,103]. Bu sebeplerle, son yıllarda görüşlerin kolayca paylaşıldığı çevrimiçi platformlar, araştırmacılara, işletmelere ve kurumlara, veri seti sağlama, örneklem boyutunu genişletme, maliyetleri azaltma ve hızlı veri toplama gibi olumlu katkılar sunmaktadır [103]. Yukarıda belirtilen pozitif katkılar sayesinde, veri toplama sürecinde veri kaynağı olarak sosyal medya ve elektronik ticaret gibi çevrimiçi platformları kullanmak, metodolojik sınırlamaları azaltabilmektedir [103,104].

İnceleme Kavramı: Bu kavram, çevrimiçi pazarlama platformlarında veya sosyal medyada bir öğeyle ilgili olarak gözden geçirenin görüşlerini ya da deneyimlerini açıklayan metinsel ifadelerdir. Bu ifadeler ürün, hizmet, marka veya şirket hakkında büyük bir bilgi potansiyeline sahip eWOM'u oluşturmaktadır. eWOM'u analiz etmek ve ölçmek, şirketlere ve tüketicilere karar almalarında yardımcı olma niteliği taşıması açısından oldukça değerlidir [105].

Öznel ve nesnel metin: GM'de metinler; duyguya, kişisel görüşe veya değerlendirme içeriğine sahip öznel (olumlu veya olumsuz) metinler ve duygu içermeyen gerçek bilgilerle oluşturulmuş nesnel (nötr) metinler şeklinde sınıflandırılmaktadır [96].

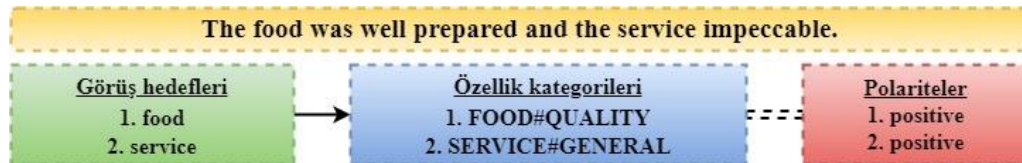
Görüş sözcükleri: GM'nin temel bir yapıtaşı olan görüş ya da duygu sözcükleri olumlu veya olumsuz polariteleri taşıyan ifadelerdir. Bu sözcüklerin çoğu sıfatlar ve zarflardır, ancak isimler ve fiiller duyguları ifade etmek için de kullanılabilir [14,18]. Olumlu görüş sözcükleri istenen durum ya da nitelikleri, olumsuz görüş sözcükleri ise istenmeyen durum veya nitelikleri temsil etmektedir.

Varlık (entity) Kavramı: Bu kavram, tipik bir GM'de genellikle ürünleri veya markaları temsil etmektedir. Bu sebeple GM, bu varlıklar hakkındaki görüşlerin çıkarılmasını amaçlamaktadır. Ancak incelemelerde aynı varlığı kullanıcılar birçok farklı şekilde ifade edebildiği düşünüldüğünde, GM sisteminin varlıkları derlemlerden (incelemeler, bloglar ve forumlar gibi) otomatik olarak keşfetmesi önemlidir [14].

GM’de varlık çıkarımı bir Varlık İsmi Tanıma (Name Entity Recognition, NER) problemidir [106]. NER işlevi, bilgi çıkarma başlığı altında NLP ve Metin Madenciliği alanlarında çalışılmaktadır [107].

Görüş Hedefi/Özellik Kavramı: Bu kavram (aspect), metinlerde yorumlanan bir varlığın öznel görüşlerle yorumlanan yönlerini ifade etmektedir [55]. Bu yönler, inceleme cümlelerinde tekil ya da bağımsız polaritelere sahip görüş sözcükleriyle nitelenmektedir [39]. ÖTGM’de görüş hedefleri ya da özellikler açık (explicit) ve örtülü (implicit) olmak üzere ikiye ayrılmaktadır [16]. Açık görüş hedefleri, cümlede nitelenen varlığa ilişkin bir yönün açık ifadesini (OT [75]) temsil etmektedir [10]. Bu bağlamda metinlerde isimler/isim tamlamaları herhangi bir cümledeki potansiyel açık görüş hedefleri olarak ele alınabilmektedir [11,75]. Örtülü özelliklerde ise, görüş hedeflerini temsil eden terimler açıkça işaretlenememekte kullanıcılar tarafından sadece ima yoluyla atıfta bulunmaktadır [108].

Özellik kategorisi: İnceleme cümleleri üzerinde otomatik görüş hedefi çıkarımı yanı sıra kategorilerinin belirlenmesi de önemli bir ÖTGM görevidir [43]. Özellik kategorisi kavramı, nitelenen varlıkların açık veya örtülü yönlerini global nitelikte temsil eden kategori ya da kategori kombinasyonlarını ifade etmektedir [35]. Şekil 3.2’de sunulan örnek bir inceleme cümlesi üzerinde; görüş hedefi ifadeleri, özellik kategorileri (çoklu ve hiyerarşik formda) ve görüş hedeflerini niteleyen polaritelere ilişkin çıkarımlar sunulmaktadır.



Şekil 3.2. İnceleme cümlesi üzerinde görüş hedefleri, özellik kategorileri ve polarite çıkarımları.

Görüş sözlükleri: Görüş sözcüklerinin veya ifadelerinin bir listesi (kelime veya kelime öbeği topluluğu) görüş sözlüğü olarak adlandırılmaktadır [109]. Çoğu GM uygulamasında, görüş sözcüklerinin polarite çıkarımlarını elde edebilmek için görüş sözlüklerine başvurulmaktadır. Polarite çıkarımlarında söz konusu sözlükler

yardımıyla görüş sözcüklerinin polarite değerleri belirlenebilmektedir [28]. Polarite değerleri, sözlüğün genişliğine ve kapasitesine bağlı olarak belirli kategorilerde (pozitif, negatif, nötr) veya normalleştirilmiş sayısal aralıkta üretilebilmektedir. Polarite değerlerinin elde edilmesinde yaygın olarak; SentiWordNet [48], SenticNet [110], TextBlob [111] ve Değerlik Farkındalıklı Sözlük ve Duygu Akıl Yürütücü (Valence Aware Dictionary and sEntiment Reasoner, VADER) [112,113] gibi nitelikli görüş sözlükleri kullanılmaktadır.

Sözcük türü (Part-of-speech, POS) işaretleme: POS, bir kelimenin sözdizimsel veya morfolojik davranışı ile tanımlanan dilsel kategorileri ifade etmektedir. POS etiketleme ise, NLP'nin önemli görevleri arasında yer almaktadır. Bu görevde, cümledeki dizgelerin doğru POS kategorileriyle etiketlenmesi amaçlanmaktadır [114]. Dilbilgisel olarak POS etiketleri, isim (noun), özel isim (proprn), sıfat (adj), fiil (verb) ve zarf (adv) gibi açık özellikli etiketlerden oluşmaktadır [115]. Ancak dizgelerin kapalı özellikli bir şekilde etiketlenmesi de mümkündür. Çizelge 3.1'de POS etiketleyici çıktılarında kullanılan evrensel açık ve kapalı etiketler sunulmaktadır [116,117].

Çizelge 3.1. Evrensel nitelikli açık ve kapalı POS etiketleri.

Evrensel POS etiketleri					
Kısaltma	Açılım		Kısaltma	Açılım	
ADJ	adjective	sıfat	*NUM	numeral	sayısal
*ADP	adposition (preposition/postposition)	edat	*PART	particle	ek
ADV	adverb	zarf	*PRON	pronoun	zamir
*AUX	auxiliary	yardımcı	PROPN	proper noun	özel isim
*CCONJ	coordinating conjunction	koordine edici bağlaç	*PUNCT	punctuation	noktalama
*DET	determiner	belirleyici	*SCONJ	subordinating conjunction	yantümce bağlacı
INTJ	interjection	ünlem	*SYM	symbol	simge
NOUN	noun	isim	VERB	verb	yüklem

*Kapalı özellikli POS etiketleri

POS etiketleyi geliřtirmek NLP'nin önemli bir araştırma alanıdır ve bu sebeple birçok dil ve yazılım platformu için POS etiketleme araçları geliřtirilmiřtir. Bu bağlamda POS etiketleme görevlerinde, Stanza [118], spaCy, NLTK [119], Flair [120] ve UDPipe [121] gibi etiketleyiciler arařtırmacılar tarafından yaygın olarak kullanılmaktadır [122].

Baęlılık Ayırırması (Dependency Parsing) : Baęlılık ayırırması, cümlelerin dilbilgisel yapıları bakımından analizlerinin gerçekteřirilebilmesi amacıyla, cümle bileřenleri arasındaki iliřkileri temsil eden nitelikli ve yönlü bir grafi oluřturma görevini ifade etmektedir [36]. Bu bağlamda baęlılık iliřkileri, bir yönetici (governor, superior, regent) ile bir baęımlı (modifier, inferior, subordinate) argümanlarına sahip bileřenler arasındaki ikili dilbilgisel iliřkileri temsil etmektedir. Őekil 3.3'te yönetici ve baęımlı arasındaki birebir baęlılık iliřkisi temsili sunulmaktadır.



Őekil 3.3. Yönetici ve baęımlı arasındaki birebir baęlılık iliřkisi temsili

Baęlılık iliřkilerinde, yönetici bir isim cümlesindeki birincil isim veya bir fiil cümlesindeki fiili temsil edebilirken, bileřende kalan dięer kelimeler ya doğrudan ya da dolaylı olarak yöneticinin baęımlılarıdır [123]. Çizelge 3.2'de ise baęlılık iliřkilerinde tanımlanmış evrensel iliřki tiplerinin bir listesi sunulmaktadır [124].

Çizelge 3.2. Evrensel bağıllık ilişki tipleri.

Cümle Tabanlı İlişki Tipleri	Açıklama	Nominal Değiştirici Nitelikli İlişki Tipleri	Açıklama	Diğer İlişki Tipleri
NSUBJ (Nominal subject)	Nominal özne	NMOD (Nominal modifier):	Nominal değiştirici	CONJ (Conjunct) Bir düzenleyici bağlaçla bağlanan iki öge arasındaki ilişki
DOBJ (Direct object)	Fiilin Doğrudan nesnesi	AMOD (Adjectival modifier):	Sıfat değiştirici	Compound Birleşik kelimeler
IOBJ (Indirect object)	Fiilin dolaylı nesnesi	NUMMOD (Numeric modifier)	Sayısal değiştirici	
CCOMP (Clausal complement)	Cümlesel tamamlayıcı	APPOS (Appositional modifier)	Yanyana isim değiştirici	
XCOMP (Open clausal complement)	Açık cümlesel tamamlayıcı	DET (Determiner)	Belirleyici	
		CASE	Edatlar (prepositions, postpositions) ve diğer durum belirteçleri	
*Nominal: dilbilimsel form				

3.2. GÖRÜŞ MADENCİLİĞİ PROBLEM TANIMI

GM problemi, verilen bir cümle (d) üzerinde, varlık (e), özellik (a), polarite (s), görüş sahibi (h) ve zaman (t) bileşenlerinin çıkarılmasını ifade etmektedir. GM problemlerinin çözümünde başvurulan görevler her doküman için tanımlanan “ $e_i, a_{ij}, s_{ijkl}, h_k, t_l$ ” şeklindeki beşli bileşenlerin çıkarımlarından türetilmiştir [14,30]. Ancak farklı senaryolarda tüm bileşenlerin çıkarımına gerek duyulmaz. Örneğin, üçüncü bileşen doküman seviyesi için yeterliken, ayrıntılı seviyelerdeki analizlerde ise daha fazla bileşenin çıkarılması gerekmektedir [30]. Beşli bileşenlerin ilki varlıktır ve varlık çıkarımı NER ile gerçekleştirilmektedir. NER’deki zorluk aynı varlıkların kullanıcılar tarafından farklı şekillerde isimlendirilmesidir. Varlığa ilişkin diğer bir problem tanımları ise varlık kategorileri ve varlık ifadeleri ile varlık özellik kategorileri ve özellik ifadeleridir [14].

Varlık kategorisi benzersiz bir varlığı temsil ederken, varlık ifadesi ise metinde içerisindeki kelime veya kelime öbeğidir. Ayrıca varlık ifadelerini varlık kategorilerine ayırma işlemine varlık kategorizasyonu (sınıflandırması) denir. Varlık özellik kategorisi ise varlığın benzersiz bir yönünü temsil ederken, özellik ifadesi ise metinde bir özellik kategorisini işaret eden kelime veya kelime öbeğidir [14].

GM'de bir diğer problem tanımı açık ve örtülü özellik ifadelerinin çıkarılmasıdır. Cümlede varlığı niteleyen genellikle isim/isim tamlaması ifadelerine olarak açık özellikler, varlık yönünün ima edilerek örtülü bir şekilde nitelendirildiği ifadelerle kapalı özellik ifadeleri denmektedir [55,58]. Örneğin; “Bilgisayarın ekran kartı çok iyi fakat pahalıdır.” şeklinde verilen bir inceleme cümlesinde “ekran kartı” açık ifadedir. Bu cümlede kapalı özellik ifadesi “fiyat” ifadesidir ve “pahalıdır” şeklinde örtülü olarak nitelendirilmiştir.

Sonuç olarak GM'de bir D dokümanı ele alındığında, “ e_i , a_{ij} , s_{ijkl} , h_k , t_l ” bileşenlerinin tümünün çıkarımında beş ana görev gerçekleştirilmektedir.

Bu görevler [14];

1. **Varlık çıkarımı ve sınıflandırma:** Bu görev, D'deki tüm varlık ifadelerini çıkarılmasını ve eş anlamlı varlık ifadelerinin varlık kümeleri halinde kategorize edilmesini içermektedir. Çıkarılan her varlık ifadesi kategorisi, benzersiz bir varlık (e_i) ile temsil edilmektedir.
2. **Özellik çıkarımı ve sınıflandırma:** Bu görev, varlıkların tüm özellik ifadelerinin çıkarılmasını ve bu özellik ifadelerini kümeler halinde kategorilere ayrılmasını amaçlamaktadır. Burada her varlık (e_i) için; özellik ifadeleri kümesi, benzersiz bir özelliği temsil eden a_{ij} ifadelerinden oluşmaktadır.
3. **Görüş sahibi çıkarımı ve sınıflandırma:** Bu görevde ilk iki görevde verilen süreçlere benzer şekilde görüş sahibi çıkarımları ve sınıflandırma amaçlanmaktadır.

4. **Zaman çıkarma ve standardizasyon:** Bu görevde, görüşlerin verildiği zamanların çıkarını ve farklı zaman biçimlerinin standartlaştırılması söz konusudur. Çıkarımlar yukarıda belirtilen görevlerin süreçlerine benzer şekilde yürütülmektedir.
5. **Özellik polaritesi sınıflandırması:** Bu görevde, ele alınan a_{ij} yönüne ilişkin bir görüşün polaritesinin hesaplanması ya da polarite sınıfının (kategorisinin) belirlenme işlevi gerçekleştirilmektedir [31].

3.3. GÖRÜŞ MADENCİLİĞİ ÖN AŞAMALARI

Veri kaynaklarının büyük bir kısmının yapılandırılmamış (metin, ses ve video gibi.) verilerden oluşması önemli araştırma zorluklarını ortaya çıkarmaktadır. Araştırmacılar bu zorlukları ele almak için NLP yöntemlerine, IR ve IE yöntemlerine başvurulmaktadır [8,125]. Bu bağlamda GM, çeşitli NLP, IR, yapılandırılmış ve yapılandırılmamış Veri Madenciliği tekniklerini kullanan bir araştırma alanıdır [8]. Elde edilen verilerin farklı formatlarda birçok kaynaktan gelmesi ve büyük bir kısmının yapılandırılmamış olması sebebiyle, sağlam ve güvenilir sonuçlar üretebilen bir GM sisteminin oluşturulmasında, çeşitli ön adımlara ihtiyaç duyulmaktadır. Ayrıca uygulanan modellere uygun metin temsillerinin seçilmesi ve modellerin girişine uygun bir formata getirilmesi de GM performansını etkileyen önemli bir husustur [126]. Yukarıdaki hususlar dikkate alındığında, veri toplama, veri ön işleme ve metin temsili [55,127] görevleri GM sistemlerinin ön süreçlerinde uygulanan en yaygın alt aşamalar yada görevler olarak karşımıza çıkmaktadır [8,16]. Bu görevler, çeşitli senaryo ve seviyelerde gereksinimler doğrultusunda ayrı ayrı da ele alınabilmektedir.

Bu bölümde genel bir GM sisteminin başlangıç süreçlerinde uygulanabilen, verilerin elde edilmesi, düzenlemesi ve dönüşümüne yönelik; veri toplama, veri ön işleme ve metin temsili aşamaları literatür incelemeleriyle birlikte detaylı olarak sunulmaktadır.

3.3.1. Veri Toplama Teknikleri

Çevrimiçi kaynaklarının çeşitliliği ve yüksek hacimli olması sebebiyle, veri toplama görevi, veri formatına ve gerçekleştirmek istenen analiz türüne göre değişebilen öznel bir süreçtir [8]. Facebook, Twitter, Instagram ve Flickr gibi sosyal medya platformları ve e-ticaret platformlarında paylaşılan inceleme kaynakları özellikle zengin metinsel ve görsel içeriği sahiptir. Bu sebeple araştırmacılar için cazip bir veri toplama kaynağıdır [128]. Bu veri kaynaklarından manuel yaklaşımlarla maliyetsiz bir şekilde verileri elde edebilme, veri hacmine ve analistin kişisel beceri düzeyine göre değiştiğinden [128] sınırlamalara yol açmaktadır. Bu sebeple, zaman alıcı ve daha zahmetli manuel yaklaşımlar yerine, teknik bilgi ve programlama becerileri gerektiren otomatikleştirilmiş veri toplama araçlarını kullanmak [129]; veri çeşitliği ve veri hacmi gibi sınırlamaları azalttığından, daha kaliteli verilerle beslenen nitelikli bir GM sistemi oluşturabilmek için önemlidir [92].

Verilerin toplama süreçlerinde, Uygulama Programlama Arabirimleri (Application Programming Interface, API) geliştiricilere ve araştırmacılara çevrimiçi platformlardan programlı bir şekilde bağlantı kurmak için bir dizi fonksiyonel servis sağlamaktadır [130]. API'ler, veri akışı ve Temsili Durum Aktarımı (Representational State Transfer, REST) şeklinde iki geçerli mimariye ayrılmaktadır. [129]. Veri akışı API'leri, belirlenen salt okunur yapıya sahip sürekli gerçek zamanlı olarak verileri iletmektedir. REST API'ler ise esnek sorgulamalarla geriye dönük kullanılabilen ve sorgulanabilen verilerin iletimini sağlamaktadır [131]. Bu API'ler aracılığıyla yaygın olarak HTML, XML, JSON ve CSV gibi metin yapılarında veriler elde edilebilmektedir.

3.3.2. Metin Ön İşleme Teknikleri

Verilerin toplanması aşamasından sonraki adım GM analizlerinin amacına uygun bir şekilde verilerin hazırlanmasıdır. Toplanan metin verilerin her kaydı, kendisini niteleyen benzersiz bir tanımlayıcıya sahip olmalıdır. Doküman olarak adlandırılan bu kayıtlar, bir araya gelerek doküman koleksiyonunu veya külliyatını oluşturmaktadır. Metinlerin hazırlanmasında uygulanan ön işleme yöntemlerinin çoğu

NLP tabanlı görevleri içermektedir. Ön işlemede amaç, ham bir metin girdisinin alınıp amacına uygun bir şekilde dizgelerin çıkarılmasıdır. Sıklıklarına göre sıralanabilen bu dizgeler, tekil olarak ele alındığında, ilgili külliyyatın sözlük bileşenleri olarak analizlerde yer alabilmektedir [132]. GM’de metinleri yapılandırmak ve özellikleri çıkarmak için dizgeleme (tokenization), standartlaştırma ve metin temizleme, etkisiz kelimeleri (stopwords) kaldırma, gövdeleme (stemming) ve kök çözümleme (lemmatization) gibi ön işleme adımları uygulanmaktadır [30,132]. Bu bölümde bu adımlara ilişkin teknikler başlıklara ayrılarak özetlenmektedir.

Dizgeleme (tokenization): Cümleyi veya dokümanları kelimeler veya kelime öbekleri olarak adlandırılan dizgelere bölmeyi amaçlayan NLP’nin temel bir tekniğidir [30]. Dizgeleme sonrası çıktılar, dilbilgisi yapısı ve dizilişleri dikkate alınmadan, nicelik temsillerine veya ağırlığını gösteren değerlerle yeniden temsil edilerek BoW’u oluşturmaktadır [81]. BoW’u oluşturan bileşenler n-gram olarak adlandırılan n uzunluğunda ardışık kelime dizileridir. Bu dizilerin üretilmesinin amacı, analizlerde bir bütün olarak ele alınması gereken bitişik sözcükleri aynı niceliklerle temsil edebilmektir. Tek kelimeli dizgeler uni-gram, yan yana iki kelimedenden oluşan dizgeler ise bi-gram olarak adlandırılmaktadır [132].

Standartlaştırma ve metin temizleme: Dokümanlardaki terimlerin karşılaştırılabilir ve ele alınabilir hale getirilme sürecini ifade etmektedir. Bu amaçla, ilk adım olarak metinlerin büyük, küçük harf dönüşümleri gerçekleştirilmektedir. Buna benzer olarak bu süreçte; dizgeler arasındaki fazla boşlukların kaldırılması, sayısal ifadelerin düzenlenmesi, yazım hataları kontrolü veya analizin amacına uygun sözlüklerle değerli bir kelime olup olmadığının belirlenmesi veya yanlış kullanılan noktalama işaretlerinin kaldırılması gibi işlemler uygulanabilmektedir [1,33]. Bu görev, dizgeler arasındaki tutarlılığın sağlanmasına yardımcı olmaktadır [132].

Etkisiz kelimeleri (stopwords) kaldırma: Gerçekleştirmek istenen analizin çıktılara katkı sağlamayan, değersiz veya etkisiz dizgeleri kaldırma sürecini ifade etmektedir. Oxford sözlüğü ‘ne göre, “and”, “the”, “be”, “to” ve “of” gibi dizgeler en yaygın etkisiz kelimelerdir. Etkisiz kelimelerin ele alınmasında, yazılım platformlarına entegre edilebilen çok sayıda açık kaynaklı kütüphane

kullanılabilmektedir [133]. Ancak üzerinde çalışılan bir dil için tanımlanmış standart etkisiz sözcüklerle metinlerde temizleme işlemi gerçekleştirilse de, bu sözcüklerin tümünden yok sayılması etki alanına veya projeye bağlı olarak değerlendirilmesi gerekmektedir [132]. Bu bağlamda, GM’de, her bir kelimenin hatta herhangi bir noktalama işaretinin, analizlerde cümlenin anlam bütünlüğüne ve yapısına katkı sağlayabildiği düşünüldüğünde ön işleme sürecinin kontrollü bir şekilde gerçekleştirilmesi önem arz etmektedir. Bu sebeple, analiz sürecini daha verimli hale getirmek ve sürecin özenli ve ayrıntılı bir şekilde ele alınmasını sağlamak amacıyla, ön işlemede alana özgü ya da özel sözlüklerin kullanılması ya da uygun ön işleme tekniklerinin uygulanması gerekmektedir [1].

Gövdeleme (stemming) ve kök çözümlenme (lemmatization): Gövdeleme ve kök çözümlenme işlemleriyle, varyantlara sahip kelime formlarının temel formlarına indirgenmesi amaçlanmaktadır [134]. Gövdeleme, genellikle kelimelerin türetme eklerinin kaldırılmasında görevlidir ve sözlükte yer alıp almadığına bakılmaksızın ele alınan kelimelerin, morfolojik formlarının her birinin anlamsal olarak ilişkili olduğu varsayıldığı köklere dönüştürülmesi sürecini yönetmektedir [135]. Kök çözümlenme ise; gövdelemeden farklı olarak kelimenin bağlamına bağlı sözcük türünü belirleme ve daha sonra lemma olarak adlandırılan baş sözcüğün kanonik biçiminin elde edilmesindeki kompleks süreci ifade etmektedir [135,136]. Ayrıca yazılım geliştirme platformlarına farklı algoritmalarla geliştirilmiş çok sayıda gövdeleyici ve kök çözümlenici araç entegre edilebilmektedir [30,137].

3.3.3. Metin Temsil Modelleri

Metin temsili, NLP’nin temel görevleri arasındadır. Bu görevle düşük boyutlu vektörler üzerinde kelimelerin bağlamsal benzerliğini koruyarak daha anlamlı ve verimli temsil sunulması sağlanabilmektedir [127]. GM ve metin sınıflandırması çalışmalarında, verimli bir temsil işlevi ancak dilbilimsel ve anlamsal (semantik) bilgilerini öğrenebilen doğru metin temsil modelleriyle mümkündür [126]. Literatürdeki ilk çalışmalarda, metinlerin temsillerinde basit ancak uygulamalarda el yordamı mühendislik gerektiren Kelime Torbası (Bag-of-words, BoW) modeline yer verilmiştir. BoW (one-hot vektör, TF-IDF, Hashing gibi) modelinin görevi, içerdiği

öğelerin benzersiz niceliklerle ve ağırlığını gösteren değerlerle doküman terim matrisi oluşturmaktır [81]. Bu model metin sınıflandırmalarında, kelimeler, metin belgeleri ve belirli kategoriler arasındaki yüzeysel ilişki düzeyini yakalamaktadır [138]. BoW modelinin dezavantajı, metinlerin gramer ve kelime sırası dikkate alınmadan, sırasız bir koleksiyonu olarak temsil edilmesidir [81]. Metin temsilinde için doküman terim matrisinden farklı olarak, literatürde Gizli Anlamsal Dizinleme (Latent Semantic Indexing, LSI) [138] ve LDA [139] gibi dağıtık metin temsil modelleri sunulmaktadır.

Son yıllarda literatürde Word2Vec (CBoW, skip-gram) [140], GloVe [141,142] gibi sinir ağı tabanlı dağıtık WEM'lere yer verilmektedir [81]. Word2vec modelleri arasında yer alan; CBoW, konumundan bağımsız olarak bağlama dayalı olarak bir kelimeyi tahmin etmeyi, Skip-Gram ise belirli bir kelimeyi pencere parametresine göre çevreleyen kelimeleri ileri beslemeli sinir ağı mekanizmasını kullanarak tahmin etmeyi amaçlamaktadır [143]. Çalışma şekli LSI'ya benzeyen Glove ise istatistiksel terim temelli sayıya dayalı model kullanmaktadır [81]. Doküman temsilinde ise Word2Vec alt yapısına sahip Doc2Vec modeli kullanılmaktadır [139].

FastText, sözcük bileşenlerine (mikro düzeyde n-gramlar) dayalı olarak vektör temsilleri oluşturmaktadır. Bu sayede bazı kelimeler eğitim veri setinde olmamasına (görünmeyen sözcükler) rağmen temsillerin üretilmesine olanak sağlamaktadır [144]. Dağıtık WEM'lerden farklı olarak dağılımsal temsillerde, sözcükler ve cümleler gerçek sayıların vektörleri veya tensörleri olarak ele alınmaktadır. Sözcük vektörleri, bu sözcüklerin belge koleksiyonlarında diğer sözcüklerle olan ilişkilerinin belirlenmesiyle çıkarılmaktadır [145]. Bununla birlikte, aralarında güçlü bir ilişki olan dağıtık temsiller, dağılımsal temsillerin yaklaşık değerini ifade etmektedir [146].

Daha yakın zamanlarda, BERT gibi Dönüştürücü (Transformer) adı verilen derin öğrenme modeli tabanlı, bağlamsal ve dağılımsal semantik mimariye uygun olarak önceden eğitilmiş NLP yaklaşımları ortaya çıkmıştır [147]. Birçok NLP görevinde etkileyici sonuçlar gösteren BERT [148] ile kompozisyon anlamlarının doğru bir şekilde temsil edildiği kabul edilmektedir [149-151]. BERT modeline ek olarak bu çalışmada, ACD görevinin gerçekleştirilmesinde, BERT gibi önceden eğitilmiş SFT tarafından üretilen Seyrek Dağıtık Temsil (Sparse Distributed Representation, SDR)

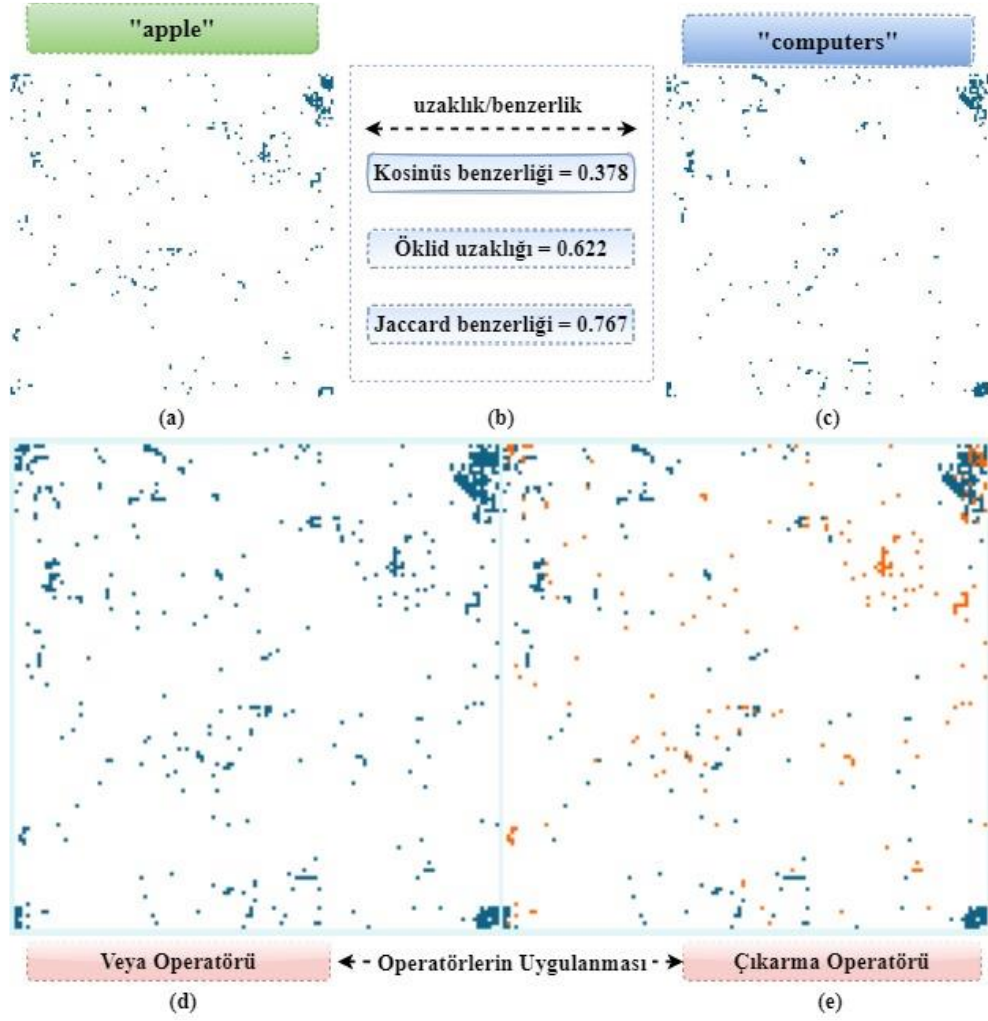
[152] vektörleri kullanılmıştır. Son zamanlardaki çalışmalar, SDR vektörlerinin sınıflandırma ve anomali tespit görevlerinde başarılı bir şekilde uygulandığını göstermektedir [153-155].

3.3.3.1. BERT modeli

Google tarafından geliştirilen BERT; NLP, Soru Cevaplama ve GM uygulamalarında kullanılmaktadır. BERT, BooksCorpus ve English Wikipedia'da önceden eğitilmiş, çok katmanlı ve çift yönlü derin öğrenme tabanlı bir temsil modelidir [7,148]. Ayrıca BERT'in, BERT_{BASE} ve BERT_{LARGE} olmak üzere iki sürümü yayınlanmıştır [141] [151]. BERT'in başarısı, kelimeler arasındaki ilişkiyi içinde bulunduğu bağlama göre öğrenen bir dikkat mekanizmalı Dönüştürücü derin öğrenme mimarisine dayanmaktadır [156]. Word2Vec, FastText ve GloVe gibi geleneksel bağlamdan bağımsız kelime gömme modelleri, yalnızca tek bir yönü dikkate alarak her kelime için tek bir kelime gömme temsili üretirken [148], BERT ise sol ve sağ bağlamları dikkate alarak çift yönlü bağlamsal metin temsillerine dönüştürmektedir [7,157].

3.3.3.2. SFT modeli

SFT, metinlerin semantik olarak temellendirilmiş bir temsile dönüştürülmesinde, HTM tabanlı alternatif bir hesaplama teorisi geliştirme girişimidir [152,158]. Wikipedia verilerine göre önceden eğitilmiş bir kelime gömme modeli olan SFT, kelimeleri daha hassas ve çok sayıda bağlamlara ayırarak vektör temsilleri üretmektedir. Diğer geleneksel kelime gömme modelleri düşük boyutlu ve yoğun metin temsilleri oluşturmak için boyutluluk azaltmayı kullanmaktadır. SFT'yle kelimelerin açık özelliklerinin dağılımsal kodlanmasıyla, çok seyrek yapıda ikili temsil vektörlerine (çoğu bit "0" ve yalnızca birkaçı "1") kodlanmaktadır. Ardından bu vektörler 2-boyutlu topoğrafik bir semantik harita-uzay üzerine yerleştirilmektedir [152,154]. Kodlanan bu vektörler Anlamsal Parmak İzi (Sematic Fingerprint, SF) olarak adlandırılmaktadır. SF'ler yüksek boyutlu (16.384 bit), gürültülere dayanıklı ve az miktarda veriyle yüksek semantik yükü (tüm ilişkili bağlamlar) depolayabilme yeteneğine sahip bir yapıdadır [158,159].



Şekil 3.4. İki boyutlu semantik uzay üzerinde, cortical.io Retina sunucusu üzerinde üretilen kelime temsilleri ve bu temsiller üzerinde uygulamalar, (a) "apple" kelimesinin SF temsili, (b) "computers" kelimesinin SF temsili, (c) "apple" ve "computers" kelimeleri arasındaki vektörel mesafe/benzerlik hesaplamaları, SF'ler arasında (d) veya (e) çıkarma operatörlerinin uygulanması.

Şekil 3.4'te, 128x128 boyutlarına sahip bir semantik uzay üzerinde "apple" ve "computers" kelimelerinin SFT ile oluşturulmuş SF'leri ve bu kelimeler üzerinde gerçekleştirilen "veya" ve "çıkarma" operatörleriyle üretilen temsiller sunulmaktadır. Ayrıca Şekil 4. (b), (d) ve (e)'de sunulduğu üzere SF vektörleri birbiriyle uyumlu olduğundan atomik seviyede toplanabilme (cümleler, paragraflar, belgeler) ve birbirleriyle yaygın uzaklık/benzerlik yöntemleriyle (Öklid uzaklığı, Hamming uzaklığı, Jaccard benzerliği, Kosinüs benzerliği ve Levenshtein uzaklığı vb.) kıyaslanabilmektedir [158,160]. Temsiller HTM tabanlı oluşturulduğundan her bir

temsilin seyreklik parametresi (oranı) değeri (1 değerli bit) minimum %0.05, maksimum ise %2 oranındadır [161].

3.4. GÖRÜŞ MADENCİLİĞİ GÖREVLERİ

GM, temel olarak doküman, cümle, varlık veya özellik ve konsept seviyelerinde incelenmektedir [8,14]. GM’de doküman seviyesi [162-165], dokümanın genel polaritesiyle ilgilendiğinden doğru değerlendirmeler için uygun olmayan ancak yüzeysel bir analiz imkanı sağlamaktadır [16]. Cümle seviyesi [45,46], doküman seviyesine göre daha ayrıntılı analizleri gerçekleştirme yeteneğine sahip olsa da bu seviyede cümleler kısa dokümanlar olarak ele alınmaktadır [166]. Araştırmacılar doküman ve cümle seviyelerinde, öznellik analizi [100,167] ve görüş sınıflandırması [32] [44] gibi temel görevleri gerçekleştirilmektedir. Varlık ve özellik seviyesi [1,10] [11,18], metnin tümünü ifade edebilecek soyut bir polarite tanımlaması gerçekleştirmek yerine, metinlerde çoklu (bağımsız) polariteler göz önünde bulundurularak çıkarılan özelliklerin ayrıntılı analizlerine olanak sağlayan üçüncü bir seviye olarak kabul edilmektedir. Konsept seviyesi [40,168,169] ise, doğal dil görüşleri ile ilişkili semantik ve etkili bilgileri çıkararak, karşılaştırmalı olarak varlık veya özellik temelinde görüşsel analizlerin gerçekleştirilmesine imkan sağlamaktadır. Bu bölümün devamında genel GM görevleri çalışma seviyelerine göre detaylandırılarak sunulmaktadır.

3.4.1. Doküman Seviyesi Görevleri

Doküman seviyesinde, belgenin bütünü temsil edebilecek polarite tabanlı sınıflandırma gerçekleştirilerek genel polaritenin tanımlanması amaçlanmaktadır [14]. Örneğin; bir ürün incelemesinin değerlendirilmesinde, incelemenin ürün hakkında genel olarak olumlu veya olumsuz bir görüş ifade edip etmediği doküman seviyesinde belirlenmektedir. Bu seviyede uygulanan tekniklerin çoğu denetimli öğrenme yöntemlerine dayanmaktadır [19]. Doküman seviyesi, belgenin tamamını tek bir varlık olarak ele aldığından GM’nin en soyut düzeyidir ve derinlemesine doğal dil işleme gerektiren detaylı görevleri içermemektedir [14,16]. Bu sebeple bu seviye, belgenin ayrıntılı analizi ve değerlendirilmesi için uygun değildir. Ayrıca forum, blog ya da e-

ticaret platformlarında yaralan inceleme metinlerinde kullanıcılar tarafından atanan yıldız derecelendirmelerinin varlığı düşünüldüğünde [165], duygu yönelimi etiketinin belirlenmesine ihtiyaç duyulmamaktadır [14]. Ancak doküman seviyesinde en büyük zorluk, sadece sözcükler ve cümleler arasındaki anlamsal ilişkiyi ele almak değil, aynı zamanda belge kompozisyonunu temsil edebilecek şekilde anlamsal bilgilerin genel bağlamının da dikkate alınması gerekliliğidir [44]. Doküman seviyesinde ele alınan dokümanlar üzerinde denetimli ve denetimsiz yaklaşımlarla görüş sınıflandırılması, görüş derecelendirme tahmini, alanlar arası ve diller arası görüş sınıflandırması gibi alt görevler gerçekleştirilmektedir [14].

3.4.2. Cümle Seviyesi Görevleri

Cümle seviyesi görevi, dokümanların birden fazla görüşe sahip olma durumu göz önünde bulundurulduğunda doküman seviyesine göre daha ayrıntılı bir analiz imkanı sağlamaktadır [166]. Ancak cümleler kısa belgeler olarak ele alındığından, sınıflandırma problemlerinde cümle ve doküman seviyeleri arasında belirleyici büyük farklar bulunmamaktadır [14]. Cümle seviyesinde de doküman seviyesindeki gibi bir cümlenin genellikle tek bir görüş içerdiğini varsayılmaktadır. Bu sebeple bu seviyedeki görev, her bir cümlenin olumlu, olumsuz veya nesnel bir görüş ifade edip etmediğini belirlemektir. Cümle seviyesi, olgusal içeriğe sahip nesnel cümleleri, görüş veya görüşler içeren öznel cümlelerden ayıran öznellik sınıflandırmasıyla yakından ilişkilidir [170]. Bu seviyede cümlenin görüş tabanlı olarak sınıflandırması iki ayrı sınıflandırma problemi düşünülerek çözülebilmektedir. Bu problemin çözümünde ilk adım bir cümlenin nesnel ya da öznel nitelikli bir görüşe sahip olup olmadığının belirlenmesidir. İkinci adım ise bu görüş cümlelerinin polarite tabanlı sınıflara ayrılmasıdır [16,171]. Cümle seviyesi sınıflandırma problemlerinde, denetimli yaklaşımlara ek olarak sözlük tabanlı [172-174] yöntemler de kullanılabilir [14]. Ayrıca bu seviyede doküman seviyesindeki gibi öznellik analizi, görüş sınıflandırması, diller arası öznellik ve görüş sınıflandırması ve farklı senaryolarda karşı karşıya kalınabilen koşullu [175] ve iğneleyici [176] içeriğe sahip cümleler de ele alınabilmektedir.

3.4.3. Varlık ve Özellik Seviyesi Görevleri

Varlık ve özellik seviyesi görevinde, genel polarite üzerinden belgeyi ilişkilendirmekten daha çok metinde yorumlanan varlık ya da varlıkların kullanıcılar tarafından nasıl değerlendirildiğini ölçmeyi amaçlayan [33] kompleks bir çalışma gerekmektedir [37,177]. Bu bağlamda daha gerçekçi sonuçlar üretmek ve ayrıntılı analizler [39] gerçekleştirmek amacıyla bu seviyede, metinlerde yorumlanan varlıklar ve onların özellikleriyle birlikte polariteye sahip nitelendirici OW'ler çeşitli yöntemlerle ele alınmaktadır. Örneğin, “Bataryası iyi olmasa da bu telefonu seviyorum.” cümlesi olumlu bir görüş sunsa da bu cümlenin tamamen olumlu olduğunu söylenemez. Çünkü örneklenen cümlede olumlu olarak nitelenen telefon ifadesiyken, telefonun bataryası olumsuz olarak vurgulanmaktadır. Bu nedenle, söz konusu analiz seviyesinin amacı, varlıklar ve/veya onların özellikleri hakkındaki görüşleri keşfetmektir [14].

Varlık veya özellik seviyesinde, görüş özetleme ve duygu sözlüğü analiziyle birlikte birbirlerine bağımlı bir şekilde uygulanan özellik duygu sınıflandırması ve özellik çıkarımı [178] olarak üç temel görev gerçekleştirilmektedir [36]. Özellik tabanlı görüş sınıflandırmasında yorumlanan varlığın farklı yönleri hakkındaki görüşlerin olumlu, olumsuz veya tarafsız olup olmadığı belirlenmektedir [14]. Polarite olarak adlandırılan bu duygu yönelimlerinin belirlenmesinde denetimli öğrenme ve sözlük tabanlı olmak üzere iki temel yaklaşım kullanılmaktadır [14]. Sözlük tabanlı yöntemlerde [179], kelimelerin polarite değerlerinin ya da polarite kategorilerinin yer aldığı listelere başvurulmaktadır [28].

Özellik çıkarımında ise; verilen bir cümle içerisinde yorumlanan varlık ya da varlıklara ilişkin yönleri temsil eden açık (belirgin) [10,33] veya örtülü [108,180] tüm özellik terimleri çıkarılmaktadır [58]. Eğer özellik metin içerisinde açıkça belirtilmiş ise açık özellik olarak nitelendirilmektedir [10]. Örtülü özellikler ise temsil edilecek özellik terimleri açıkça belirlenemeyen sadece ima ile atıfta bulunulmuş terimlerdir [75]. Örneğin, “Bu bilgisayarın işlemcisi gerçekten hızlı ve alışmamın ne kadar kolay olduğunu görünce şok oldum” şeklindeki yazılan bir inceleme cümlesinde yorumlanan varlık olarak “bilgisayar” ifadesine, OT olarak “bilgisayarın işlemcisi” şeklindeki açık ifadeye ve öznitelik terimleri olarak ise “işlemci performansı” ve “kullanılabilirlik”

şeklinde örtülü özellik terimlerine ÖTGM yaklaşımları kullanılarak ulaşılabilmektedir. Açık özellik ifadeleri genellikle isimler ve isim öbekleridir, ancak fiiller, fiil öbekleri, sıfatlar ve zarflar da olabilmektedir [106].

GM alanında öncü araştırmacılardan Bing Liu'ya göre; açık özellik ifadelerinin çıkarılmasında dört ana yaklaşıma başvurulmaktadır [14,16,181].

1. Sık kullanılan isimlere ve isim tamlamalarına dayalı çıkarım: Bu yaklaşımda, genel olarak POS etiketleyici yardımıyla isimler ve isim öbeklerinin çıkarılması sağlanmaktadır. Ardından POS etiketleyici çıktılarının frekansları ya da istatistiksel birliktelik sonuçları (TF-IDF, PMI gibi teknikler) bir eşik değerine bağlı olarak kullanılmaktadır [58]. Ancak bu yaklaşımın genel olarak dezavantajı, varlığın farklı yönleri hakkındaki yorumlarda kullanılan kelime dağarcığının ve istatistiksel çıktılarının değerli veya değersiz kelimeleri doğru temsil edememesi ve tam anlamıyla açıklayamamasıdır.

2. Görüş sözcükleri ve görüş hedefi ifadelerinin bağıllık ilişkilerinden yararlanarak çıkarım: Bu yaklaşımlarda, OW'lerle ilişkili OT'lerin çıkarılması amaçlanmaktadır. Bu sebeple, ilk olarak duygu sözcüklerine en yakın isim veya isim tamlamalarının çıkarılması ele alınmıştır. Ancak kilit bir role sahip OW'nin bilinmemesi ya da varlık yönüne ilişkin bir duygu ifadesinin yer almaması durumları sınırlamalara yol açmaktadır. Bu sınırlamaların çözümünde, daha güvenilir sonuçlar üreten ve OW'lerin OT'lerle birlikte ele alınmasına olanak sağlayan bağıllık ayrıştırması yöntemlerine başvurulmaktadır [36,76]. Bir diğer yöntem ise; çıkarım kurallarını üretmek için; bağıllık ayrıştırıcısı kullanarak OW'lerle OT'ler arasındaki ilişkileri tanımlayan ve ön görüş sözlüğünün genişletilmesini ve hedef ifadelerin çıkarılmasını amaçlayan çift yayılım yöntemidir [182].

3. Denetimli öğrenme modelleri kullanarak çıkarım: Özellik çıkarımında, manuel olarak etiketlenmiş verileri kullanan sıralı öğrenme ya da sıralı etiketleme tabanlı HMM ve CRF [18,183] gibi yaklaşımlar etkili denetimli

öğrenme yaklaşımları arasındadır [16]. Bu yaklaşımların dışında, özellik çıkarımında etkin derin öğrenme tabanlı yaklaşımları da kullanılmaktadır [43].

4. Başlık (konu) modelleme ile çıkarma: Başlık modelleme çalışmaları, dokümanlar içerisinde yer alması muhtemel birçok başlığın ve bu başlıklarla ilişkili kelimelerin olasılık dağılımıyla varlıklarını varsayarak, dokümanların başlıklarını ya da varlık yönlerini keşfetmeyi amaçlayan yaklaşımları içermektedir. Bu amaçla, denetimsiz LDA [12] ve Olasılıksal Gizli Anlamsal Analiz (probabilistic Latent Semantic Analysis, pLSA) gibi modellere başvurulmaktadır [181]. Başlık modelleme yaklaşımları, doküman seviyesi amaçlarına da uygun olduğundan, farklı başlıkların çıkarılması ve çıkarılan başlıkların değerlendirilmesinde doküman seviyelerinde de uygulanabilmektedir [16].

3.4.4. Konsept Seviyesi Görevleri

İlk olarak 2003 yılında Cambria tarafından önerilen konsept seviyesi [168], web ontolojileri semantik ağlarının kullanımıyla metinlerin anlamsal analizine odaklanmaktadır [16,169]. Bu yaklaşımlar, karşılaştırmalı ve detaylı GM analizlerin gerçekleştirilmesine imkân sağlamaktadır. Konsept seviyesi, herhangi bir duyguyu açıkça ifade etmeyen kavramları (örtülü), dolaylı olarak bu kavramlarla bağlantılı diğer kavramların analiziyle ele alarak, semantik ve duygusal yönelim bilgilerini çıkarmayı amaçlamaktadır. Örneğin; bir otel incelemesinde “soğuk oda” olumsuz bir durumu ifade ederken, “soğuk içecek” ise olumlu durumu ifade edebilmektedir [184]. Kavram düzeyinde GM yaklaşımları, temel olarak SentiWordNet [185], SenticNet [95], ANEW ve WordNet-Affect [186] gibi mevcut görüş sözlüklerinden yararlanmaktadır.

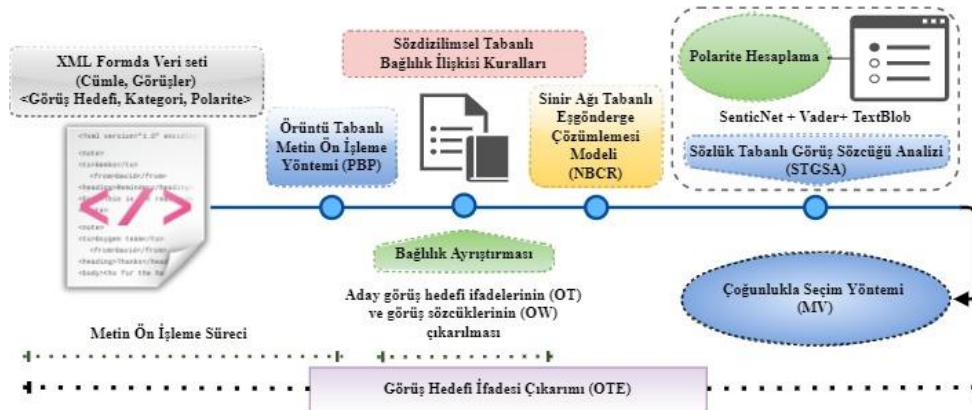
BÖLÜM 4

GÖRÜŞ HEDEFİ ÇIKARIMI (OTE) YAKLAŞIMI

Bu bölümde, ilk olarak, önerilen OTE yaklaşımının genel mimarisi ve bileşenleri açıklanmaktadır (Bölüm 4.1). Bölüm 4.2.1'de metodoloji başlığı altında; geliştirilen PBP yönteminin ayrıntıları verilmektedir. Bölüm 4.2.2'de, aday OT ve OW çıkarımlarını sağlayan genişletilmiş söz dizilim tabanlı ilişki kuralları ve nihai ifadelerin çıkarımını gerçekleştiren STGSA aşaması sunulmaktadır. Ayrıca bu bölümde, ifade çıkarımlarının metin içerisindeki varsa varyasyonlarını çıkararak, birbirleri yerlerine yazılacak ifadeleri belirleyen NBCR modeli de yer almaktadır. Son olarak, Bölüm 4.2.3'te, OTE çıktılarının birleştirilerek, optimum çıktının seçilmesini sağlayan MV yöntemi sunulmaktadır.

4.1. OTE YAKLAŞIMI GENEL MİMARİSİ VE BİLEŞENLERİ

Şekil 4.1'de önerilen OTE yaklaşımının bileşenlerini ve çıkarımlarda baştan sona uygulanan süreçleri özetleyen genel mimari sunulmaktadır.



Şekil 4.1. Geliştirilen OTE yaklaşımına ilişkin genel mimari.

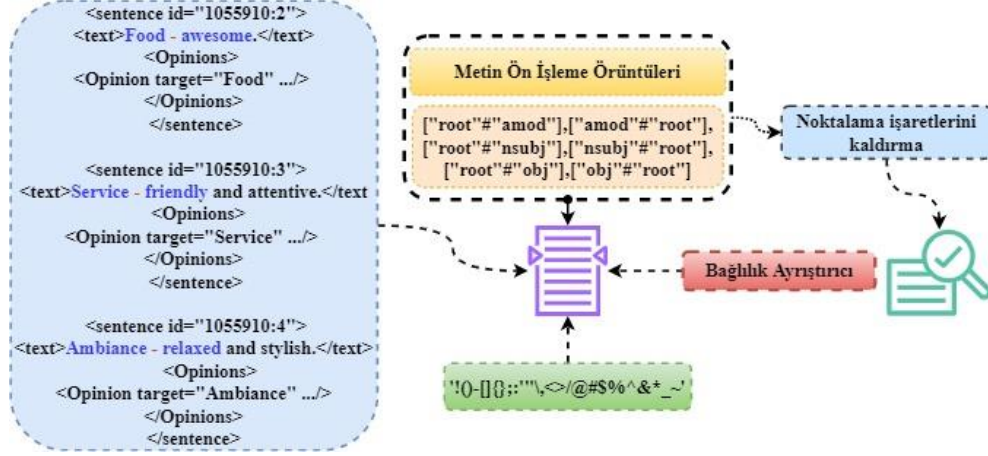
Şekil 4.1'de görüldüğü üzere, OTE'nin ilk aşaması, XML biçiminde toplanan verilerin, metin ön işleme sürecine dahil edilmesidir. Metin ön işleme süreci, geliştirilen PBP yöntemi tarafından yürütülmektedir. OTE'nin ikinci aşaması, aday OT ve OW terimlerinin çıkarılmasıdır. Bu aşama, bağıllık ayrıştırıcısı grafi üzerinde çalışan genişletilmiş sözdizimsel tabanlı bağıllık ilişki kurallarına ait algoritmalar tarafından yönetilmektedir. Aday terimlerin çıkarılmasından sonraki aşama, STGSA ile ilgilidir. STGSA aşamasında çıkarılan aday OW'lerin polarite hesaplamaları polarite analizörleri (SenticNet, VADER, TextBlob) kullanarak gerçekleştirilmesinde ve polarite çıktılarına bağlı olarak nihai OT'lerin belirlenmesinde görevlidir. Son aşamada ise polarite analizör modellerinin çıktıları üzerinde performans optimizasyonu gerçekleştirilmektedir. Bu optimizasyonun gerçekleştirilmesinde analizör çıktıları üzerinde MV yöntemi uygulanmaktadır. Ayrıca, doğru ifade çıkarımlarına ulaşabilmek ve nihai OW'ler yerine yazılabilecek ifadelerin çıkarımları için NBCR modeli kullanılmaktadır. Şekil 4.1'de yer alan XML formda veri seti ve STGSA'ya ilişkin detaylı bilgiler “Deneysel Çalışmalar ve Sonuçlar” bölümünde detaylı bir şekilde verilmektedir.

4.2. METODOLOJİ

4.2.1. Örüntü Tabanlı Metin Ön İşleme Yöntemi (PBP)

Çevrimiçi platformlarda kullanıcılar tarafından oluşturulan metinlerde birçok uyumsuz noktalama işareti olabilmektedir. Bu durum metinlerin toplu işlenmesinde veya ileri düzey analizlerde kısıtlamalara yol açabilmektedir. Özellikle POS etiketleme ve bağıllık ayrıştırması gibi görevlerde cümlelerin sözdizimsel yapısı dikkate alındığından yazım yanlışlarının ve noktalama işaretlerinin varlığı eksik çıkarımlara neden olmaktadır. Yukarıda bahsedilen sorunları aşmak için; NLP'nin geleneksel metin ön işleme [187] teknikleri yerine, cümlenin söz dizim yapısını ve anlamsal bütünlüğünü bozmadan sınırlı olarak uygulanabilen özelleştirilmiş metin ön işleme yöntemlerine ihtiyaç duyulmaktadır [1]. Şekil 4.2'de mimarisi sunulan PBP yöntemiyle, dilbilgisel tamlama kurallarına göre geliştirilmiş örüntüler kullanılarak yalnızca sözcük grupları (isim öbekleri gibi) arasındaki uyumsuz noktalama işaretleri elimine edilmektedir [1]. Böylece bu yöntemle, giriş verilerini düzenlenmesi ve girdi

metinlerinin gürültülerinin giderilmesi sağlanarak OTE çıktı performansı iyileştirilmektedir.



Şekil 4.2. Dilbilgisel tamlama kuralları örüntüleriyle geliştirilen metin ön işleme yöntemi (PBP).

Şekil 4.2'de görüldüğü üzere, PBP yöntemiyle cümlenin yapısına ve anlamına katkıda bulunan kelimeler olduğu gibi kalırken, diğer noktalama işaretleri kaldırılmaktadır. Örneğin, "Service- friendly and attentive" şeklindeki inceleme cümlesindeki "service" kelimesi bir görüş hedefi ifadesidir ve bu ifade ancak "service-friendly" ifadesindeki noktalama işaretinin kaldırılmasıyla çıkarılması mümkündür. Başka bir örnekleme için "Ambiance- relaxed and stylish" cümlesi ele alındığında, bu cümledeki görüş hedefi olan "ambiance" kelimesinin çıkarımı ancak aradaki noktalama işaretinin kaldırılmasıyla mümkündür.

Şekil 4.3'te ise geliştirilen PBP yöntemine ilişkin algoritma sunulmaktadır. "checkPunct" ve "checkPattern" işlevleri, mevcut noktalama işaretlerinin cümle yapısı üzerindeki etkisini kontrol etmek için geliştirilmiştir. Bağlılık ayırıştırıcı çıktıları, "checkPattern" fonksiyonu ile belirlenen örüntü yapısına göre kontrol edilmektedir.

```

Initialize  $S \in \text{Sentences}$ 
for each  $s_i$  in  $S$  do
  if checkPunct( $s_i$ ) and checkPattern( $s_i$ ) then
    removePunct( $s_{ik}$ )
  end if
end for

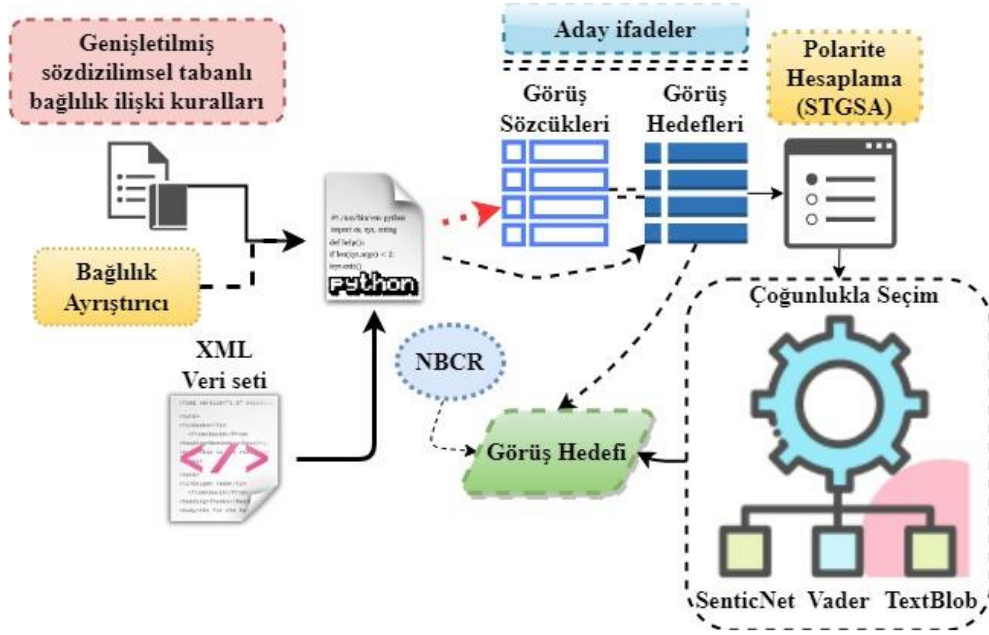
```

▷ k noktalama işaretinin indeksidir.

Şekil 4.3. Metin ön işleme için geliştirilen PBP yöntemi algoritması.

4.2.2. Genişletilmiş Sözdizilimsel Tabanlı Bağlılık İlişki Kuralları

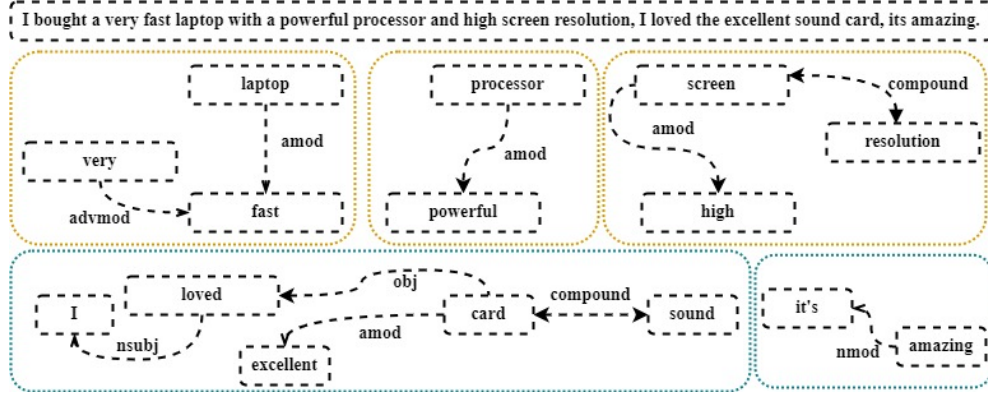
Bu bölümde, genişletilmiş sözdizilimsel tabanlı ilişki kurallarıyla aday OT ve OW'lerin çıkarılması açıklanmaktadır. Şekil 4.4'te, geliştirilen OTE yaklaşımı süreçlerinin detaylandırıldığı mimari tüm bileşenleriyle birlikte sunulmaktadır. Bu mimarinin girişinde genişletilmiş sözdizilimsel tabanlı bağlılık ilişki kuralları ve XML formda veri seti kullanılmaktadır.



Şekil 4.4. Bileşenleriyle birlikte geliştirilen OTE mimarisi.

Sözdizilimsel tabanlı bağlılık ilişki kuralları, sözdizilimsel yapının sözlüksel öğeleri arasındaki asimetrik ikili ilişkileri yönetmektedir. Bağlılık ayırıştırıcısı tarafından üretilen bu ilişkiler, Bağlılık ilişki türü (deprel), yönetici (g) ve bağımlı (d) şeklindeki üçlü bileşen türleriyle ele alınmaktadır (Şekil 9). Açık Bilgi Çıkarma [10,18,182] stratejilerine dayalı olarak genişletilen sözdizilimsel kurallara ilişkin geliştirilen

algoritmalar tarafından, çıkarılan bağıllık ilişkileri değerlendirilerek çıkarım süreci yönetilmektedir. Bağıllık ayrıştırıcısının görevi, bir cümledeki farklı kelimeler arasındaki ilişkileri temsil eden bir graf yapısı üretmektir. Şekil 4.5'te çok kelimeli OT ve OW içeren örnek bir cümle üzerinde bağıllık ayrıştırması çıktıları sunulmaktadır.



Şekil 4.5. Çok kelimeli OT ve OW içeren örnek bir cümle üzerinde bağıllık ayrıştırıcı çıktıları.

Şekil 4.5'te görüldüğü üzere, OW'lerle OT'ler arasındaki ilişkiler, ancak bağıllık ayrıştırma [18] işleminden sonra oluşturulan hiyerarşik graflar üzerinde analiz edilebilmektedir. Analizler sonrası OTE çıktıları, potansiyel OT ve OW adayları olarak kabul edilmektedir. OTE'de, sözdizimsel tabanlı bağıllık ilişki kuralları algoritmaları kullanılarak ilk olarak bu aday ifadelerin çıkarılması amaçlanmaktadır. Bu sebeple, aday ifadelerin çıkarımı OTE için en önemli başlangıç görevidir [33]. Bununla birlikte, yine Şekil 4.5'te görüldüğü gibi OT ve OW'lerin birbirini değiştiren çok kelimeli ifadelerden oluştuğunu varsayıldığında ayrıştırma performansını artırmak için kural yapısının yeni özelliklerle genişletilmesi gerekmektedir [1]

Bu çalışmada, OTE görevi için ortak ilişki türlerine bağlı olarak geliştirilen sözdizimsel tabanlı bağıllık ilişki yapısı, birbirini değiştiren çok kelimeli ifadelerin yakalanabilmesi amacıyla yardımcı ilişki türleriyle genişletilmiştir. Çizelge 4.1'de genişletilmiş kurallarla ilgili ilişki türleri ve açıklamaları sunulmaktadır. Bu kapsamda OTE görevlerinde aday ifadelerinin çıkarım çözünürlüğünü arttırmak amacıyla temel bağımlılık bağıntı kurallarına bileşik, advmod, obl, nmod gibi yardımcı ilişki türleri eklenmiştir [1,18]

Çizelge 4.1. Temel bağıllık ilişkisi türleri (d_i) ve genişletilmiş sözdizimsel tabanlı kurallar için tanımlanan yardımcı ilişki türleri ve açıklamaları.

Temel Bağlılık İlişkileri		Yardımcı Bağlılık İlişkileri		
Değişken	İlişki Türü	Değişken	İlişki Türü	Açıklama
d_1	amod	d_4	compound	Birleşik kelimeler
d_2	nsubj	d_5	advmod	Bir yüklemi veya değiştiriciyi (zarf değiştirici) değiştirmeye yarayan bir kelimenin (isim cümlesi) zarf veya zarf tümcesi
d_3	obj	d_6	obl	İşlevsel olarak bir sığata veya bir fiile veya başka bir zarfa eklenen bir zarfın karşılığı
nsubj : Nominal özne amod : Sıfat değiştirici obj : Nesne		d_7	nmod	Yalın dışı veya ek olarak işlev gören isim. İsimlerin veya yan tümceli yüklemelerin nominal değiştiricileri için kullanılır (nominal değiştirici)
*Nominal : dilbilimsel form				

Çizelge 4.1'de $d_{1,2,3}$ temel ilişki türleri, diğerleri ise çok kelimeli ifade çıkarımı işlemi desteklemek için eklenen yardımcı ilişki türleridir. Şekil 4.6'da genişletilmiş söz dizim tabanlı ilişki kuralları yürüten algoritma sunulmaktadır. Sunulan algoritmaya göre, tanımlanan temel ve yardımcı ilişki türleri yardımıyla, bağımlılık ayrıştırıcı fonksiyonu ($deprel()$) çıkışları kullanılarak, “g” ve “dep” çiftlerinden “ote” ve “ow” bileşenleri seçilmektedir.

```

Başlat  $S^p \subset S \wedge e_i \in S_i^p$  ▷  $S^p$ : görüş cümleleri
for each  $s_i$  in  $S_i^p$  do
  for each  $deprel_j$  in  $deprel(s_i)$  do
    if  $deprel_{ij}=d_1$  and compute( $deprel_{ij}$ ) then
       $ote_{ij} \leftarrow multiWordOTE(g_{ij})$  ▷ ote: görüş hedefi ifadesi
       $ow_{ij} \leftarrow multiWordOW(deprel_{ij})$  ▷ ow: görüş sözcüğü ifadesi
    else if  $deprel_{ij}=d_2$  and compute( $g_{ij}$ ) then
       $ote_{ij} \leftarrow multiWordOTE(deprel_{ij})$ 
       $ow_{ij} \leftarrow multiWordOW(g_{ij})$ 
    else if  $deprel_{ij}=d_3$  and compute( $g_{ij}$ ) then
       $ote_{ij} \leftarrow multiWordOTE(deprel_{ij})$ 
       $ow_{ij} \leftarrow multiWordOW(g_{ij})$ 
    end if
  end for
end for

```

Şekil 4.6. Genişletilmiş sözdizim tabanlı ilişki kurallarını yöneten algoritma.

Şekil 4.6’da verilen algoritmada, "e_i" metindeki yorumlanan varlığı, "ote_{ij}" varlığın OT’lerini, "ow_{ij}" ise metinde görüş hedeflerini niteleyen OW’leri temsil etmektedir. Ayrıca algoritmada, “deprel”, “compute” ve “multiWord” adlı fonksiyonlar kullanılmaktadır. “deprel” fonksiyonu kendisine parametre olarak verilen cümleye ilişkin tüm bağıllık ilişkilerini çıkarmak için kullanılmaktadır. Böylece istenilen bağımlılık ilişkilerine ulaşılabilir. Ardından, bağımlılık ilişkisini oluşturan yönetici (g) ve bağımlı (dep) çiftleri "ote" ve "ow" atamaları için çıkarılmaktadır. Bu algoritmaya göre; (1) bağımlılık ilişkisi türü **d₁** ise, “dep” değişkeninin polarite değeri, “compute” fonksiyonu tarafından hesaplanmaktadır. Polarite değeri öznel değer aralığına sahipse, "g" ifadesi "ote" olarak devam eder. (2) **d₂** ve **d₃** bağımlılık ilişki türleri için, “compute” fonksiyonu “g” değişkeninin polarite değerini hesaplamaktadır. Bu değer polaritesi öznel değer aralığına sahip ise "dep" ifadesi "ote" olarak devam ettirilir.

Son olarak, "g" ve "dep" değiştirici kelimelerle değerlendirilir. İki veya daha fazla kelime içeren ifadeler geliştirilen “multiWord” fonksiyonu ile yeni "ote" ve "ow" çıkarımları gerçekleştirilir. Bu sebeple **d_{1,2,3}** ilişki türleri için “multiword” fonksiyonu çok kelimeli terimlerin çıkarılmasında anahtar role sahiptir. Çıktıları çok kelimeli ifadeler olan fonksiyonlarda, çok kelimeli görüş ifadelerini çıkarmak için **d_{1,2,3}** ile "advmod" ve **d₁** ile "obl" ve çok kelimeli görüş hedeflerinin çıkarılmasında ise **d_{1,2}** ile "nmod" kullanılmaktadır.

STGSA aşaması ise; “compute” fonksiyonu tarafından yönetilmektedir. Bu süreçte SenticNet, VADER ve TextBlob (polarite çözümleyici modeller) gibi polarite sözlükleri kullanılarak aday görüş hedefiyle ilişkili OW’lerin polariteleri hesaplanmaktadır. Daha sonra, bu polarite kaynakları çıktıları, optimum çıktının belirlenmesi amacıyla uygulanan MV yönteminin girişinde kullanılmaktadır. MV yöntemi, Bölüm 4.2.3’te detaylı olarak sunulmaktadır.

OTE yaklaşımında, nihai OT varyasyonları görüş hedef ifadeleri çıkarıldıktan sonra metinlerde aynı referansa sahip ifadeler NBCR modeliyle çıkarılabilmektedir. Girdilerde NBCR modelinin uygulanması, doğru görüş hedeflerinin çıkarılmasında önemli bir role sahiptir. NBCR modeli, aday görüş hedefinin sonuçları, elde edilen

görüş hedefi ifadesi yerine yazılabilecek ifadelerle birleştirmektedir. Ancak bu model, bazı cümlelerin kompleks yapısı nedeniyle aynı referansa sahip ifadeleri bulmada verimsiz sonuçlar üretebilmektedir. Bu sorunu ele almak için; kompleks cümleleri NBCR modeli girişinde ayrıştırmak, anlamsal bütünlüğü bozmadan çıkarım çözümlüğü performansını arttırmaktadır. Bu nedenle bu çalışmada veri setindeki karmaşık cümleler ayrıştırılarak NBCR modeli girişinde kullanılmıştır. Cümle ayrıştırma işlemi sayesinde kompleks cümleler daha kısa cümlelere dönüştürülmüştür. Şekil 4.7’de ayrıştırılmamış ve ayrıştırılmış cümlelere göre NBCR modeli tarafından üretilen çıktılar örneklenmektedir.



Şekil 4.7. İnceleme cümlesi (üstte) ve görüş hedefi etiketi (koyu yeşil renkli ifade), cümle ayrıştırma işlemi uygulanmadan önce NBCR çıkarımları, cümle ayrıştırma işlemi sonrası NBCR çıkarımları.

Şekil 4.7’de yer alan inceleme cümlesinde görüldüğü üzere, ancak cümle ayrıştırma işlemi sonrası "the staff" anlamına gelen ifadeler doğru bir şekilde belirlenmektedir. Bu sayede çıktılarda “them” ve “they” gibi zamirlerin yerine “the staff” ifadesi kullanılabilir.

4.2.3. Çoğunlukla Seçim (MV)

Kolektif Öğrenme stratejileri, birden çok sınıflandırıcının uygulandığı problemlerde, sınıflandırma tahminlerini birleştirilerek, en yüksek performansa sahip sınıflandırıcının seçilmesine ilişkin metodolojiler sunmaktadır. Bu bağlamda Kolektif

Öğrenme, farklı sınıflandırıcıların sonuçlarını birleştirmek ve belirli bir problem için en uygun sınıflandırıcıyı belirlemek için kullanılan bir dizi stratejiye sahiptir [188]. Bu stratejilerin çıktıları belirlenen ortalama, minimum, maksimum, medyan, çoğunluk ve seçim gibi çeşitli yöntemlerle birleştirmektedir [189,190].

Bağımsız sınıflandırıcı tahmin havuzuna sahip bir MV yöntemi için, L sayıda sınıflandırıcıya sahip sınıflandırıcılar arasında benzersiz doğruluk (P) sonuçları kullanılarak, ikili bağımlılık açısından MV'nin alt ve üst doğruluk limitleri türetilebilmektedir.

Eşitlik 1'deki formülde, önce sınıflandırıcılar tarafından $D_i: R^n \rightarrow \Omega$ tanımlı $D = \{D_1, \dots, D_L\}$ eşitliği sınıflandırıcıların bir kümesi olsun, $x \in R^n$ olmak koşuluyla $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ sınıflandırıcı etiketi kümesinde tanımlı sınıf etiketlerinin (x) atanmış olduğu kabul edilmektedir [188,189]. Tek sayıda sınıflandırıcı sayılı, L sayıdaki sınıflandırıcı arasında, $\Omega = \{\omega_1, \omega_2\}$ olmak üzere Eşitlik 1'de ifade edilen binominal formül ile münferit (ayrık) P değerleri için genel P_{maj} değerleri hesaplanmaktadır. Üç sınıflandırıcı için hesaplanan P_{maj} değerleri Çizelge 4.2'de sunulmaktadır. Çizelge 4.2'de koyu yazılmış değerler, deneysel çalışmalardan elde edilen sonuçların doğruluklarının test edilmesi için ele alınan doğruluk parametrelerini ifade etmektedir.

$$P_{maj} = \sum_{m=0}^{L/2} \binom{L}{m} p^{L-m} (1-p)^m \quad (1)$$

Çizelge 4.2. L sayıda bağımsız sınıflandırıcı için münferit doğruluk skorlarına göre MV için hesaplanan maksimum doğruluk skorları.

Münferit Doğruluklar ($p > 0,5$)	L sayıdaki bağımsız sınıflandırıcı için MV doğruluk skorları (L=3)
0.6	0.6480
0.7	0.7840
0,8	0.8960
0.9	0.9720

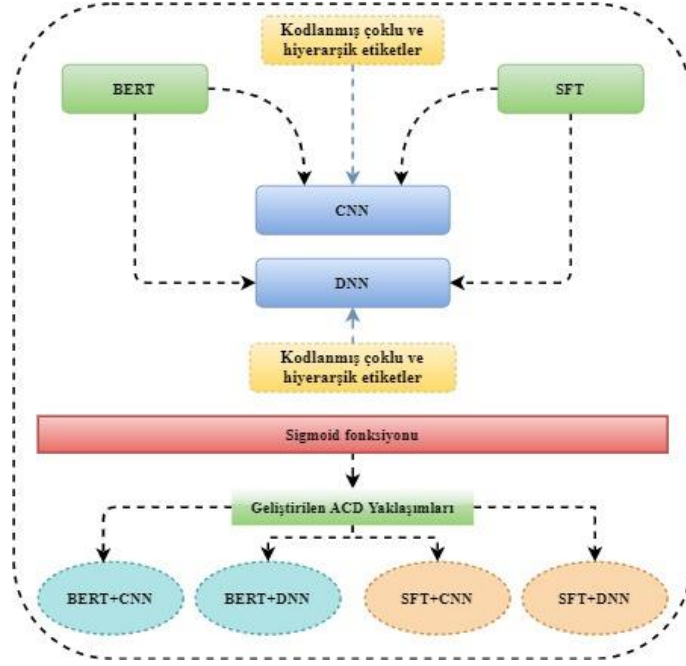
BÖLÜM 5

ÖZELLİK KATEGORİSİ TESPİTİ (ACD) YAKLAŞIMI

Bu bölümde, ilk olarak Bölüm 5.1'de, önerilen ACD yaklaşımının mimarisi ve yaklaşımda uygulanan yöntemler sunulmaktadır. Ardından, Bölüm 5.2'de metodoloji başlığı altında; ilk olarak yaklaşımın sınıflandırıcı modelleri olan CNN ve DNN derin öğrenme modellerine, bu modellerin girdilerinde kullanılan metinlerin kodlanarak semantik vektörlere dönüştürülmesini sağlayan önceden eğitilmiş WEM'lere ve son olarak derin öğrenme modellerinin eğitiminde kullanılan çıktı etiketlerinin model girişlerine uygun bir forma getirilmesi amacıyla kodlanmasına yer verilmektedir.

5.1. ACD YAKLAŞIMI GENEL MİMARİSİ VE BİLEŞENLERİ

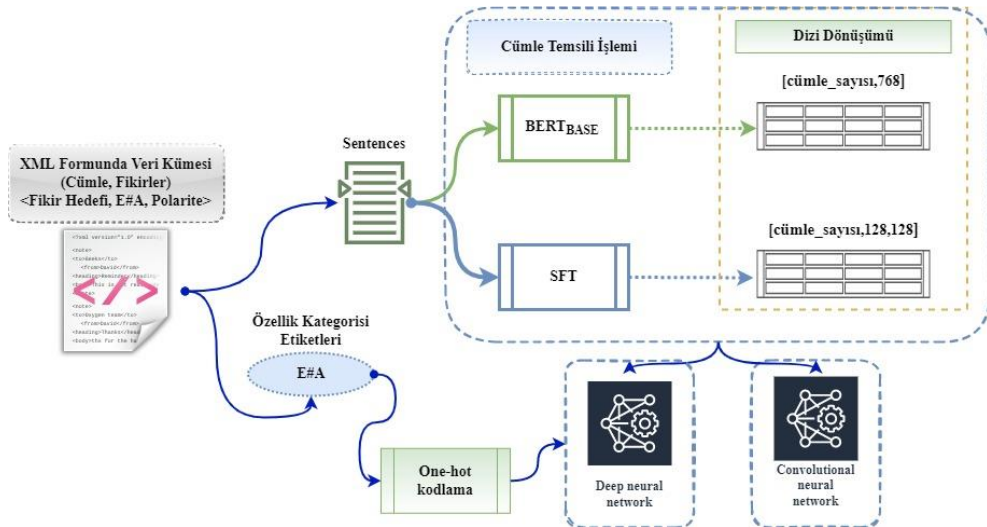
Şekil 5.1'de çoklu ve hiyerarşik yapıda etiketlenmiş inceleme metinleri üzerinde WEM'lerin ve derin öğrenme modellerinin ikili kombinasyonları kullanılarak geliştirilen ACD yaklaşımlarına ilişkin bir görsel sunulmaktadır. Şekil 5.1'de görüldüğü üzere, bu çalışmada önerilen ACD yaklaşımları, BERT ve SFT WEM'leri girdi olarak ayrı ayrı kullanan CNN ve DNN derin öğrenme modelleriyle geliştirilmiştir. Bu sebeple, bu çalışmada ACD görevlerinin gerçekleştirilmesi amacıyla BERT+DNN, BERT+CNN, SFT+DNN ve SFT+CNN şeklinde dört yaklaşım önerilmektedir.



Şekil 5.1. Çoklu ve hiyerarşik yapıda etiketlenmiş inceleme metinleri üzerinde ACD görevlerine ilişkin önerilen yaklaşımlar.

CNN ve DNN tabanlı öğrenme modellerinin eğitiminde kullanılan çıktı etiketleri, ise kodlanarak uygun formlara dönüştürülmüş ve her bir yaklaşıma entegre edilmiştir.

Önerilen ACD yaklaşımlarında yürütülen aşamalara ilişkin genel mimari ve bileşenleri özetleyen görsel Şekil 5.2’de sunulmaktadır.



Şekil 5.2. Önerilen ACD yaklaşımlarına ilişkin genel mimari ve bileşenler.

Şekil 5.2’de görüldüğü üzere, önerilen her bir ACD yaklaşımı iki temel aşamada gerçekleştirilmektedir. İlk aşamada, her bir cümle SFT ve BERT WEM’ler tarafından ele alınarak, semantik nitelikli temsil vektörlerine dönüştürülmektedir. İkinci aşamada üretilen vektör temsilleriyle çoklu ve hiyerarşik yapıdaki özellik kategori etiketlerinin kodlanmış vektörleri kullanılarak, CNN ve DNN derin öğrenme tabanlı metin sınıflandırılmaları gerçekleştirilmektedir. Sınıflandırıcı modellerin eğitiminde kullanılan çıktı etiketleri one-hot kodlama yöntemi ile ikili vektörlere dönüştürülerek kullanılmıştır. Çıktı etiketlerinin kodlanmasına ilişkin yöntem Bölüm 5.2.3’te Çıktı Etiketlerinin Kodlanması başlığı altında ayrıntılı olarak sunulmaktadır.

5.2. METODOLOJİ

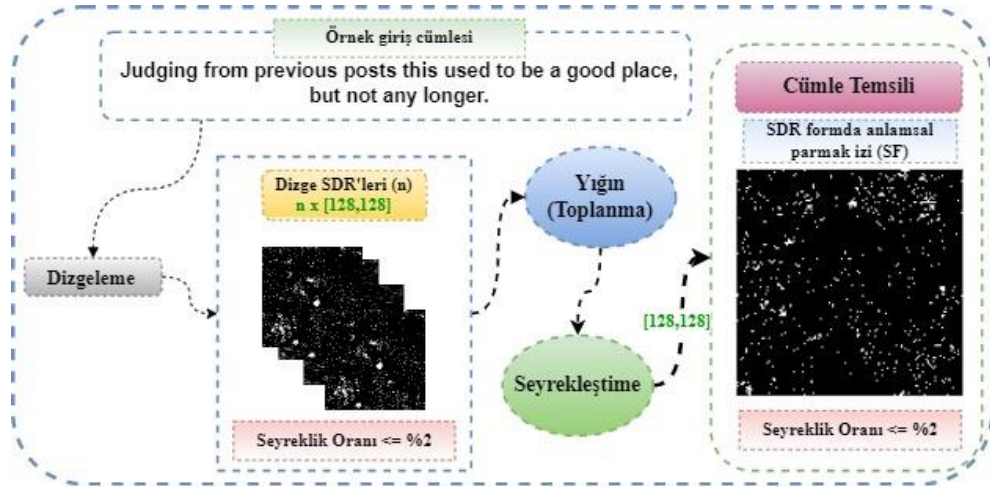
5.2.1. Derin Öğrenme Modelleri (CNN, DNN)

CNN yaklaşımı, genellikle görüntüleri incelemek, tanımlamak veya sınıflandırmak amacıyla evrişim çekirdekleri ve havuzlama teknikleriyle tasarlanmış derin bir sinir ağıdır. Yapılan çalışmalar CNN modelinin Metin Madenciliği ve NLP görevleri alanında uygulanabilirliğini de göstermektedir [191]. CNN ve DNN modelleri, giriş katmanı, çoklu gizli katmanlar ve bir çıkış katmanından oluştuğu için tasarım açısından birbirlerine yakındırlar [192]. DNN, MLP’nin bir uzantısıdır ve birden fazla gizli katmanlı hali olarak kabul edilmektedir [193]. DNN, öğrenme için geri yayılım tekniğini kullanan ileri beslemeli bir sinir ağıdır. Genellikle girdilerin vektörler olarak sunulduğu DNN’de nöronlar katmanlar halinde düzenlenir ve bir katmandaki tüm nöron çıktıları, bir sonraki katmandaki tüm nöronlar için girdi olmaktadır. CNN’de ise DNN’in aksine girdilerde tensör adı verilen n-boyutlu matrisler kullanılmaktadır [194].

5.2.2. Kelime Temsil Modelleriyle Metin Temsillerinin Üretilmesi

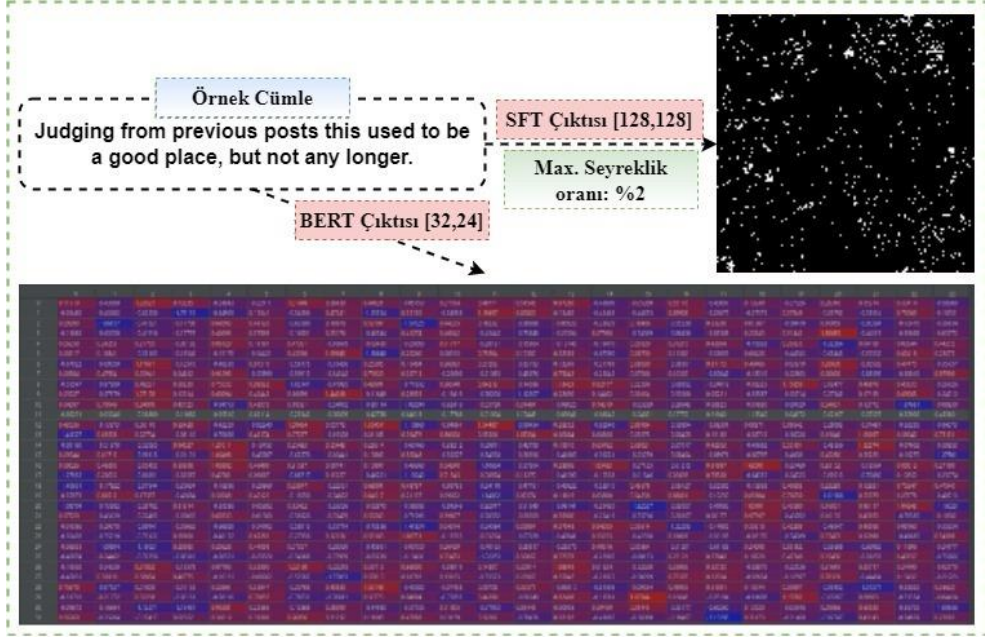
Bu bölümde önerilen ACD görevinin girişinde kullanılan metinlerin (cümlelerin) temsil vektörlerine dönüştürülmesi amacıyla kullanılan SFT ve BERT WEM’ler açıklanmaktadır. Şekil 5.3’te, SFT WEM ile örnek bir inceleme cümlesinin temsilde uygulanan aşamalar sunulmaktadır. Şekil 5.3’te görüldüğü üzere SFT ilk olarak,

verilen cümlelerin her bir dizge için SF'ler oluşturmaktadır. Üretilen bu dizge SF'leri atomik üniteleri temsil eden SDR vektörleridir [161]. İkinci olarak, her bir dizgeye ilişkin SF'ler cümle SDR vektörlerini oluşturabilmek için aralarında toplanmaktadır (yığın edilme). Böylece en sık temsil edilen özellikler en yüksek bit yığınlarını ortaya çıkarmaktadır [154]. Son olarak, uygulanan seyrekleştirme göreviyle oluşan bit yığınları belirli bir eşik değeri kullanılarak seyrekliğin tanımlanmış bir düzeyde kalması (seyreklik oranı) garanti altına alınarak, tüm belirsiz bitler elemine edilmektedir. Böylece en yüksek yığınlara sahip bitlerin, son doküman ya da belge SF'sinde yer alması sağlanmaktadır [158].



Şekil 5.3. SFT kelime temsil modeliyle cümle temsili süreçleri.

SFT gibi ön eğitilmiş bir WEM olan BERT ise bağlama duyarlı temsiller üretiminde Dönüştürücü tabanlı, çok katmanlı ve çift yönlü bir derin öğrenme modeli kullanmaktadır [87]. Bu çalışmada, uygulanan BERT_{BASE}, 12 adet dönüştürücü blok katman sayısına, 12 adet öz-dikkat kafaya ve 110 milyon parametreye sahiptir ve çıktısı ise $n \times 768$ boyutlu matrislerdir [195]. BERT mimarisi kanonikleştirme, dizgeleme görevlerini içeren ön işleme katmanı ve modelin absorbe edildiği ve tanımlandığı hassas ayar katmanı şeklinde iki temel katmandan oluşmaktadır [7]. Şekil 5.4'te örnek bir inceleme cümlesi üzerinde BERT ve SFT WEM'leri tarafından elde edilen metin vektörlerine ilişkin çıktılar ve özellikleri sunulmaktadır. Şekil 5.4'te görüldüğü üzere, BERT cümle vektörleri "[32,24]", SFT cümle vektörleri ise "[128,128]" girdi formlarında derin öğrenme modellerinde kullanılmaktadır.

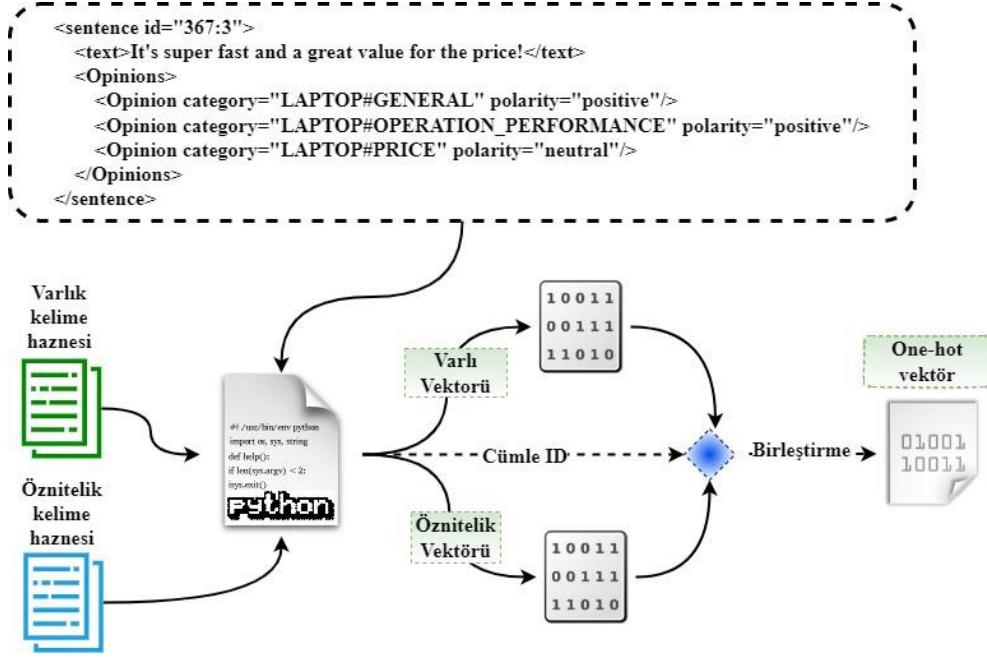


Şekil 5.4. Örnek bir cümle üzerinde BERT ve SFT kelime temsil modeliyle üretilen cümle temsilleri.

5.2.3. Çıktı Etiketlerinin Kodlanması

Önerilen ACD yaklaşımlarında, derin öğrenme modellerinin eğitimde kullanılmak üzere global özellik kategorilerini temsil eden çoklu ve hiyerarşik yapıdaki kategori etiketleri bir one-hot vektörüne kodlanarak uygulanmıştır. Kullanılan inceleme veri setlerine ait cümlelerin her biri ana kategorilerle (E) ve her kategorinin özneteliklerine (A) sahip alt kategorileriyle etiketlenmiştir.

Şekil 5.5'te her bir inceleme metin verisi için tanımlanmış bu çıktı etiketlerinin bir one-hot vektörlere kodlanmasına ilişkin aşamalar sunulmaktadır.



Şekil 5.5. Çıktı etiketlerin bir one-hot vektörüne kodlanması

Şekil 5.5'te görüldüğü üzere ilk olarak her veri setinde yer alan E ve A değerleri için kelime dağılımları oluşturulmuştur. Daha sonra her cümle için E ve A atamalarında kullanılmak üzere ayrı ayrı one-hot vektörler üretilmiştir. Cümleyi niteleyen etiketler için one-hot vektörlerle ilgili indis alanına 1 (bir) değeri atanmıştır. Çoklu etiket durumlarında ise ilgili vektörlerde birden fazla alan 1 (bir) değerliğe sahip olabilmektedir. Son olarak üretilen one-hot vektörler birleştirilerek etiketleri temsil eden tek bir one-hot vektöre dönüştürülmüştür.

BÖLÜM 6

DENEYSEL ÇALIŞMALAR VE PERFORMANS KARŞILAŞTIRMALARI

Bu bölümde, önerilen OTE ve ACD yaklaşımlarının performanslarının test edilmesi amacıyla gerçekleştirilen deneysel çalışmalara ilişkin bilgiler sunulmaktadır. Bölüm 6.1’de gerçekleştirilen deneysel çalışmalarda kullanılan veri setleri, performans metrikleri, görüş sözlükleri ve derin öğrenme modelleri açıklanmaktadır. Bölüm 6.2’de önerilen OTE yaklaşımıyla gerçekleştirilen deneysel çalışmaların sonuçları ve diğer yaklaşımlarla performans yönünden karşılaştırmaları tablolar üzerinde sunulmaktadır. Bölüm 6.3’te ise önerilen ACD yaklaşımlarıyla gerçekleştirilen deneysel çalışmalardan elde edilen sonuçlar ve yaklaşımların her birinin literatürdeki diğer yaklaşımlar arasındaki konumu karşılaştırma tablolarıyla sunulmaktadır.

6.1. DENEYSEL ORTAM

6.1.1. Veri Setleri

Bu çalışmada, OTE ve ACD yaklaşımlarının performanslarını test etmek amacıyla gerçekleştirilen deneysel çalışmalar, çoğu araştırmacı tarafından kıyaslama veri seti olarak kabul edilen SemEval16-ÖTGM’de sunulan restoran ve dizüstü bilgisayar alanlarına (domainlerine) ait inceleme veri setleri [11,50] üzerinde gerçekleştirilmiştir.

Dizüstü bilgisayar veri seti etiketleri, metinleri çoklu veya tekil olarak niteleyen hiyerarşik yapıdaki “özellik kategorisi {E#A}” ve “polarite” verilerinden oluşmaktadır. Özellik kategorisinde (E#A), E veri setine ait bir fikri temsil eden global E varlığını (üst kategori), A ise varlığın öznelik (alt kategori) bilgisini içermektedir. Restoran veri seti etiketleri ise; dizüstü bilgisayar veri seti ile aynı özelliklere sahiptir.

Ancak restoran veri seti ek olarak “OT (opinion target)” ve ofset aralığı etiketlerini de içermektedir. Bu sebeple OTE deneysel çalışmaları, elde edilen çıkarımları doğru değerlendirmek amacıyla halihazırda görüş hedef etiketlerine sahip restoran veri seti üzerinde gerçekleştirilmiştir. ACD yaklaşımı deneysel çalışmaları ise; restoran ve dizüstü bilgisayar inceleme veri setleri üzerinde gerçekleştirilmiştir. Veri setleri ve XML yapıları hakkında tanımlayıcı bilgiler aşağıdaki Çizelge 6.1’de sunulmaktadır [42].

Çizelge 6.1. Kullanılan veri setlerine ilişkin tanımlayıcı istatistiksel bilgiler.

Kriterler	Restoran	Dizüstü bilgisayar
İnceleme sayısı	350	450
Cümle sayısı	2000	2500
Görüş etiketli cümle sayısı	1708	2039
Toplam görüş etiketi sayısı	2507	2909
Tanımlı kategori sayısı (E)	6	22
Tanımlı öznitelik sayısı (A)	5	9
Görüş etiketine sahip her cümle için ortalama etiket sayısı	1.468	1.427
Görüş etiketine sahip her cümle için min /max etiket sayısı	1-8	1-5
OT’lerin kelime aralıkları (min/max)	1-15	-
OT sayısı (Tek kelimeli/çift kelimeli/iki kelime üstü/üç kelime üstü)	1409, 316, 507, 191, 72	-
XML Formda Kullanılan Veri Setlerinin Genel Yapısı		
<pre> <text> &sentenceID - &sentence </text> <Opinions> <Opinion target= &OTE category=&E#A polarity=&polarity from=&startingoffset to=&endingoffsets /> </Opinions> </pre>		

6.1.2. Performans Metrikleri

OTE ve ACD yaklaşımlarına ilişkin deneysel çalışmalarda, yaklaşımların performanslarını değerlendirmek için, kesinlik (p), duyarlılık (r), f_1 skor (f), ve doğruluk (accuracy) şeklinde dört metrik kullanılmıştır. Bu metriklerde kullanılan doğru-pozitif (TP), doğru-negatif (TN), yanlış-pozitif (FP) ve yanlış-negatif (FN) parametrelerinin detayları aşağıda sunulmaktadır.

TP: Sınıfı pozitif olan ve yaklaşımlar tarafından pozitif olarak sınıflandırılmış sınıflandırma sayısını temsil etmektedir.

TN: Sınıfı negatif olan ve yaklaşımlar tarafından negatif olarak sınıflandırılmış sınıflandırma sayısını temsil etmektedir.

FP: Sınıfı negatif olan ve yaklaşımlar tarafından pozitif olarak sınıflandırılmış sınıflandırma sayısını temsil etmektedir.

FN: Sınıfı pozitif olan ve yaklaşımlar tarafından negatif olarak sınıflandırılmış sınıflandırma sayısını temsil etmektedir.

Kullanılan bu metriklerden mikro-p skoru Eşitlik 2’de, mikro -r skoru Eşitlik 3’te, mikro-f skoru Eşitlik 4’te ve doğruluk skoru ise Eşitlik 5’te verilen matematiksel eşitliklerle hesaplanmaktadır.

$$\text{mikro - p} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{mikro - r} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{mikro - f} = \frac{p \times r}{p + r} \quad (4)$$

$$\text{doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

6.1.3. Görüş Sözlükleri

Çoğu GM uygulamasında, kelimelerin bir polarite değeriyle ilişkilendirmede görüş sözlükleri önemli bir role sahiptir. ÖTGM’de yaygın olarak bu polarite değerlerine sahip görüş sözcükleri kullanılarak farklı düzeylerde analizler yapılabilmektedir. Sözlük tabanlı yöntemler, bu kelimelerin polarite skorlarını veya kategorilerini

belirleme görevini gerçekleştirmektedir [28]. Polarite değerleri, sözlük kaynağının genişliğine ve kapasitesine bağlı olarak belirli kategorilerde (pozitif, negatif, nötr) veya normalleştirilmiş sayısal aralıklarda elde edilmektedir. Bir polarite sözlüğü olan SenticNet; yapay zeka, dilbilim ve psikoloji alanlarıyla ilgili 200.000'den fazla doğal dil kavramını ve cümle bilgisi içeren kavram düzeyinde duygu analizi için geliştirilmiş herkese açık bir bilgi kaynağıdır [110]. SentiWordNet, SenticNet'e ilham vermiş olsa da SenticNet'e göre performans, işlevsellik bakımından daha esnek sonuçlar üretebilmektedir. SentiWordnet, her WordNet kelimesi için üç sayısal polarite puanına (pozitif, negatif, nötr) dayalı çıktılar üretir. SenticNet, kategorik çıktılar yerine [-1.0, +1.0] aralığında polarite değerleri üretmektedir. Bu sayede OTE görevlerinde, üretilen bu polarite değerleri daha esnek ve karmaşık analizleri gerçekleştirmeyi mümkün hale getirmektedir [33].

SenticNet'e alternatif olarak bu çalışmada polarite analizörü olarak uygulanan TextBlob, NLP görevlerini gerçekleştirebilen ve cümlelerin veya kelimelerin polarite değerlerini hesaplayabilen açık kaynaklı bir yazılım kütüphanesidir. TextBlob'ta hesaplanan polarite değerleri, Naive Bayes tabanlı analizör tarafından hesaplanmaktadır [111]. Bu bağlamda TextBlob, çıktı olarak "polarite, öznellik" formunda değer çiftleri üretmektedir. Polarite ve öznellik skorları [-1.0, 1.0] ve [0.0, 1.0] aralığında değerlere sahiptir. Öznellik puanı 0.0 için "çok nesnel", 1.0 için ise "çok öznel" anlamına gelmektedir.

VADER, metin verileri üzerinde doğrudan çalışabilen ve polarite sınıflarına (negatif, nötr, pozitif) ek olarak polarite yoğunluğunu da hesaba katarak daha hassas bir analiz imkanı sağlayan MIT lisansına sahip açık kaynaklı bir yazılım kütüphanesidir [112]. Literatürde VADER, Naive Bayes, Maximum Entropy ve SVM gibi makine öğrenmesi teknikleriyle kullanıldığında, LIWC, ANEW, General Inquirer ve SentiWordNet gibi sözlüklere göre etkin performanslar gösterdiği belirtilmiştir [113]. VADER'de polarite sınıflarının yanı sıra bileşik (compound) olarak adlandırılan özellik değeriyle tek bir sınıf ve skor elde etmek mümkündür. Bileşik skoru, sözlükteki her kelimenin bir kurala bağlı olarak ayarlanmış değerlik skorlarının toplanmasıyla hesaplanmaktadır ve hesaplanan bu skorlar [-1,+1] aralığında normalleştirilmiştir [113]. Bu aralıkta -1 "en olumsuz" ve +1 "aşırı pozitif" anlamına gelmektedir.

Arařtırmacılar, bileşik skoru $[0.05,1.0]$ aralıęında pozitif, $[-0.05,-1.0]$ aralıęında negatif ve $(-0.05, +0.05)$ aralıęında ise nötr olmak üzere standart üç kategoride ele alınmasını önermektedir.

6.1.4. Derin Öğrenme Modelleri (CNN ve DNN)

Geliştirilen ACD yaklaşımlarında kullanılan derin öğrenme modelleri çoklu ve hiyerarşik yapıya sahip inceleme metinleri üzerinde yapılandırılmıştır. Böylece yaklaşımlarda sınıf etiketleri veya sınıf üyelikleri birbirini dışlamamakta ve daha fazla sınıf etiketleri arasındaki olasılıęın tahmin edilmesi amaçlanmaktadır [81]. Yaklaşımların eğitiminde ele alınan çıktı etiketlerinin sayısı doğrudan sinir aęı tarafından düęüm sayısı olarak belirlenmektedir. Bu amaçla bir önceki bölümde açıklanan çıktıların kodlanması göreviyle, düęüm sayılarının tanımlanmasına olanak sağlanmıştır. Bu amaçla çalışmamızda restoran veri seti için 11, dizüstü bilgisayar veri seti için ise 31 çıktılı bir yapı oluşturulmuştur. Çıkış katmanındaki etiketlerin birbirini dışlamayan bir yapıda olduğundan her düęüm için “binary cross-entropy loss function” ile uyumlu sigmoid aktivasyonunu uygulanmıştır [193]. Gizli katmanlarda ise ReLU fonksiyonu kullanılmıştır.

6.1.4.1. Derin Öğrenme Modelleri Hiperparametre Deęerleri

Bu çalışmada önerilen ACD yaklaşımlarının gerçekleştirilmesinde kullanılan CNN ve DNN sınıflandırıcı modellerinin ampirik olarak belirlenen hiperparametre deęerleri Çizelge 6.2 ve Çizelge 6.3’te sunulmaktadır. Çalışmada kullanılan inceleme metinleri çok etiketli birbirini dışlamayan yapılarda ele alınmıştır. Bu sebeple çıkış aktivasyon fonksiyonu olarak uygulanan derin aęların çıkış katmanında softmax fonksiyonu yerine binary cross-entropy loss function ile uyumlu sigmoid fonksiyonu kullanılmıştır [193]. Test verileri ise tablolarda verilen eğitim oranı varyasyonlarına göre belirlenmektedir.

Çizelge 6.2. CNN modeli için eğitimde kullanılan hiperparametreler.

CNN modeli eğitim hiperparametreleri	Kelime Temsil Modelleri	
	BERT _{BASE}	SFT
Çıkış aktivasyon fonksiyonu	Sigmoid	
Her bir evrişim (convolution) katmanı için aktivasyon fonksiyonu	ReLU	
Giriş formu	[32, 24, 1]	[128,128,1]
Evrişim katmanı sayısı (min.-maks.)	3-5	
Tam bağlantılı/yoğunluk (dense) katmanı- çıktı katmanı sayısı	2 - 1	
Filtre formu	2d	
Normalizasyon türü	Yığın (batch) norm	
Her evrişim katmanının çekirdek sayısı	8, 16, 32, 64,128	
Her evrişim katmanındaki çekirdek boyutu	(4,4)	(6,6)
Her evrişim katmanından sonra havuzlama boyutu	(2,2)	
Her tam bağlantılı/yoğunluk katmanının nöron sayısı	128, 64, çıktı uzunluğu	
Dropout (Evrişim, Dense)	(0.2 , 0.5)	
Kayıp fonksiyonu	“binary crossentropy”	
Optimize edici fonksiyon	“adam”	
Tur (epoch) sayısı	30, 100	
Yığın uzunluğu	64	
Eğitim oranı	0.20, 0.25, 0.30	

Çizelge 6.3. DNN modeli için eğitimde kullanılan hiperparametreler.

DNN modeli eğitim hiperparametreleri	Kelime Temsil Modelleri	
	BERT _{BASE}	SFT
Çıkış aktivasyon fonksiyonu	Sigmoid	
Her tam bağlantılı yoğunluk katmanındaki aktivasyon fonksiyonu	ReLU	
Giriş formu	[32, 24, 1]	[128,128,1]
Tam bağlantılı/yoğunluk katmanı- çıktı katmanı	2 - 1	
Normalizasyon	Yığın (batch) norm	
Tam bağlantılı/yoğunluk katmanı nöron sayısı	256, 128, 64, 32, çıktı uzunluğu	
Kayıp fonksiyonu	“binary crossentropy”	
Optimize edici fonksiyon	“adam”	
Tur (epoch) sayısı	10, 30, 50, 100	
Yığın uzunluğu	64	
Eğitim oranı	0.20, 0.25, 0.30	

6.2. OTE YAKLAŞIMI DENEYSEL ÇALIŞMALARI VE PERFORMANS KARŞILAŞTIRMALARI

Gerçekleştirilen deneysel çalışmalar sonucunda yapılan analizlere göre, önerilen OTE yaklaşımının çıkarım performansı mikro-f skor metriği kullanılarak 0.70003 olarak ölçülmüştür. Deneysel çalışmalardan elde edilen performans sonuçları; girişte uygulanan PBP yönteminin, cümle ayrıştırımlı NBCR modelinin, genişletilmiş sözdizimsel tabanlı bağıllık ilişki kuralları algoritmalarının ve MV yönteminin özellik çıkarımı süreçlerine dahil edilmesiyle elde edilmiştir. Gerçekleştirilen deneysel çalışmalarda, Bölüm 6.1.1'de detaylandırılan restoran incelemeleri veri seti kullanılmıştır. Bu bağlamda önerilen OTE yaklaşımının başarısı çıkarımların söz konusu veri seti üzerindeki etiketli görüş hedef ifadeleriyle karşılaştırılması sonucu değerlendirilmiştir. Ayrıca bu bölümde literatürde OTE amacıyla söz konusu veri seti kullanılarak gerçekleştirilen ilgili diğer çalışmalar ve performans sonuçları da sunulmaktadır. Bu sayede, önerilen yaklaşımın performansı ile benzer amaçlarla sunulan diğer yaklaşımların performanslarının karşılaştırılmasına olanak sağlanmıştır. Bu bağlamda Çizelge 6.4'te, SemEval16-ÖTGM'de yer alan OTE amacıyla özelleştirilmiş 5 numaralı görev için; mikro-f skor metriğine göre ilgili bildiri kitapçığında raporlanan çalışmaların performans sonuçları sunulmaktadır. Ancak Çizelge 6.4'te bildiri kitapçığında raporlanan tüm sonuçlar yerine karşılaştırmalarını sadeleştirmek adına sadece performans skorları 0.5'den yüksek olan çalışmalara yer verilmiştir [42]. Çizelge 6.5'te ise, önerilen OTE yaklaşımını güncel diğer çalışmalarla karşılaştırılabilmek amacıyla SemEval16'da raporlanan çalışmalar dışındaki ilgili diğer çalışmaların performans sonuçları sunulmaktadır.

Çizelge 6.4. Restoran veri seti için SemEval16-ÖTGM’de Görev 5 için raporlanan çalışmaların öğrenme yöntemleri, metin ön işleme teknikleri, öğrenme modelleri, mikro-f skor metriğinde ölçülen performans sonuçları ve önerilen yaklaşımın denetimli yaklaşımlar arasındaki konumu.

Çalışma Kısaltması	Öğrenme Yöntemi	Metin Ön İşleme Tekniği	Öğrenme Modeli	Mikro-f skor
NLANGP	Denetimli	-	RNN+CRF	0.7234
AUEB	Denetimli	Büyük/küçük harf, rakam ve noktalama işaretleri gibi kontroller	CRF	0.70441
Önerilen OTE Yaklaşımı	Denetimsiz	Örüntü Tabanlı	Kural tabanlı	0.70003
UWB	Denetimli	Kök çözümlenme, frekanslı POS-n	CRF	0.67089
GTI	Denetimli	POS işaretleme ve kök çözümlenme	CRF	0.66553
SentiSys	Denetimli	Bölümlendirmeyi, cümle dizgeleme ve cümle etiketlemeyi gözden geçirme	CRF	0.66545
buñji	Denetimli	Sözlük oluşturma	RNN	0.64882
DMIS	Denetimli	-	-	0.63495
XRCE	Denetimli	Kök çözümlenme, sözdizimsel ayrıştırıcı	CRF + Geri Bildirimli Kolektif Öğrenme Modeli	0.6198
UWate	Denetimli	Tohum kelime çıkarma	Bağlılık Ayrıştırma+ MWUs +NPMI	0.57067
KnowC	Denetimli	POS işaretleme	Ön eğitilmiş kelime vektörleri	0.56816
TGB	Denetimli	HTML kodlarını/URL'leri kaldırma, kök çözümlenme ve gövdeleme	Çok dilli sistem	0.55054
BUAP	Denetimli	-	-	0.50253

Çizelge 6.4 'te görülebileceği üzere, en düşük mikro-f skoru 0.50253'tür. Ortalama mikro-f skoru ise 0.6271'dir. Önerilen yaklaşımla elde edilen mikro-f skoru ortalama mikro-f skordan daha yüksektir. Ayrıca elde edilen mikro-f skorlarına göre raporlanan diğer 12 yaklaşımdan daha yüksek performans elde edilmiştir. Önerilen yaklaşımın

AUEB yaklaşımından farkı 0.00438'dir. Önerilen OTE yaklaşımının performansı, en başarılı denetimli NLANGP yaklaşımıyla karşılaştırılabilir ölçekte ve söz konusu yaklaşımın performansına ise çok yakındır.

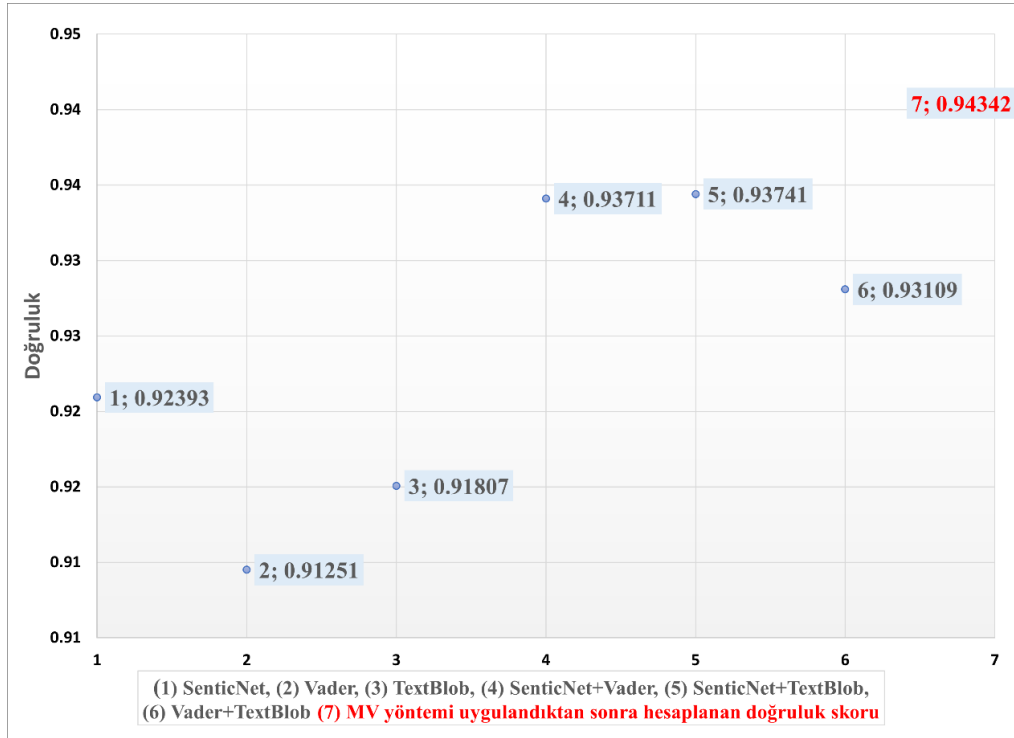
Önerilen OTE yaklaşımının, literatürde yer alan ve aynı veri setini kullanan diğer denetimsiz yaklaşımlarla [11,33,50] karşılaştırılması amacıyla Çizelge 6.5 hazırlanmıştır. Çizelge 6.5'te literatürdeki denetimsiz yaklaşımların; öğrenme modelleri, ön işleme yöntemleri ve mikro-f skorları listelenmektedir.

Çizelge 6.5.Restoran veri seti için ilgili diğer çalışmaların, öğrenme yöntemleri, metin ön işleme teknikleri, eğitim modelleri, mikro-f skor metriğinde ölçülen performans sonuçları ve önerilen yaklaşımın denetimsiz yaklaşımlar arasındaki konumu.

Çalışma Adı	Öğrenme Yöntemi	Ön İşleme	Öğrenme Model	Mikro-f skor
Dragoni, M., ve ark. [33]	Denetimsiz	WordNet destekli olarak etkisiz kelimeleri kaldırma	Kural tabanlı	0.6687
Chauhan, Ganpat Singh, ve ark.[11]	Denetimsiz	Dizgeleme, küçük harf kontrolü	Kural tabanlı	0.6455
Wu, Chuhan, ve ark. [50]	Denetimsiz	Kelime sayısı eşik değeri ve sayısal ve sayısal+harf şeklindeki kelimelerin kontrolü ve dönüştürülmesi	Kural tabanlı ve Makine Öğrenmesi	0.6424
Önerilen OTE Yaklaşımı	Denetimsiz	Örüntü Tabanlı	Kural tabanlı	0.70003

Çizelge 6.5'te görüldüğü üzere, ilgili çalışmalar arasında ölçülen en düşük mikro-f skoru 0.64240 ve en yüksek mikro-f skoru 0.66870'tir. Ortalama mikro-f skoru ise 0.6522'dir. Önerilen OTE yaklaşımıyla, en yüksek performansa sahip yaklaşımın performansına göre yaklaşık 0.0313'lük performans iyileştirilmesi sağlanmıştır.

Gerçekleştirilen çalışmada, görüş sözlükleri (SenticNet, VADER, TextBlob) çıktıları MV yöntemi ile birleştirilerek, en uygun sınıflandırıcı seçilmiştir. Şekil 6.1’de, çalışmada uygulanan polarite analizör (görüş sözlükleri) modellerinin tekil ve ikili kombinasyonları şeklinde değerlendirilmelerine ilişkin doğruluk skorları grafiksel olarak sunulmaktadır. Şekil 6.1’de, MV yöntemi uygulandıktan sonra ölçülen genel doğruluk skoru ise kırmızı renkte gösterilmektedir.



Şekil 6.1. SenticNet, Vader ve TextBlob polarite analizörlerinin tekil ve ikili kombinasyonlarıyla ölçülen doğruluk skorları ve MV yönteminden sonra hesaplanan genel doğruluk skoru.

Şekil 6.1’de görüldüğü üzere, MV yönteminden sonra önerilen OTE yaklaşımının doğruluk skoru 0.94342 olarak ölçülmüştür. Böylece, sınıflandırıcı modelleri üzerinde MV yönteminin uygulanmasıyla daha yüksek bir doğruluk skoru elde edilmiştir. Bölüm 4.2.3’te Çoğunlukla Seçim başlığı altında açıklanan Eşitlik 1 kullanılarak hesaplanan değerlere göre; gerçekleştirilen OTE yaklaşımıyla tutarlı sonuçların elde edilmiş olduğu doğrulanmaktadır.

6.3. ACD YAKLAŞIMLARI DENEYSEL ÇALIŞMALAR VE PERFORMANS KARŞILAŞTIRMALARI

Önerilen ACD yaklaşımlarının sınıflandırma performanslarını test etmek amacıyla gerçekleştirilen deneysel çalışmalarda, uygulanan derin öğrenme modelleri Çizelge 6.1.4’te detayları sunulan hiperparametre değerleri kullanılarak, restoran ve dizüstü bilgisayar inceleme veri setleri üzerinde eğitilmiştir. Çizelge 6.6’da SFT+DNN, SFT+CNN, BERT+DNN ve BERT+CNN ACD yaklaşımlarıyla uygun tur sayılarında ulaşılan maksimum ve ortalama sınıflandırma performanslarının mikro-f, mikro-p ve mikro-r türünden metrik sonuçları sunulmaktadır.

Çizelge 6.6. BERT ve SFT WEM’lerini girdi olarak kullanan CNN ve DNN derin öğrenme tabanlı ACD yaklaşımlarının deneysel çalışmalar sonucu elde edilen ortalama ve maksimum sınıflandırma performansı skorları.

Veri Setleri	Uygulanan ACD yaklaşımları	Ortalama			Maksimum		
		mikro-f	mikro-p	mikro-r	mikro-f	mikro-p	mikro-r
RESTORAN	SFT + DNN	0.7621	0.7275	0.8027	0.7702	0.7409	0.8134
	BERT + DNN	0.7903	0.7675	0.8164	0.7962	0.7817	0.8316
	SFT + CNN	0.7165	0.7584	0.6812	0.7362	0.7818	0.7275
	BERT + CNN	0.7381	0.8198	0.6722	0.7749	0.8331	0.7242
	Ortalama:				0.7694	0.7844	0.7742
DİZÜSTÜ BİLGİSAYAR	SFT + DNN	0.7059	0.6540	0.7695	0.7144	0.6727	0.7695
	BERT + DNN	0.7136	0.6712	0.7648	0.7279	0.6933	0.7820
	SFT + CNN	0.6060	0.7374	0.5161	0.6446	0.7545	0.5710
	BERT + CNN	0.6289	0.7441	0.5484	0.6720	0.7774	0.6199
	Ortalama:				0.6897	0.7245	0.6856

Çizelge 6.6’ da önerilen ACD yaklaşımlarının sınıflandırma sonuçlarına, aşırı uyum (overfitting) durumu göz önünde bulundurularak ortalama 30 tur sayısında (epoch) ulaşılmıştır. Çizelge 6.6 incelendiğinde mikro-f ve mikro-r metriklerinde en iyi sınıflandırma performans değeri BERT WEM’ini girdi olarak kullanan DNN tabanlı yaklaşımla elde edilmiştir. Restoran veri seti üzerinde uygulanan yaklaşımların sınıflandırma performansları incelendiğinde, maksimum mikro-f skoru 0.7962, mikro-p skoru 0.8331 ve mikro-r skoru ise 0.8316 olarak ölçülmüştür. Dizüstü bilgisayar veri

seti üzerinde ise ulaşılan maksimum mikro-f skoru 0.7279, mikro-p skoru 0.7774 ve mikro-r skoru ise 0.7820 olarak ölçülmüştür. Restoran veri seti için ortalama mikro-f skoru 0.7903, mikro-p skoru 0.8198 ve mikro-r skoru ise 0.8164 olarak hesaplanmıştır. Dizüstü bilgisayar veri setinde ise mikro-f skoru için 0.7136, mikro-p skoru için 0.7441 ve mikro-r skoru için 0.7648 şeklinde en iyi ortalama değerlere ulaşılmıştır. Ölçülen doğruluk, mikro-f ve mikro-r metrik sonuçlarına göre her iki veri seti için en iyi ikinci performans SFT WEM kullanan DNN yaklaşımıyla elde edilmiştir. Mikro-p sonuçlarına bakıldığında ise BERT WEM modelinin uygulandığı CNN tabanlı yaklaşım her iki veri seti üzerinde de en iyi sınıflandırma performansını göstermiştir. Ayrıca ölçülen mikro-f skorlarına göre restoran veri setine ait en iyi performansa sahip sonuçlar tam bağlantılı/yoğunluk ve çıktı katmanlarının nöronlarının sayısı 128,64,11 şeklinde düzenlenen DNN yaklaşımıyla elde edilmiştir. Yine mikro-f skorlarına göre dizüstü bilgisayar veri seti üzerinde alınan en iyi sonuçların elde edildiği DNN tabanlı yaklaşımında, tam bağlantılı/yoğunluk ve çıktı katmanlarının nöronlarının sayısı 256,128,31 şeklinde düzenlenmiştir.

Çizelge 6.7’de, restoran ve dizüstü bilgisayar inceleme veri setleri için, SemEval16-ÖTGM’nin bildiri kitapçığında 5 numaralı görev için mikro-f metriğine göre raporlanan yaklaşımların performansları önerilen yaklaşımlarla kıyaslanmak amacıyla sunulmaktadır. SemEval16-ÖTGM bildiri kitapçığında restoran veri seti için 30, dizüstü bilgisayar veri seti için ise 22 adet çalışma raporlanmıştır [42]. Ancak, Çizelge 6.7’de raporlanan tüm çalışmalar yerine her bir veri seti için en yüksek performans gösteren ilk 10 çalışma WEM’leri ve öğrenme modelleriyle birlikte detaylandırılarak listelenmektedir. Çizelge 6.7’de koyu yazılmış değerler bu çalışmada önerilen ACD yaklaşımlarının mikro-f skorlarını belirtmektedir.

Çizelge 6.7. Restoran ve dizüstü bilgisayar incelemeleri için SemEval-ÖTGM 2016 bildiri kitapçığında raporlanan ACD yaklaşımlarının mikro-f metriğine göre ölçülen sınıflandırma performansı sonuçları.

Restoran				Dizüstü bilgisayar			
Kısaltma	WEM	Öğrenme Modeli	mikro-f	Kısaltma	WEM	Öğrenme Modeli	mikro-f
NLANGP (U)	Word2vec, GloVe	CNN	0.73031	NLANGP (U)	Word2vec, GloVe	CNN	0.51940
NileT	-	-	0.72886	AUEB (U)	El yordamı mühendislik, skip-gram	CRF	0.49105
BUTkn (U)	-	-	0.72396	SYSU	-	-	0.49076
AUEB (U)	El yordamı mühendislik, skip-gram	CRF	0.71537	BUTkn (U)	-	-	0.48396
BUTkn (C)	-	-	0.71494	UWB (C)	GloVe , CBOW, hand crafted	Maximum entropy	0.47891
SYSU	-	-	0.70869	BUTkn (C)	-	-	0.47527
XRCE	Sözlüksel anlamsal özellikler, bigramlar ve trigramlar (el yordamı mühendislik)	CRF	0.68701	UWB (U)	GloVe , CBOW, el yordamı mühendislik	Maximum entropy	0.47258
UWB (U)	GloVe , CBOW, el yordamı mühendislik	Maximum entropy	0.68203	NileT	-	-	0.47196
INSIG	GloVe	CNN	0.68108	NLANG (C)	word2vec, GloVe	CNN	0.46728
ESI	-	-	0.67979	INSIG (U)	GloVe	CNN	0.45863
Önerilen ACD Yaklaşımı (1)	BERT	DNN	0.7903	Önerilen Yaklaşım (1)	BERT	DNN	0.7136
Önerilen ACD Yaklaşımı (2)	SFT	DNN	0.7621	Önerilen Yaklaşım (2)	SFT	DNN	0.7059
Önerilen ACD Yaklaşımı (3)	BERT	CNN	0.7381	Önerilen Yaklaşım (3)	BERT	CNN	0.6289
Önerilen ACD Yaklaşımı (4)	SFT	CNN	0,7165	Önerilen Yaklaşım (4)	SFT	CNN	0.6060

Çizelge 6.7’de görüldüğü üzere, restoran inceleme veri seti için bildiri kitapçığında raporlanan en düşük mikro-f skoru 0.67979, en yüksek mikro-f skoru 0.73031’dir. Raporlanan tüm çalışmaların genel ortalaması ise 0.7052’dir. Çizelge 6.7 incelendiğinde, önerilen BERT+DNN, SFT+DNN ve BERT+CNN yaklaşımlarıyla diğer yaklaşımlara göre daha yüksek ACD performans sonuçları elde edilmiştir. Bu çalışmada, önerilen yaklaşımlar arasında en yüksek performans değerine 0.7903 mikro-f skoru ile BERT+DNN yaklaşımıyla ulaşılmıştır. Önerilen BERT+DNN yaklaşımıyla bildiri kitapçığında raporlanan en yüksek performansa sahip çalışma kıyaslandığında 0.06 değerlikte performans iyileştirmesi sağlandığı görülmektedir. Bu çalışmada en yüksek ikinci performans değeri 0.7621 mikro-f skoruyla SFT+DNN yaklaşımının uygulanmasıyla ölçülmüştür. Bu yaklaşımla raporlanan en yüksek performansa sahip çalışmaya göre 0,032 değerlikte performans iyileştirmesi gerçekleştirilmiştir. Bu çalışmada önerilen en yüksek performansa sahip üçüncü yaklaşım ise BERT+CNN yaklaşımıdır. BERT+CNN yaklaşımıyla raporlanan en yüksek performanslı çalışmaya göre yaklaşık 0.007 değerlikte performans iyileştirmesi elde edilmiştir. Bu çalışmada önerilen dördüncü yaklaşım olan SFT+CNN yaklaşımıyla, raporlanan diğer çalışmaların genel performans ortalamasından daha yüksek performans sonuçlarına ulaşılmıştır. Ayrıca önerilen SFT+CNN yaklaşımıyla yüksek performanslı yaklaşımlara yakın ve rekabetçi performans değerleri elde edildiği gözlemlenmiştir.

Dizüstü bilgisayar incelemeleri için, Çizelge 6.7 incelendiğinde en düşük performanslı çalışmanın mikro-f skoru 0.45863, en yüksek performanslı mikro-f skoru ise 0.51937’dir. Dizüstü bilgisayar veri seti için kıyaslanan tüm çalışmaların genel ortalaması ise 0.48098’dir. Bu çalışmada, Dizüstü bilgisayar veri seti için sunulan tüm ACD yaklaşımlarıyla, diğer ACD yaklaşımlarına göre daha yüksek mikro-f skorları elde edilmiştir. Sunulan yaklaşımlar arasında 0.7136 olarak ölçülen en yüksek performans değerine BERT+DNN yaklaşımıyla ulaşılmıştır. Ayrıca BERT+DNN yaklaşımıyla, raporlanan en yüksek performansa sahip çalışmaya göre 0.194 değerlikte bir performans iyileştirilmesi gerçekleştirilmiştir. İkinci en iyi performans SFT+DNN yaklaşımıyla elde edilmiştir. SFT girdili DNN tabanlı yaklaşımla, diğer çalışmalara göre 0.187 değerlikte performans iyileştirmesi gerçekleştirilmiştir. Bu çalışmada değerlendirilen diğer ACD yaklaşımlarının performansları analiz edildiğinde;

BERT+CNN yaklaşımı ile 0.11 değerlikte, SFT+CNN yaklaşımıyla ise 0,087 değerlikte performans iyileştirilmeleri sağlanmıştır.

Yukarıda sunulan performans karşılaştırmalarına ek olarak Çizelge 6.8’de ilgili diğer güncel çalışmaların performans sonuçları, WEM ve öğrenme modelleriyle birlikte sunulmaktadır.

Çizelge 6.8. Restoran ve dizüstü bilgisayar incelemeleri üzerinde literatürde sunulan diğer ilgili ACD yaklaşımların WEM’leri, öğrenme modelleri ve f-skor metriğine göre ölçülen sınıflandırma performansı sonuçları.

Önerilen yaklaşımların ve ilgili diğer çalışmalara ait yapısal özellikler			Veri setleri	
			Restoran	Dizüstü bilgisayar
Önerilen yaklaşımlar ve ilgili diğer çalışmalar	WEM	Öğrenme Modeli	mikro-f	mikro-f
[35]	GloVe	Çok katmanlı CNN’ler	0.9245	0.6982
[12]	Word2vec, Apache Spark MLlib	W2VLDA	0,7810	-
[196]	GloVe	Çok görevli öğrenme sinir ağları ile birleştirilmiş Çift Yönlü LSTM ve CNN	0.7642	-
[197]	Word2vec + Graf CNN	Çift Yönlü GRU	71.818	-
Önerilen Yaklaşım (1)	BERT	DNN	0.7903	0.7136
Önerilen Yaklaşım (2)	SFT	DNN	0.7621	0.7059
Önerilen Yaklaşım (3)	BERT	CNN	0.7381	0.6289
Önerilen Yaklaşım (4)	SFT	CNN	0,7165	0.6060

Çizelge 6.8 incelendiğinde restoran veri seti için ilgili diğer çalışmalarda en yüksek mikro-f skoru 0.9245 olarak raporlanmıştır. Dizüstü bilgisayar için ise 0.6982 olarak raporlanmıştır. Çizelge 6.8’de görüldüğü üzere, restoran veri seti üzerinde BERT+DNN yaklaşımı tüm çalışmalar arasında en iyi ikinci yaklaşım durumundadır. Dizüstü bilgisayar incelemeleri üzerinde ise önerilen BERT+DNN ve SFT+DNN yaklaşımlarıyla en yüksek performans sonuçlarına ulaşılmıştır. Ayrıca önerilen diğer yaklaşımlardan (BERT+CNN, SFT+CNN) ise her iki veri setinde de rekabetçi performans değerleri elde edilmiştir.

BÖLÜM 7

BULGULAR VE TARTIŞMA

Bu bölümde, tez çalışmasında önerilen Görüş Hedefi Çıkarımı (OTE) ve Özellik Kategorisi Tespiti (ACD) yaklaşımlarını test etmek amacıyla gerçekleştirilen deneysel çalışmaların analizleri sonunda ulaşılan bulgular ve sonuçlar değerlendirilmektedir. Bölüm 7.1’de önerilen OTE yaklaşımına ilişkin bulgular ve sonuçlar, Bölüm 7.2’de ise önerilen ACD yaklaşımlarına ilişkin bulgular ve sonuçlar sunulmaktadır.

7.1. ÖNERİLEN OTE YAKLAŞIMI BULGULARI VE SONUÇLARI

7.1.1. OTE Yaklaşımı Bulguları

Çalışmamızda elde edilen deneysel çalışmaların sonuçları; PBP yöntemi, genişletilmiş sözdizilimsel bağıllık ilişki kuralları ve MV yönteminin OTE performansına katkıda bulunduğunu göstermiştir. Önerilen OTE yaklaşımında uygulanan bu yöntemler daha önce değerlendirilmemiştir. Bu çalışmada, üç yeni önemli bulgu elde edilmiştir. İlk bulgu, ham inceleme metinleri üzerinde NLP’nin geleneksel metin ön işleme teknikleri yerine etki alanından bağımsız olarak kullanılabilen ve metin ön işlemleri gerektiren yaklaşımlara entegre edilebilen PBP yönteminin uygulanmasının OTE performansına katkıda bulunduğudır. Geliştirilen bu yöntemle, dil dışı bir kaynak kullanılmadan, bağıllık ayrıştırma çıktıları kullanılarak sadece dilbilgisel tamlama kurallarına uygun olmayan noktalama işaretleri kaldırılmıştır. Böylece, orijinal noktalama işaretleri ve etkisiz kelimeler korunarak, cümlelerin anlamı ve yapısı bozulmamıştır. İkinci bulgu, sözdizilimsel tabanlı bağıllık ilişki kurallarının harici bir dilsel kaynak kullanmadan yeni ilişki bileşenleriyle genişletilmesinin çok kelimeli ifadelerin çıkarılmasına olanak sağladığıdır. Özellik çıkarımlarında genişletilmiş sözdizilimsel tabanlı bağıllık ilişki kurallarının uygulanması, OT çıkarım çözünürlüğü performansına katkıda bulunmuştur.

Üçüncü bulgu ise polarite analizör modellerinin çıktılarının MV yöntemi ile birleştirilmesiyle, çıktı performansı optimizasyonunun sağlanmasıdır. Böylece, önerilen yaklaşımın genel doğruluk skoru iyileştirilmiştir. Elde edilen tüm bulgulara ek olarak, doğru ifadeyi yakalamak için çıkarılan OT'lerin birbirinin yerine kullanılabilen kelimelerle yeniden ifade etme süreci önemlidir. Bu amaçla, aynı referansa sahip kelimeleri tespit etmek için NBCR modeli kullanılmıştır. Bu sinir ağı tabanlı modelin tercih edilmesindeki en büyük etken, deterministik ve istatistiksel modellere göre daha yüksek performans göstermesidir. Ancak bu model, yüksek donanım gereksinimleri nedeniyle diğer modellere göre daha yavaş çalışmaktadır. Öte yandan, eşgönderge çözümleme modelleri karmaşık cümleler üzerinde yetersiz sonuçlar üretebilmektedir. Bu problemin üstesinden gelmek için NBCR modelinin girişinde karmaşık cümleler yerine ayrıştırılmış cümlelerin kullanılması sağlanmıştır.

7.1.2. OTE Yaklaşımı Sonuçları

Sonuç olarak bu tez çalışmasında, daha maliyetli denetimli yaklaşımlara alternatif olarak etki alanından (domain) bağımsız olarak çalışabilen kural tabanlı algoritmalar ve yeni yöntemlerle desteklenmiş denetimsiz OTE yaklaşımı önerilmektedir. Önerilen bu yaklaşımla; inceleme metinleri üzerinde yorumlanan varlığın, öznel olarak nitelenen özelliklerine ilişkin açık ifadelerin çıkarılması gerçekleştirilmiştir. Söz konusu yaklaşımda, PBP yönteminin, genişletilmiş sözdizimsel tabanlı bağlılık ilişki kuralları algoritmalarının ve MV yönteminin uygulanması OTE performansına katkı sağlamıştır. PBP yöntemiyle, inceleme metinlerinde dilbilgisel tamlama kurallarına uymayan sözcük dizileri arasındaki noktalama işaretleri kaldırılarak özgün bir metin ön işleme gerçekleştirilmiştir. Bu yöntemle cümlenin anlamından ve yapısından sorumlu olan etkisiz kelimeler ve diğer noktalama işaretleri korunmuştur. Sözdizimsel tabanlı mevcut bağlılık ilişki kuralları, çok kelimeli ifadelerin çıkarılabilmesi amacıyla yeni yardımcı bağlılık ilişki türleriyle genişletilmiştir. MV yöntemi ise; önerilen yaklaşımın çıktı performansını optimize etmek için model çıktıları üzerinde uygulanmıştır. Ayrıca inceleme metinlerinde aynı referansa sahip kelimelerin tespiti, diğer modellere göre daha yüksek performans sunan NBCR modeli ile gerçekleştirilmiştir. Bu modelin karmaşık cümlelerdeki çözümleme performansını iyileştirmek için NBCR girdilerinde cümle ayrıştırma işlemi uygulanmıştır.

Gerçekleştirilen deneysel çalışmalardan elde edilen analiz sonuçlarına göre; önerilen OTE yaklaşımının performans bakımından etkin sonuçlar ürettiği ve yaklaşımda uygulanan yöntemlerin ise çıkarım performansına katkı sağladığını göstermektedir. Bu bağlamda, önerilen OTE yaklaşımıyla, diğer kural tabanlı yaklaşımlara göre daha yüksek çıkarım performansı sonuçları elde edilmiştir (Çizelge 6.5). Ayrıca önerilen yaklaşımın, literatürde yer alan yüksek performanslı denetimli yaklaşımlara yakın ve kıyaslanabilir bir performans gösterdiği gözlemlenmiştir (Çizelge 6.4).

7.2. ÖNERİLEN ACD YAKLAŞIMLARI BULGULARI VE SONUÇLARI

7.2.1. ACD Yaklaşımları Bulguları

Çalışmamızda elde edilen deneysel çalışmaların sonuçları, önerilen ACD yaklaşımlarının etkinliğini ve uygulanan önceden eğitilmiş WEM'lerin sınıflandırma performansına katkı sağladığını göstermektedir. Ayrıca önerilen ACD yaklaşımlarının performansları çoklu ve hiyerarşik etiketlere sahip inceleme veri setleri üzerinde daha önce değerlendirilmemiştir. Bu tez çalışmasında, önerilen ACD yaklaşımlarıyla ilişkin dört yaklaşımda önemli bulgular elde edilmiştir. İlk bulgu dizüstü bilgisayar ve restoran inceleme veri setleri üzerinde önerilen ACD yaklaşımlarının etkin performanslar göstermesidir. İkinci bulgu DNN tabanlı ACD yaklaşımlarından, CNN tabanlı yaklaşımlara göre daha yüksek performans sonuçlarının elde edilmesidir. Üçüncü bulgu, CNN ve DNN modellerinin girdilerinde bağlamı dikkate alan BERT ve SFT WEM'lerin kullanılması ACD performansına katkı sağlamasıdır. Dördüncü bulgu ise; önerilen yaklaşımların ACD performansları analiz edildiğinde, BERT WEM ile üretilen metin temsillerinin SFT ile üretilen temsillere göre daha yüksek kapasiteli zengin temsil yeteneğine sahip olmasıdır. Yukarıda bahsedilen bulgulara ek olarak literatürde sayıca az araştırmacı tarafından çalışılan önceden eğitilmiş SFT WEM'nin, düşük kapasitede daha yüksek özellik depolayabilme özelliği, gürültülere karşı dayanıklılığı, üretilen vektörlerin uyumluluğu ve işlenebilirlik yetenekleri açısından önceden eğitilmiş WEM olarak GM sistemlerinde uygulanabilir ve tercih edilebilir olmasıdır.

7.2.2. ACD Yaklaşımları Sonuçları

Sonuç olarak, sınıflandırma yaklaşımlarında önemli bir bileşen olan WEM'lerin seçimi sınıflandırma performansını doğrudan etkilemektedir. Temsil edilmek istenen kelimelerin el yordamı mühendislik ve bağlamdan bağımsız sinirsel tabanlı WEM'lerle anlamsal bağlam özellikleri göz ardı edilerek üretilmesi, üretilen temsillerin özellik depolayabilme yeteneklerinin sınırlı olmasına yol açmaktadır. Sınıflandırma performansını kısıtlayan bu problem bağlamsal dağıtım semantiği üzerinde önceden eğitilmiş WEM'ler tarafından üretilen zengin vektörler kullanılarak aşılabilmektedir. Bu amaçla bu tez çalışmasında çoklu ve hiyerarşik yapıda etiketlenmiş restoran ve dizüstü bilgisayar incelemeleri üzerinde girdilerinde BERT ve SFT WEM'lerini kullanan CNN ve DNN tabanlı ACD yaklaşımları önerilmektedir. Gerçekleştirilen deneysel çalışmaların sonuçları, uygulanan WEM'lerin sınıflandırma performansına katkı sağladığını göstermektedir. Elde edilen tüm sonuçlar değerlendirildiğinde; BERT'in SFT dahil olmak üzere çoğu WEM'lere göre, ACD performanslarına daha yüksek bir katkı sağladığı sonucuna ulaşılmıştır. Ayrıca literatürdeki diğer çalışmalarla karşılaştırıldığında yüksek sınıflandırma performansları sunan SFT vektörlerinin; birbirleri ile uyumlu olması, atomik seviyede toplanabilme, genel mesafe/benzerlik ölçüm yöntemleriyle değerlendirilebilme, gürültülere karşı dayanıklı olma ve en önemlisi az bir boyutla yüksek anlamsal yükü taşıyabilme yetenekleri sayesinde, ACD performanslarına etkin katkılar sağlandığı gözlemlenmiştir.

Çizelge 6.6 ve Çizelge6.7'de görüldüğü üzere, önerilen BERT+DNN, BERT+CNN, SFT+DNN ve SFT+CNN tabanlı ACD yaklaşımlarının performansları ilgili diğer çalışmalarla karşılaştırılmıştır. Karşılaştırma sonuçlarına göre; dizüstü bilgisayar incelemeleri üzerinde önerilen tüm ACD yaklaşımları literatürdeki diğer çalışmalara göre daha yüksek performanslar gösterirken, restoran verileri üzerinde ise en iyi ikinci performans değerine ulaşılarak kıyaslanabilir sonuçlar elde edilmiştir. Önerilen diğer ACD yaklaşımlarından ise etkin ve rekabetçi sınıflandırma performansları elde edilmiştir.

BÖLÜM 8

SONUÇLAR VE GELECEKTEKİ ÇALIŞMALAR

Bu tez çalışmasında, Özellik Tabanlı Görüş (Fikir) Madenciliği'nin önemli alt görevleri arasında yer alan Görüş Hedefi Çıkarımı (Opinion Target Extraction, OTE) ve Özellik Kategorisi Tespiti (Aspect Category Detection, ACD) görevlerinin gerçekleştirilmesine yönelik özgün yaklaşımlar önerilmektedir.

Önerilen OTE yaklaşımıyla, inceleme metinleri üzerinde yorumlanan varlığa ilişkin öznel ifadelerle nitelenen ayırt edici özelliklerin çıkarılması sağlanmıştır. Söz konusu yaklaşımda, girdi metinlerinin düzenlenmesi amacıyla Doğal Dil İşleme'nin geleneksel metin ön işleme teknikleri yerine yeni örüntü tabanlı metin ön işleme yöntemine, çok kelimeli özellik ifadelerinin çıkarılabilmesi için genişletilen sözdizimsel tabanlı bağıllık ilişki kuralları algoritmalarına, aynı referansa sahip kelimelerin tespitinde kullanılan Sinir Ağı Tabanlı Eşgönderge Çözümlemesi modeline ve çıktı performansını iyileştirmek amacıyla uygulanan Çoğunlukla Seçim yöntemine yer verilmiştir. Önerilen OTE yaklaşımının etkinliğini test etmek amacıyla gerçekleştirilen deneysel çalışmalar, uygulanan yöntemlerin çıkarım performansına katkı sağladığını göstermektedir. Sonuç olarak; önerilen OTE yaklaşımıyla literatürde yer alan diğer denetimsiz yaklaşımlara göre daha yüksek, denetimli yaklaşımlara göre ise kıyaslanabilir performans sonuçları elde edilmiştir.

Pratik bir bakış açısıyla önerilen OTE yaklaşımı, işletmelere pazarladıkları ürünlerin zayıf yönlerinin geliştirilmesi için incelemeleri analiz etme ve tüketicilerin satın alma tercihini etkileyen ürün özelliklerini belirleme fırsatı sunmaktadır. Ayrıca söz konusu yaklaşımla işletmelere, tüketicilerin ürün tercihlerindeki değişiklikleri keşfetme imkânı sağlanmaktadır. Bu sayede, yöneticilerin karar verme ve strateji oluşturma süreçlerine yardımcı olunabilmesi amaçlanmaktadır.

OTE'ye yönelik gelecekteki çalışmalarda, çıkarılan görüş hedeflerinin ve niteleyici görüş sözcüklerinin anlamsal olarak ele alınması sağlanarak, özellik çıkarımlarının metinlerdeki genel polaritelere olan etkilerinin analizi planlanmaktadır. Ayrıca Türkçe dili için etkin kural tabanlı özellik çıkarım yöntemlerinin geliştirilmesi hedeflenmektedir.

Önerilen ACD yaklaşımıyla, çoklu ve hiyerarşik özellik kategorileri ile etiketlenmiş inceleme cümlelerinin, girdilerinde önceden eğitilmiş Dönüştürücülerden Çift Yönlü Kodlayıcı Temsilleri (Bidirectional Encoder Representations from Transformers, BERT) ve Anlamsal Katlama Teorisi (Semantic Folding Theory, SFT) kelime temsil modellerinin (word embedding model, WEM) uygulandığı Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) ve Derin Sinir Ağı (Deep Neural Network, DNN) tabanlı modellerle çok etiketli olarak sınıflandırılması gerçekleştirilmiştir. ACD amacıyla gerçekleştirilen deneysel çalışmaların performans sonuçları literatürdeki ilgili diğer çalışmaların performanslarıyla karşılaştırıldığında, uygulanan bağlama dayalı anlamsal temsil vektörleri üretebilen WEM'lerin sınıflandırma performansına etkin katkı sağladığını göstermektedir. Pratik bir bakış açısıyla önerilen ACD yaklaşımı, işletmelere çevrimiçi inceleme metinlerinin potansiyel gücünden yararlanma imkânı sunmaktadır. Bu sayede önerilen ACD yaklaşımlarıyla, özellikle pazarlama yöneticilerinin tüketici satın alma tercihlerini etkileyen ürün özelliklerini etkin bir şekilde değerlendirebilmesi böylece yöneticilerin ürün, fiyat, dağıtım ve promosyon kararlarında yol gösterici bir rol üstlenmesi amaçlanmaktadır.

Gelecekteki çalışmalarda inceleme metinleriyle; polarite, yer, zaman ve cinsiyet gibi özelliklerin birlikte ele alınabildiği anlamsal vektörlerin üretilerek Türkçe diline özgü bağlamsal nitelikli bir kelime temsil modelinin geliştirilmesi planlanmaktadır. Geliştirilmesi planlanan kelime temsil modelleriyle etkin çıkarım ve sınıflandırma performanslarının elde edilmesi hedeflenmektedir.

KAYNAKLAR

1. Karaođlan, K. M. and Findık, O., "Extended rule-based opinion target extraction with a novel text pre-processing method and ensemble learning", *Applied Soft Computing*, 108524 (2022).
2. Verma, S. and Yadav, N., "Past, Present, and Future of Electronic Word of Mouth (EWOM)", *Journal Of Interactive Marketing*, 53: 111–128 (2021).
3. Ismagilova, E., Slade, E. L., Rana, N. P., and Dwivedi, Y. K., "The Effect of Electronic Word of Mouth Communications on Intention to Buy: A Meta-Analysis", *Information Systems Frontiers*, 22 (5): 1203–1226 (2020).
4. Alalwan, A. A., Rana, N. P., Dwivedi, Y. K., and Algharabat, R., "Social media in marketing: A review and analysis of the existing literature", *Telematics And Informatics*, 34 (7): 1177–1190 (2017).
5. Xliema, J. "Effect of Social Networks o 11 Consumer Behaviour: Complex Buying", *IFAC-PapersOnLine*, 52 (25), 504–508." (2019).
6. Ansari, S. and Gupta, S., "Customer perception of the deceptiveness of online product reviews: A speech act theory perspective", *International Journal Of Information Management*, 57 (November 2020): 102286 (2021).
7. Geetha, M. P. and Karthika Renuka, D., "Improving the performance of aspect based sentiment analysis using fine-tuned Bert Base Uncased model", *International Journal Of Intelligent Networks*, 2: 64–69 (2021).
8. Ravi, K. and Ravi, V., "A survey on opinion mining and sentiment analysis: Tasks, approaches and applications", *Knowledge-Based Systems*, 89: 14–46 (2015).
9. Jansen, B. J., Salminen, J. O., and Jung, S.-G., "Making Meaningful User Segments from Datasets Using Product Dissemination and Product Impact", *Data And Information Management*, 4 (4): 237–249 (2020).
10. Tubishat, M., Idris, N., and Abushariah, M., "Explicit aspects extraction in sentiment analysis using optimal rules combination", *Future Generation Computer Systems*, 114: 448–480 (2021).
11. Singh Chauhan, G., Kumar Meena, Y., Gopalani, D., and Nahta, R., "A two-step hybrid unsupervised model with attention mechanism for aspect extraction", *Expert Systems With Applications*, 161: 113673 (2020).

12. García-Pablos, A., Cuadros, M., and Rigau, G., "W2VLDA: Almost unsupervised system for Aspect Based Sentiment Analysis", *Expert Systems With Applications*, 91: 127–137 (2018).
13. Rashid, A., Anwer, N., Iqbal, M., and Sher, M., "A survey paper: areas, techniques and challenges of opinion mining", *International Journal Of Computer Science Issues (IJCSI)*, 10 (6): 18 (2013).
14. Liu, B., "Sentiment analysis and opinion mining", *Synthesis Lectures On Human Language Technologies*, 5 (1): 1–184 (2012).
15. Montoyo, A., Martínez-Barco, P., and Balahur, A., "Subjectivity and sentiment analysis: An overview of the current state of the area and envisaged developments", *Decision Support Systems*, 53 (4): 675–679 (2012).
16. Hemmatian, F. and Sohrabi, M. K., "A survey on classification techniques for opinion mining and sentiment analysis", *Artificial Intelligence Review*, 52 (3): 1495–1545 (2019).
17. Thet, T. T., Na, J. C., and Khoo, C. S. G., "Aspect-based sentiment analysis of movie reviews on discussion boards", *Journal Of Information Science*, 36 (6): 823–848 (2010).
18. Liu, Q., Gao, Z., Liu, B., and Zhang, Y., "Automated rule selection for opinion target extraction", *Knowledge-Based Systems*, 104: 74–88 (2016).
19. Liu, B. and Zhang, L., "A survey of opinion mining and sentiment analysis", *Mining Text Data*, Springer, 415–463 (2012).
20. Li, Y. M. and Li, T. Y., "Deriving market intelligence from microblogs", *Decision Support Systems*, 55 (1): 206–217 (2013).
21. Kang, D. and Park, Y., "Review-based measurement of customer satisfaction in mobile service: Sentiment analysis and VIKOR approach", *Expert Systems With Applications*, 41 (4 PART 1): 1041–1050 (2014).
22. Cheng, L. C. and Huang, C. L., "Exploring contextual factors from consumer reviews affecting movie sales: an opinion mining approach", *Electronic Commerce Research*, 20 (4): 807–832 (2020).
23. Bing, Li, Keith CC Chan, and Carol Ou. "Public sentiment analysis in Twitter data for prediction of a company's stock price movements." *2014 IEEE 11th International Conference on e-Business Engineering. IEEE*, 2014.
24. Meduru, M., Mahimkar, A., Subramanian, K., Padiya, P. Y., and Gunjgur, P. N., "Opinion Mining Using Twitter Feeds for Political Analysis", *International Journal Of Computer (IJC)*, 25 (1): 116–123 (2017).

25. Tsakalidis, A., Papadopoulos, S., Cristea, A. I., and Kompatsiaris, Y., "Predicting Elections for Multiple Countries Using Twitter and Polls", *IEEE Intelligent Systems*, 30 (2): 10–17 (2015).
26. Cambria, E. and White, B., "Jumping NLP curves: A review of natural language processing research", *IEEE Computational Intelligence Magazine*, 9 (2): 48–57 (2014).
27. Riaz, S., Fatima, M., Kamran, M., and Nisar, M. W., "Opinion mining on large scale data using sentiment analysis and k-means clustering", *Cluster Computing*, 22 (3): 7149–7164 (2019).
28. Sharma, S. S. and Dutta, G., "SentiDraw: Using star ratings of reviews to develop domain specific sentiment lexicon for polarity determination", *Information Processing And Management*, 58 (1): 102412 (2021).
29. Chenlo, J. M. and Losada, D. E., "An empirical study of sentence features for subjectivity and polarity classification", *Information Sciences*, 280: 275–288 (2014).
30. Sun, S., Luo, C., and Chen, J., "A review of natural language processing techniques for opinion mining systems", *Information Fusion*, 36: 10–25 (2017).
31. Appel, O., Chiclana, F., Carter, J., and Fujita, H., "A hybrid approach to the sentiment analysis problem at the sentence level", *Knowledge-Based Systems*, 108: 110–124 (2016).
32. Wen, J., Zhang, G., Zhang, H., Yin, W., and Ma, J., "Speculative text mining for document-level sentiment classification", *Neurocomputing*, 412: 52–62 (2020).
33. Dragoni, M., Federici, M., and Rexha, A., "An unsupervised aspect extraction strategy for monitoring real-time reviews stream", *Information Processing And Management*, 56 (3): 1103–1118 (2019).
34. Luo, Z., Huang, S., and Zhu, K. Q., "Knowledge empowered prominent aspect extraction from product reviews", *Information Processing And Management*, 56 (3): 408–423 (2019).
35. Wei, Y., Zhang, H., Fang, J., Wen, J., Ma, J., and Zhang, G., "Joint aspect terms extraction and aspect categories detection via multi-task learning", *Expert Systems With Applications*, 174 (February): 114688 (2021).
36. Rana, T. A. and Cheah, Y. N., "Aspect extraction in sentiment analysis: comparative analysis and survey", *Artificial Intelligence Review*, 46 (4): 459–483 (2016).

37. Saberi, B. and Saad, S., "Sentiment analysis or opinion mining: A review", *International Journal On Advanced Science, Engineering And Information Technology*, 7 (5): 1660–1666 (2017).
38. J, A. K. and Abirami, S., "Aspect-based opinion ranking framework for product reviews using a Spearman's rank correlation coefficient method", *Information Sciences*, 460–461: 23–41 (2018).
39. Wu, S., Xu, Y., Wu, F., Yuan, Z., Huang, Y., and Li, X., "Aspect-based sentiment analysis via fusing multiple sources of textual knowledge", *Knowledge-Based Systems*, 183: 104868 (2019).
40. Poria, S., Cambria, E., Winterstein, G., and Huang, G. Bin, "Sentic patterns: Dependency-based rules for concept-level sentiment analysis", *Knowledge-Based Systems*, 69 (1): 45–63 (2014).
41. Rill, S., Reinel, D., Scheidt, J., and Zicari, R. V., "PoliTwi: Early detection of emerging political topics on twitter and the impact on concept-level sentiment analysis", *Knowledge-Based Systems*, 69 (1): 24–33 (2014).
42. Pontiki, M., Galanis, D., Papageorgiou, H., Androutsopoulos, I., Manandhar, S., Al-Smadi, M., Al-Ayyoub, M., Zhao, Y., Qin, B., De Clercq, O., and others, "Semeval-2016 task 5: Aspect based sentiment analysis", *International Workshop On Semantic Evaluation*, 19–30 (2016).
43. Do, H. H., Prasad, P. W. C., Maag, A., and Alsadoon, A., "Deep Learning for Aspect-Based Sentiment Analysis: A Comparative Review", *Expert Systems With Applications*, 118: 272–299 (2019).
44. Rao, G., Huang, W., Feng, Z., and Cong, Q., "LSTM with sentence representations for document-level sentiment classification", *Neurocomputing*, 308: 49–57 (2018).
45. Araújo, M., Pereira, A., and Benevenuto, F., "A comparative study of machine translation for multilingual sentence-level sentiment analysis", *Information Sciences*, 512: 1078–1102 (2020).
46. Meškelė, D. and Frasincar, F., "ALDONAr: A hybrid solution for sentence-level aspect-based sentiment analysis using a lexicalized domain ontology and a regularized neural attention model", *Information Processing And Management*, 57 (3): 102211 (2020).
47. Gandhi, H. and Attar, V., "Extracting Aspect Terms using CRF and Bi-LSTM Models", *Procedia Computer Science*, 167: 2486–2495 (2020).
48. Yadav, M. L. and Roychoudhury, B., "Effect of trip mode on opinion about hotel aspects: A social media analysis approach", *International Journal Of Hospitality Management*, 80 (December 2018): 155–165 (2019).

49. Anand, D. and Mampilli, B. S., "A novel evolutionary approach for learning syntactic features for cross domain opinion target extraction", *Applied Soft Computing*, 102: 107086 (2021).
50. Wu, C., Wu, F., Wu, S., Yuan, Z., and Huang, Y., "A hybrid unsupervised method for aspect term and opinion target extraction", *Knowledge-Based Systems*, 148: 66–73 (2018).
51. Jiménez-Zafra, S. M., Martín-Valdivia, M. T., Molina-González, M. D., and Ureña-López, L. A., "Relevance of the SFU ReviewSP-NEG corpus annotated with the scope of negation for supervised polarity classification in Spanish", *Information Processing And Management*, 54 (2): 240–251 (2018).
52. Venugopalan, M. and Gupta, D., "An Unsupervised Hierarchical Rule Based Model for Aspect Term Extraction Augmented with Pruning Strategies", *Procedia Computer Science*, 171: 22–31 (2020).
53. Al-Smadi, M., Qawasmeh, O., Al-Ayyoub, M., Jararweh, Y., and Gupta, B., "Deep Recurrent neural network vs. support vector machine for aspect-based sentiment analysis of Arabic hotels' reviews", *Journal Of Computational Science*, 27: 386–393 (2018).
54. Akhtar, M. S., Gupta, D., Ekbal, A., and Bhattacharyya, P., "Feature selection and ensemble construction: A two-step method for aspect based sentiment analysis", *Knowledge-Based Systems*, 125: 116–135 (2017).
55. Poria, S., Cambria, E., and Gelbukh, A., "Aspect extraction for opinion mining with a deep convolutional neural network", *Knowledge-Based Systems*, 108 (3): 42–49 (2016).
56. Feng, J., Cai, S., and Ma, X., "Enhanced sentiment labeling and implicit aspect identification by integration of deep convolution neural network and sequential algorithm", *Cluster Computing*, 22 (3): 5839–5857 (2019).
57. Toh, Z. and Su, J., "NLANGP at SemEval-2016 Task 5: Improving Aspect Based Sentiment Analysis using neural network features", *SemEval 2016 - 10th International Workshop On Semantic Evaluation, Proceedings*, 282–288 (2016).
58. Hu, M. and Liu, B., "Mining and summarizing customer reviews", *KDD-2004 - Proceedings Of The Tenth ACM SIGKDD International Conference On Knowledge Discovery And Data Mining*, 168–177 (2004).
59. Popescu, Ana-Maria, and Oren, Etzioni. "Extracting product features and opinions from reviews." *Natural language processing and text mining. Springer, London*, 9-28, (2007).

60. Somasundaran, S. and Wiebe, J., "Recognizing stances in online debates", *ACL-IJCNLP 2009 - Joint Conf. Of The 47th Annual Meeting Of The Association For Computational Linguistics And 4th Int. Joint Conf. On Natural Language Processing Of The AFNLP, Proceedings Of The Conf.*, 226–234 (2009).
61. Rubtsova, Y. and Koshelnikov, S., "Aspect extraction from reviews using conditional random fields", *Communications In Computer And Information Science*, 518: 158–167 (2015).
62. Jin, W., Ho, H. H., and Srihari, R. K., "OpinionMiner: A novel machine learning system for web opinion mining and extraction", *Proceedings Of The ACM SIGKDD International Conference On Knowledge Discovery And Data Mining*, 1195–1203 (2009).
63. Augustyniak, Ł., Kajdanowicz, T., and Kazienko, P., "Comprehensive analysis of aspect term extraction methods using various text embeddings", *Computer Speech And Language*, 69: 101217 (2021).
64. Wang, T., Cai, Y., Leung, H. F., Lau, R. Y. K., Li, Q., and Min, H., "Product aspect extraction supervised with online domain knowledge", *Knowledge-Based Systems*, 71: 86–100 (2014).
65. Mukherjee, A. and Liu, B., "Aspect extraction through semi-supervised modeling", *50th Annual Meeting Of The Association For Computational Linguistics, ACL 2012 - Proceedings Of The Conference*, 1: 339–348 (2012).
66. Song, W., Wen, Z., Xiao, Z., and Park, S. C., "Semantics perception and refinement network for aspect-based sentiment analysis", *Knowledge-Based Systems*, 214: 106755 (2021).
67. Ren, F., Feng, L., Xiao, D., Cai, M., and Cheng, S., "DNet: A lightweight and efficient model for aspect based sentiment analysis", *Expert Systems With Applications*, 151: 113393 (2020).
68. Liu, N. and Shen, B., "Aspect-based sentiment analysis with gated alternate neural network", *Knowledge-Based Systems*, 188: 105010 (2020).
69. Elman, J. L., "Finding structure in time", *Cognitive Science*, 14 (2): 179–211 (1990).
70. Goldberg, Y., "Neural network methods for natural language processing", *Computational Linguistics*, 44 (1): 194–195 (2018).
71. Ma, Y., Peng, H., Khan, T., Cambria, E., and Hussain, A., "Sentic LSTM: a Hybrid Network for Targeted Aspect-Based Sentiment Analysis", *Cognitive Computation*, 10 (4): 639–650 (2018).

72. Jebbara, S. and Cimiano, P., "Aspect-based relational Sentiment analysis using a stacked neural network architecture", *Frontiers In Artificial Intelligence And Applications*, 285: 1123–1131 (2016).
73. Popescu, A. M. and Etzioni, O., "Extracting product features and opinions from reviews", *Natural Language Processing And Text Mining*, (October): 9–28 (2007).
74. Li, S., Zhou, L., and Li, Y., "Improving aspect extraction by augmenting a frequency-based method with web-based similarity measures", *Information Processing And Management*, 51 (1): 58–67 (2015).
75. Rana, T. A. and Cheah, Y. N., "A two-fold rule-based model for aspect extraction", *Expert Systems With Applications*, 89: 273–285 (2017).
76. Qiu, G., Liu, B., Bu, J., and Chen, C., "Expanding domain sentiment lexicon through double propagation", *IJCAI International Joint Conference On Artificial Intelligence*, 9: 1199–1204 (2009).
77. Wu, Yuanbin, et al. "Phrase dependency parsing for opinion mining." Proceedings of the 2009 conference on empirical methods in natural language processing. 2009.
78. Kumar, C. S. P. and Babu, L. D. D., "Evolving dictionary based sentiment scoring framework for patient authored text", *Evolutionary Intelligence*, 14 (2): 657–667 (2021).
79. Hatzivassiloglou, V. and McKeown, K. R., "Predicting the semantic orientation of adjectives", *35th Annual Meeting Of The Association For Computational Linguistics And 8th Conference Of The European Chapter Of The Association For Computational Linguistics*, 174–181 (1997).
80. Moreno-Ortiz, A. and Fernández-Cruz, J., "Identifying Polarity in Financial Texts for Sentiment Analysis: A Corpus-based Approach", *Procedia - Social And Behavioral Sciences*, 198: 330–338 (2015).
81. Stein, R. A., Jaques, P. A., and Valiati, J. F., "An analysis of hierarchical text classification using word embeddings", *Information Sciences*, 471: 216–232 (2019).
82. Liu, H., Chen, G., Li, P., Zhao, P., and Wu, X., "Multi-label text classification via joint learning from label embedding and label correlation", *Neurocomputing*, 460: 385–398 (2021).
83. Tarekegn, A. N., Giacobini, M., and Michalak, K., "A review of methods for imbalanced multi-label classification", *Pattern Recognition*, 118: 107965 (2021).

84. Al-Salemi, B., Mohd Noah, S. A., and Ab Aziz, M. J., "RFBoost: An improved multi-label boosting algorithm and its application to text categorisation", *Knowledge-Based Systems*, 103: 104–117 (2016).
85. Wang, B., Hu, X., Li, P., and Yu, P. S., "Cognitive structure learning model for hierarchical multi-label text classification", *Knowledge-Based Systems*, 218: 106876 (2021).
86. Wang, P., Xu, B., Xu, J., Tian, G., Liu, C. L., and Hao, H., "Semantic expansion using word embedding clustering and convolutional neural network for improving short text classification", *Neurocomputing*, 174: 806–814 (2016).
87. Cai, L., Song, Y., Liu, T., and Zhang, K., "A Hybrid BERT Model That Incorporates Label Semantics via Adjustive Attention for Multi-Label Text Classification", *IEEE Access*, 8: 152183–152192 (2020).
88. Chen, G., Ye, D., Xing, Z., Chen, J., and Cambria, E., "Ensemble application of convolutional and recurrent neural networks for multi-label text categorization", *Proceedings Of The International Joint Conference On Neural Networks*, 2017-May: 2377–2383 (2017).
89. Wang, R., Ridley, R., Su, X., Qu, W., and Dai, X., "A novel reasoning mechanism for multi-label text classification", *Information Processing And Management*, 58 (2): 102441 (2021).
90. Khan, K., Baharudin, B., Khan, A., and Ullah, A., "Mining opinion components from unstructured reviews: A review", *Journal Of King Saud University - Computer And Information Sciences*, 26 (3): 258–275 (2014).
91. Kumar, S., Kar, A. K., and Ilavarasan, P. V., "Applications of text mining in services management: A systematic literature review | Elsevier Enhanced Reader", *International Journal Of Information Management Data Insights*, 1 (1): 100008 (2021).
92. Tang, F., Fu, L., Yao, B., and Xu, W., "Aspect based fine-grained sentiment analysis for online reviews", *Information Sciences*, 488: 190–204 (2019).
93. Seerat, B. and Azam, F., "Opinion mining: Issues and challenges (a survey)", *International Journal Of Computer Applications*, 49 (9): (2012).
94. Dave, K., Lawrence, S., and Pennock, D. M., "Mining the peanut gallery: Opinion extraction and semantic classification of product reviews", *Proceedings Of The 12th International Conference On World Wide Web, WWW 2003*, 519–528 (2003).
95. Cambria, E., Poria, S., Bajpai, R., and Schuller, B., "SenticNet 4: A semantic resource for sentiment analysis based on conceptual primitives", *COLING 2016 - 26th International Conference On Computational Linguistics, Proceedings Of COLING 2016: Technical Papers*, 2666–2677 (2016).

96. Nassif, A. B., Elnagar, A., Shahin, I., and Henno, S., "Deep learning for Arabic subjective sentiment analysis: Challenges and research opportunities", *Applied Soft Computing*, 98: 106836 (2021).
97. Sailunaz, K. and Alhajj, R., "Emotion and sentiment analysis from Twitter text", *Journal Of Computational Science*, 36: 101003 (2019).
98. Malik, M., Habib, S., and Agarwal, P., "A Novel Approach to Web-Based Review Analysis Using Opinion Mining", *Procedia Computer Science*, 132: 1202–1209 (2018).
99. Schouten, K. and Frasincar, F., "Survey on Aspect-Level Sentiment Analysis", *IEEE Transactions On Knowledge And Data Engineering*, 28 (3): 813–830 (2016).
100. Tang, H., Tan, S., and Cheng, X., "A survey on sentiment detection of reviews", *Expert Systems With Applications*, 36 (7): 10760–10773 (2009).
101. D'Andrea, E., Ducange, P., Bechini, A., Renda, A., and Marcelloni, F., "Monitoring the public opinion about the vaccination topic from tweets analysis", *Expert Systems With Applications*, 116: 209–226 (2019).
102. Bian, J., Yoshigoe, K., Hicks, A., Yuan, J., He, Z., Xie, M., Guo, Y., Prosperi, M., Salloum, R., and Modave, F., "Mining twitter to assess the public perception of the "internet of things"", *PLoS ONE*, 11 (7): e0158450 (2016).
103. Dong, X. and Lian, Y., "A review of social media-based public opinion analyses: Challenges and recommendations", *Technology In Society*, 67: 101724 (2021).
104. Adams-Cohen, N. J., "Policy Change and Public Opinion: Measuring Shifting Political Sentiment With Social Media Data", *American Politics Research*, 48 (5): 612–621 (2020).
105. Chen, K., Luo, P., and Wang, H., "An influence framework on product word-of-mouth (WoM) measurement", *Information And Management*, 54 (2): 228–240 (2017).
106. Zhang, L. and Liu, B., "Aspect and Entity Extraction for Opinion Mining", *Data Mining and Knowledge Discovery for Big Data*, Springer, 1–40 (2014).
107. Kim, D., Lee, J., So, C. H., Jeon, H., Jeong, M., Choi, Y., Yoon, W., Sung, M., and Kang, J., "A Neural Named Entity Recognition and Multi-Type Normalization Tool for Biomedical Text Mining", *IEEE Access*, 7: 73729–73740 (2019).
108. Ganganwar, V. and Rajalakshmi, R., "Implicit Aspect Extraction for Sentiment Analysis: A Survey of Recent Approaches", *Procedia Computer Science*, 165: 485–491 (2019).

109. Deng, S., Sinha, A. P., and Zhao, H., "Adapting sentiment lexicons to domain-specific social media texts", *Decision Support Systems*, 94: 65–76 (2017).
110. Liang, B., Su, H., Gui, L., Cambria, E., and Xu, R., "Aspect-based sentiment analysis via affective knowledge enhanced graph convolutional networks", *Knowledge-Based Systems*, 235: 107643 (2022).
111. Gauba, H., Kumar, P., Roy, P. P., Singh, P., Dogra, D. P., and Raman, B., "Prediction of advertisement preference by fusing EEG response and sentiment analysis", *Neural Networks*, 92: 77–88 (2017).
112. Borg, A. and Boldt, M., "Using VADER sentiment and SVM for predicting customer response sentiment", *Expert Systems With Applications*, 162: 113746 (2020).
113. Hutto, C. J. and Gilbert, E., "VADER: A parsimonious rule-based model for sentiment analysis of social media text", *Proceedings Of The 8th International Conference On Weblogs And Social Media, ICWSM 2014*, 8 (1): 216–225 (2014).
114. Martinez, A. R., "Part-of-speech tagging", *Wiley Interdisciplinary Reviews: Computational Statistics*, 4 (1): 107–113 (2012).
115. Priyadarshi, A. and Saha, S. K., "Towards the first Maithili part of speech tagger: Resource creation and system development", *Computer Speech And Language*, 62: 101054 (2020).
116. Marneffe, M. C. de, Manning, C. D., Nivre, J., and Zeman, D., "Universal dependencies", *Computational Linguistics*, 47 (2): 255–308 (2021).
117. Nivre, J., De Marneffe, M. C., Ginter, F., Goldberg, Y., Hajič, J., Manning, C. D., McDonald, R., Petrov, S., Pysalo, S., Silveira, N., Tsarfaty, R., and Zeman, D., .
118. Qi, P., Zhang, Y., Zhang, Y., Bolton, J., and Manning, C. D., "Stanza: A Python Natural Language Processing Toolkit for Many Human Languages", *ArXiv Preprint ArXiv:2003.07082*, 101–108 (2020).
119. Manning, C., Surdeanu, M., Bauer, J., Finkel, J., Bethard, S., and McClosky, D., "The Stanford CoreNLP Natural Language Processing Toolkit", *Proceedings Of 52nd Annual Meeting Of The Association For Computational Linguistics: System Demonstrations*, 55–60 (2015).
120. Akbik, A., Bergmann, T., Blythe, D., Rasul, K., Schweter, S., and Vollgraf, R., "FLAIR: An easy-to-use framework for state-of-the-art NLP", *Proceedings Of The 2019 Conference Of The North American Chapter Of The Association For Computational Linguistics (Demonstrations)*, 54–59 (2019).

121. Straka, Milan. "UDPipe 2.0 prototype at CoNLL 2018 UD shared task." *Proceedings of the CoNLL 2018 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies*. 2018.
122. Jin, S., Chen, S., and Xie, X., "Property-based Test for Part-of-Speech Tagging Tool", *2021 36th IEEE/ACM International Conference On Automated Software Engineering (ASE)*, 1306–1311 (2022).
123. De Marneffe, M.-C. and Manning, C. D., "Stanford typed dependencies manual", (2008).
124. De Marneffe, M.-C., Dozat, T., Silveira, N., Haverinen, K., Ginter, F., Nivre, J., and Manning, C. D., "Universal Stanford dependencies: A cross-linguistic typology.", *LREC*, 14: 4585–4592 (2014).
125. Binali, H., Potdar, V., and Wu, C., "A state of the art opinion mining and its application domains", *2009 IEEE International Conference On Industrial Technology*, 1–6 (2009).
126. Jiang, Z., Gao, S., and Chen, L., "Study on text representation method based on deep learning and topic information", *Computing*, 102 (3): 623–642 (2020).
127. Naili, M., Chaibi, A. H., and Ben Ghezala, H. H., "Comparative study of word embedding methods in topic segmentation", *Procedia Computer Science*, 112: 340–349 (2017).
128. Batrinca, B. and Treleaven, P. C., "Social media analytics: a survey of techniques, tools and platforms", *Ai & Society*, 30 (1): 89–116 (2015).
129. Toivonen, T., Heikinheimo, V., Fink, C., Hausmann, A., Hiippala, T., Järv, O., Tenkanen, H., and Di Minin, E., "Social media data for conservation science: A methodological overview", *Biological Conservation*, 233: 298–315 (2019).
130. Lomborg, S. and Bechmann, A., "Using APIs for data collection on social media", *The Information Society*, 30 (4): 256–265 (2014).
131. Fang, X. and Zhan, J., "Sentiment analysis using product review data", *Journal Of Big Data*, 2 (1): 1–14 (2015).
132. Anandarajan, M., Hill, C., and Nolan, T., "The fundamentals of content analysis", *Practical Text Analytics*, Springer, 15–25 (2019).
133. Nothman, J., Qin, H., and Yurchak, R., "Stop word lists in free open-source software packages", *Proceedings Of Workshop For NLP Open Source Software (NLP-OSS)*, 7–12 (2018).
134. Singh, J. and Gupta, V., "Text stemming: Approaches, applications, and challenges", *ACM Computing Surveys (CSUR)*, 49 (3): 1–46 (2016).

135. Jivani, A. G. and others, "A comparative study of stemming algorithms", *Int. J. Comp. Tech. Appl*, 2 (6): 1930–1938 (2011).
136. Jabbar, A., Iqbal, S., Tamimy, M. I., Hussain, S., and Akhunzada, A., "Empirical evaluation and study of text stemming algorithms", *Artificial Intelligence Review*, 53 (8): 5559–5588 (2020).
137. Gawande, V., Al Badi, M. H., UTAS, C.-I., Oman, U., CAS-Ibri, O., Al Makharoumi, M. K., and Cain, M. R., "Study Design and Implementation of NLP Techniques for Automated Grading of answers: A Conceptual Model", (2021).
138. Zhang, W., Yoshida, T., and Tang, X., "A comparative study of TF*IDF, LSI and multi-words for text classification", *Expert Systems With Applications*, 38 (3): 2758–2765 (2011).
139. Kim, D., Seo, D., Cho, S., and Kang, P., "Multi-co-training for document classification using various document representations: TF–IDF, LDA, and Doc2Vec", *Information Sciences*, 477: 15–29 (2019).
140. Zhang, H. and Zhong, G., "Improving short text classification by learning vector representations of both words and hidden topics", *Knowledge-Based Systems*, 102: 76–86 (2016).
141. Chen, H., Wu, L., Chen, J., Lu, W., and Ding, J., "A comparative study of automated legal text classification using random forests and deep learning", *Information Processing And Management*, 59 (2): 102798 (2022).
142. Pennington, J., Socher, R., and Manning, C. D., "GloVe: Global vectors for word representation", *EMNLP 2014 - 2014 Conference On Empirical Methods In Natural Language Processing, Proceedings Of The Conference*, 1532–1543 (2014).
143. Mikolov, T., Chen, K., Corrado, G., and Dean, J., "Efficient estimation of word representations in vector space", *Ist International Conference On Learning Representations, ICLR 2013 - Workshop Track Proceedings*, (2013).
144. Khattak, F. K., Jebblee, S., Pou-Prom, C., Abdalla, M., Meaney, C., and Rudzicz, F., "A survey of word embeddings for clinical text", *Journal Of Biomedical Informatics: X*, 4 (October): (2019).
145. Ferrone, L. and Zanzotto, F. M., "Symbolic, Distributed, and Distributional Representations for Natural Language Processing in the Era of Deep Learning: A Survey", *Frontiers In Robotics And AI*, 6: 153 (2020).
146. Fodor, J. A. and Pylyshyn, Z. W., "Connectionism and cognitive architecture: A critical analysis", *Cognition*, 28 (1–2): 3–71 (1988).

147. Gamallo, P., "Compositional distributional semantics with syntactic dependencies and selectional preferences", *Applied Sciences (Switzerland)*, 11 (12): (2021).
148. Ali Shah, S. M. and Ou, Y. Y., "TRP-BERT: Discrimination of transient receptor potential (TRP) channels using contextual representations from deep bidirectional transformer based on BERT", *Computers In Biology And Medicine*, 137: 104821 (2021).
149. Tay, W., Zhang, X. J., Wan, S., and Karimi, S., "Measuring Similarity of Opinion-bearing Sentences", *Proceedings Of The Third Workshop On New Frontiers In Summarization*, 74–84 (2021).
150. Pan, M., Wang, J., Huang, J. X., Huang, A. J., Chen, Q., and Chen, J., "A probabilistic framework for integrating sentence-level semantics via BERT into pseudo-relevance feedback", *Information Processing And Management*, 59 (1): 102734 (2022).
151. Devlin, J., Chang, M. W., Lee, K., and Toutanova, K., "BERT: Pre-training of deep bidirectional transformers for language understanding", *NAACL HLT 2019 - 2019 Conference Of The North American Chapter Of The Association For Computational Linguistics: Human Language Technologies - Proceedings Of The Conference*, 1: 4171–4186 (2019).
152. Cui, Y., Ahmad, S., and Hawkins, J., "The HTM spatial pooler—a neocortical algorithm for online sparse distributed coding", *Frontiers In Computational Neuroscience*, 11: 111 (2017).
153. Shah, D., Ghate, P., Paranjape, M., and Kumar, A., "Application of hierarchical temporal memory theory for document categorization", *2017 IEEE SmartWorld Ubiquitous Intelligence And Computing, Advanced And Trusted Computed, Scalable Computing And Communications, Cloud And Big Data Computing, Internet Of People And Smart City Innovation, SmartWorld/SCALCOM/UIC/ATC/CBDCCom/IOP/SCI 2017 -* , 1–6 (2018).
154. Ran, Y. and Han, H., "Text classification algorithm based on sparse distributed representation", *Proceedings Of 2020 IEEE International Conference On Advances In Electrical Engineering And Computer Applications, AEECA 2020*, 876–880 (2020).
155. Cui, Y., Ahmad, S., and Hawkins, J., "Continuous online sequence learning with an unsupervised neural network model", *Neural Computation*, 28 (11): 2474–2504 (2016).
156. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I., "Attention is all you need", *Advances In Neural Information Processing Systems*, 2017-Decem: 5999–6009 (2017).

157. Alatawi, H. S., Alhothali, A. M., and Moria, K. M., "Detecting White Supremacist Hate Speech Using Domain Specific Word Embedding with Deep Learning and BERT", *IEEE Access*, 9: 106363–106374 (2021).
158. Webber, F. D. S., "Semantic Folding Theory And its Application in Semantic Fingerprinting", *ArXiv Preprint ArXiv:1511.08855*, (2015).
159. Dalpiaz, F., van der Schalk, I., Brinkkemper, S., Aydemir, F. B., and Lucassen, G., "Detecting terminological ambiguity in user stories: Tool and experimentation", *Information And Software Technology*, 110 (December 2018): 3–16 (2019).
160. Garousi, V., Cutting, D., and Felderer, M., "Mining user reviews of COVID contact-tracing apps: An exploratory analysis of nine European apps", *Journal Of Systems And Software*, 184: 111136 (2022).
161. Ahmad, S. and Hawkins, J., "Properties of Sparse Distributed Representations and their Application to Hierarchical Temporal Memory", *ArXiv Preprint ArXiv:1503.07469*, (2015).
162. Sharma, R., Nigam, S., and Jain, R., "Opinion Mining of Movie Reviews At Document Level", *International Journal On Information Theory*, 3 (3): 13–21 (2014).
163. Liu, S., Lee, K., and Lee, I., "Document-level multi-topic sentiment classification of Email data with BiLSTM and data augmentation", *Knowledge-Based Systems*, 197: 105918 (2020).
164. Xia, R., Xu, F., Yu, J., Qi, Y., and Cambria, E., "Polarity shift detection, elimination and ensemble: A three-stage model for document-level sentiment analysis", *Information Processing And Management*, 52 (1): 36–45 (2016).
165. Moraes, R., Valiati, J. F., and Gavião Neto, W. P., "Document-level sentiment classification: An empirical comparison between SVM and ANN", *Expert Systems With Applications*, 40 (2): 621–633 (2013).
166. Marcheggiani, D., Täckström, O., Esuli, A., and Sebastiani, F., "Hierarchical multi-label conditional random fields for aspect-oriented opinion mining", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 8416 LNCS: 273–285 (2014).
167. Hasan, A., Moin, S., Karim, A., and Shamshirband, S., "Machine Learning-Based Sentiment Analysis for Twitter Accounts", *Mathematical And Computational Applications*, 23 (1): 11 (2018).

168. Cambria, E., "An introduction to concept-level sentiment analysis", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 8266 LNAI (PART 2): 478–483 (2013).
169. Zad, S., Heidari, M., Jones, J. H., and Uzuner, O., "A survey on concept-level sentiment analysis techniques of textual data", *2021 IEEE World AI IoT Congress (AIIoT)*, 285–291 (2021).
170. Wiebe, J. M., Bruce, R. F., and O'Hara, T. P., "Development and use of a gold-standard data set for subjectivity classifications", *Proceedings Of The 37th Annual Meeting Of The Association For Computational Linguistics*, 246–253 (1999).
171. Hatzivassiloglou, V. and Wiebe, J. M., "Effects of adjective orientation and gradability on sentence subjectivity", *COLING 2000 Volume 1: The 18th International Conference On Computational Linguistics*, 299–305 (2000).
172. Cho, H., Kim, S., Lee, J., and Lee, J. S., "Data-driven integration of multiple sentiment dictionaries for lexicon-based sentiment classification of product reviews", *Knowledge-Based Systems*, 71: 61–71 (2014).
173. Huang, M., Xie, H., Rao, Y., Liu, Y., Poon, L. K. M., and Wang, F. L., "Lexicon-Based Sentiment Convolutional Neural Networks for Online Review Analysis", *IEEE Transactions On Affective Computing*, (2020).
174. Biltawi, M., Etaiwi, W., Tedmori, S., Hudaib, A., and Awajan, A., "Sentiment classification techniques for Arabic language: A survey", *2016 7th International Conference On Information And Communication Systems, ICICS 2016*, 339–346 (2016).
175. Narayanan, R., Liu, B., and Choudhary, A., "Sentiment analysis of conditional sentences", *EMNLP 2009 - Proceedings Of The 2009 Conference On Empirical Methods In Natural Language Processing: A Meeting Of SIGDAT, A Special Interest Group Of ACL, Held In Conjunction With ACL-IJCNLP 2009*, 180–189 (2009).
176. Tsur, O., Davidov, D., and Rappoport, A., "ICWSM - A great catchy name: Semi-supervised recognition of sarcastic sentences in online product reviews", *ICWSM 2010 - Proceedings Of The 4th International AAAI Conference On Weblogs And Social Media*, 162–169 (2010).
177. Ozyurt, B. and Akcayol, M. A., "A new topic modeling based approach for aspect extraction in aspect based sentiment analysis: SS-LDA", *Expert Systems With Applications*, 168: 114231 (2021).
178. Akhtar, M. S., Garg, T., and Ekbal, A., "Multi-task learning for aspect term extraction and aspect sentiment classification", *Neurocomputing*, 398: 247–256 (2020).

179. Ding, X., Liu, B., and Yu, P. S., "A holistic lexicon-based approach to opinion mining", *Proceedings Of The 2008 International Conference On Web Search And Data Mining*, 231–240 (2008).
180. Tubishat, M., Idris, N., and Abushariah, M. A. M., "Implicit aspect extraction in sentiment analysis: Review, taxonomy, opportunities, and open challenges", *Information Processing And Management*, 54 (4): 545–563 (2018).
181. More, P. and Ghotkar, A., "A Study of Different Approaches to Aspect-based Opinion Mining", *International Journal Of Computer Applications*, 145 (6): 11–15 (2016).
182. Qiu, G., Liu, B., Bu, J., and Chen, C., "Opinion word expansion and target extraction through double propagation", *Computational Linguistics*, 37 (1): 9–27 (2011).
183. Lafferty, J., McCallum, A., and Pereira, F. C. N., "Conditional random fields: Probabilistic models for segmenting and labeling sequence data", (2001).
184. Cambria, E., Schuller, B., Xia, Y., and Havasi, C., "New avenues in opinion mining and sentiment analysis", *IEEE Intelligent Systems*, 28 (2): 15–21 (2013).
185. Baccianella, S., Esuli, A., and Sebastiani, F., "SENTIWORDNET 3.0: An enhanced lexical resource for sentiment analysis and opinion mining", *Proceedings Of The 7th International Conference On Language Resources And Evaluation, LREC 2010*, 10 (2010): 2200–2204 (2010).
186. Strapparava, C., Valitutti, A., and others, "Wordnet affect: an affective extension of wordnet.", *Lrec*, 4 (1083–1086): 40 (2004).
187. Nayak, A. S. and Kanive, A. P., "Survey on Pre-Processing Techniques for Text Mining", *International Journal Of Engineering And Computer Science*, 5 (6): 16875–16879 (2016).
188. Ruta, D. and Gabrys, B., "Classifier selection for majority voting", *Information Fusion*, 6 (1): 63–81 (2005).
189. Dong, X., Yu, Z., Cao, W., Shi, Y., and Ma, Q., "A survey on ensemble learning", *Frontiers Of Computer Science*, 14 (2): 241–258 (2020).
190. Kuncheva, L. I., Whitaker, C. J., Shipp, C. A., and Duin, R. P. W., "Limits on the majority vote accuracy in classifier fusion", *Pattern Analysis And Applications*, 6 (1): 22–31 (2003).
191. Li, Q., Li, P., Mao, K., and Lo, E. Y. M., "Improving convolutional neural network for text classification by recursive data pruning", *Neurocomputing*, 414: 143–152 (2020).

192. Desai, M. and Shah, M., "An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN)", *Clinical EHealth*, 4: 1–11 (2021).
193. Maxwell, A., Li, R., Yang, B., Weng, H., Ou, A., Hong, H., Zhou, Z., Gong, P., and Zhang, C., "Deep learning architectures for multi-label classification of intelligent health risk prediction", *BMC Bioinformatics*, 18 (14): 121–131 (2017).
194. Díaz-Álvarez, A., Clavijo, M., Jiménez, F., Talavera, E., and Serradilla, F., "Modelling the human lane-change execution behaviour through Multilayer Perceptrons and Convolutional Neural Networks", *Transportation Research Part F: Traffic Psychology And Behaviour*, 56: 134–148 (2018).
195. Ho, Q. T., Nguyen, T. T. D., Khanh Le, N. Q., and Ou, Y. Y., "FAD-BERT: Improved prediction of FAD binding sites using pre-training of deep bidirectional transformers", *Computers In Biology And Medicine*, 131: 104258 (2021).
196. Xue, W., Zhou, W., Li, T., and Wang, Q., "MTNA: A Neural Multi-task Model for Aspect Category Classification and Aspect Term Extraction On Restaurant Reviews", *Proceedings Ofthe The 8th International Joint Conference On Natural Language Processing*, 151–156 (2017).
197. Yang, Y., Wu, B., Li, L., and Wang, S., "A joint model for aspect-category sentiment analysis with TextGCN and Bi-GRU", *Proceedings - 2020 IEEE 5th International Conference On Data Science In Cyberspace, DSC 2020*, 156–163 (2020).

ÖZGEÇMİŞ

Kürşat Mustafa KARAOĞLAN, 1985 yılında Gaziantep’te doğdu; ilk, orta ve lise öğrenimini aynı şehirde tamamladı. Gaziantep Anadolu Lisesi’nden mezun olduktan sonra 2003 yılında başladığı Selçuk Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü’nden 2008 yılında mezun oldu. 2007-Eylül ayından itibaren özel sektörde yazılım uzmanı olarak çalıştı. Çok sayıda kurumsal yazılım projelerinde görev aldı. 2011-Aralık itibariyle Karabük Üniversitesi, Türkiye Odalar ve Borsalar Birliği Teknik Bilimler Meslek Yüksekokulu Bilgisayar Teknolojileri Bölümü’nde öğretim görevlisi olarak göreve başladı, halen bu görevine devam etmektedir. Evli ve 2 çocuk babasıdır.

ADRES BİLGİLERİ

Adres :

E-posta :