

RESTORAN MÜŞTERİLERİNİN GERİ BİLDİRİMLERİ ÜZERİNDE HEDEF KATEGORİNİN TESPİTİ VE HEDEF TABANLI DUYGU ANALİZİ

DETECTION OF ASPECT CATEGORY AND ASPECT-BASED SENTIMENT ANALYSIS ON RESTAURANT CUSTOMERS' FEEDBACKS

Dr. Öğr. Üyesi Murat Fatih TUNA¹

Dr. Öğr. Üyesi Mesut POLATGİL²

Prof. Dr. Oğuz KAYNAR³

ÖZ

Günümüzde tüketicilerin ürün ve hizmetler konusunda fikir paylaşabilecekleri birçok mecra bulunmaktadır. Bu fikirler, geri bildirim yapıları itibarıyla genellikle metin formatındadır. Duygu analizi, metin tabanlı bilgi kaynaklarında son yıllarda önem kazanan bir konudur. Daha hassas bir duygu analiz türü olan Hedef Tabanlı Duygu Analizi bir cümle içerisinde hedef terim, hedef kategori ve duygu sınıfının belirlenmesi işidir. Bu çalışmada Semeval ABSA yarışmasında yarışmacılara sunulan restoran müşterilerine ait yorumlardan oluşan bir veri seti kullanılmıştır. Word2vec, Glove, Fasttext ve Bert yöntemleri kullanılarak veri seti üzerinde hedef terim, hedef kategori ve duygu sınıfının belirlenmesi işlemi gerçekleştirilmiştir. Kelimeyi vektörü ile cümle vektörünün birleştirilmesi ABSA için sınıflandırma başarısını artırıp artıramayacağı hipotezi test edilmiştir. Dört farklı vektör yöntemi ile yapılan sınıflandırmada hedef terim için 0,78 F1 skoru ile Fasttext yöntemi, hedef kategori için 0,57 F1 skoru ile Fasttext ve duygu sınıfı için 0,76 F1 skoru ile Bert yöntemi en başarılı sonuçları vermiştir. Bu sonuçlar literatürde farklı veri setleri ve farklı diller için yapılan çalışmalarla kıyaslanmıştır. Sonuç olarak Fasttext ve Bert temsil yöntemlerinin hedef tabanlı Türkçe dilindeki metinlerin duygu analizinde başarılı sonuçlar verdiği tespit edilmiştir.

Anahtar Kelimeler: Restoran Yorumları, Hedef Tabanlı Duygu Analizi, Fasttext, Bert.

JEL Sınıflandırma Kodları: O47, O53, E13, R11.


ABSTRACT


Today, there are many channels where consumers can share their ideas about products and services. These opinions are usually in text format due to the nature of the feedback. Sentiment analysis is a topic that has gained importance in recent years, especially in text-based information sources. Aspect-based Sentiment Analysis, which is a more sensitive sentiment analysis technique, is the task of determining the aspect term, aspect category and sentiment class in a sentence. A data set consisting of the comments of restaurant customers presented to the competitors in the Semeval ABSA competition is used in the study. Using Word2vec, Glove, Fasttext and Bert methods, the aspect term, aspect category and sentiment class are determined on the data set. The hypothesis is tested whether combining the word vector and the sentence vector can improve classification success for ABSA. In the classification made with four different vector methods, Fasttext method with 0.78 F1 score for the target term, Fasttext with 0.57 F1 score for the target category, and Bert method with 0.76 F1 score for the sentiment class have the most successful results. These results are compared with studies in the literature for different data sets and different languages. As a result, it is determined that Fasttext and Bert representation methods give successful results in sentiment analysis of target-based Turkish language texts.

Keywords: Restaurant Reviews, Aspect Based Sentiment Analysis, Fasttext, Bert.

JEL Classification Codes: O47, O53, E13, R11.

¹  Sivas Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, mftuna@cumhuriyet.edu.tr

²  Sivas Cumhuriyet Üniversitesi, Şarkışla Uygulamalı Bilimler Yüksekokulu, Bilişim Sistemleri ve Teknolojileri Bölümü, mesutpolatgil@cumhuriyet.edu.tr

³  Sivas Cumhuriyet Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, okaynar@cumhuriyet.edu.tr

EXTENDED SUMMARY

Purpose and Scope:

Reviews of consumers are a type of information which must be considered by businesses when they form their marketing strategies. Customers' reviews on the use of any product or service are one of the most important parameters that real and potential customers consider when deciding whether to prefer the relevant product. Developments in the informatics and communication sector have allowed consumers to share their ideas about products and services, thus allowing them to freely express their views. This type of information is usually in text format due to the nature of the feedback. Sentiment analysis is a topic that has gained importance in recent years, especially in text-based information sources. However, classical sentiment analysis falls short in analyzing feedback from businesses that have sub-products and services, such as hotels or restaurants. However, the situation is not the same for aspect-based sentiment analysis (ABSA). As a more sensitive and fine-grained analysis technique in sentiment analysis, ABSA covers the tasks of determining the aspect term, aspect category and sentiment class in a sentence. In the SemEval'15 ABSA Competition held in 2016, four subtasks were defined regarding aspect-based sentiment analysis: aspect term detection, aspect category detection, sentiment term detection and sentiment polarity detection. This study focuses on aspect term detection, aspect category detection and sentiment term detection, which are related subtasks that point to the restaurant service component.

Design/methodology/approach:

In this study, a new model has been proposed by authors for aspect term, category and sentiment classification on the Turkish restaurant dataset created in the ABSA competition. The data set used in this study is publicly accessible and has been prepared for ABSA SemEval'15 competition. There are 1415 sentences in this data set. 148 of these sentences don't contain any sentiments. The sentences that don't contain the target term ('null') have not been evaluated in analysis proc. Using Word2vec, Glove, Fasttext and Bert methods, the aspect term, aspect category and sentiment class have been determined on the data set. While using these representation methods, ready vector models obtained because of training on large data sets have been also used in the study. For this process, the hypothesis that a successful classification can be made by combining the vector representing the word and the vector representing the sentence has been tested. At the point of the performance of these sub-tasks, the performance levels of the methods used have been tested by experimenting with various machine learning methods on the data set containing Turkish restaurant comments and presented to the contestants in the competition.

Findings:

In the study, a Keras Library-based neural network model has been used, and all the information about the neural network used has been given as Python code. As a result of classification process, in the classification made with four different vector methods, Fasttext method with 0.78 F1 score for the target term, Fasttext with 0.57 F1 score for the target category, and Bert method with 0.76 F1 score for the sentiment class have the most successful results. The performance of the models in which different word representation methods are used in sentiment classification is almost close to each other. The method using the BERT word representation method has showed the best performance compared to the others with a score of 0.76.

Conclusion and Discussion:

Results derived from machine learning process have been compared with studies in the literature for different data sets and different languages. As a result, it has been determined that Fasttext and Bert representation methods give successful results in sentiment analysis of target-based Turkish language texts. The results obtained in this study, in parallel with the literature, support that embedded representation methods can be used as a good feature identifier independent of classification algorithms in identifying aspect terms, categories and sentiments from ABSA tasks. It is thought that performance criteria can be increased by creating different data sets specific to different products and trying alternative methods on them. One of the problems that marketing science seeks to solve is to evaluate customers' feedback accurately and quickly. At this point, the study has the feature of being one of the effective tools for understanding customer views on services with multiple dimensions. In this respect, it is thought that the study will contribute both to businesses that produce products and services with more than one sub-dimension, and to academics who conduct various sentiment analysis studies on textual feedback.

1. GİRİŞ

Müşterilerin herhangi bir ürünü ya da hizmeti kullanmaya ilişkin geri bildirimleri, gerçel ve potansiyel müşterilerin ilgili ürünü tercih etme ya da etmeme kararını verirken göz önünde bulundurdıkları en önemli parametrelerden biridir. Nitekim sosyal medya ve internet teknolojilerindeki gelişim, müşterilerin deneyimlerini birçok açıdan farklı coğrafyalarda yaşayanlara bile rahatlıkla aktarabilmesini mümkün kılmaktadır. Web 2.0'ın yaygınlaşması ve akabinde geliştirilen mobil teknolojiler sayesinde var olan içeriklerin büyük bir kısmı sosyal medyadaki aktif kullanıcılar tarafından üretilir hale gelmiştir (Çetin ve Eryiğit, 2018). İçeriklerin firmalar tarafından değil de kullanıcılar tarafından üretilmesi, bir yandan tüketicilerin arasındaki etkileşimi güçlendirirken, diğer yandan işletmeler ve onların ürünleri üzerinde daha fazla söz sahibi hale gelmişlerdir. Nitekim bugün bir firmanın kendi ürünü hakkındaki iddialarından daha fazla inanılan bir şey varsa o da o firmanın ürünü hakkındaki tüketicilerin sosyal medyada var olan algısıdır. Dünya genelinde faaliyet gösteren firmaların yaklaşık onda dokuzunun mevcut bütçelerinin yaklaşık %11'ini sosyal medyadaki tüketici katılımına ayırmaları, bunun en büyük göstergesidir (de Oliveira Santini vd., 2020).

Müşterilerle karşılıklı ilişkilerin kurulması ve yönetilebilmesi için, müşterilerden gelen geri bildirimlerin etkin biçimde değerlendirilerek dönüş sağlanması gerekmektedir. Omisakin vd. (2020, s. 3), bu geri bildirimlerin yeterince hızlı yapılabilmesi durumunda müşteri sadakatini artırabileceğini ifade etmektedir. Bu geri bildirimlerin günümüzde en fazla alınabildiği kaynaklardan biri sosyal medya ve mikro bloglardır (Kim vd., 2011). Nitekim bu kaynaktan sağlanan ürün ve hizmetlere ilişkin veriler genellikle son kullanıcılardan sağlanmakta ve giderek işletme karar süreçleri açısından daha yaygın kullanılır hale gelmiştir. Bunlardan bazıları ürün ve hizmetlere ilişkin son kullanıcı yorumlarını içerdiğinden, işletmelerin karar süreçlerinde yararlandıkları bir tür veri sağlayıcı konumuna gelmişlerdir. Bu noktada bahsedilen kanallar hem tüketicilerin ürün ve hizmetlerle ilgili bilgi arayışlarına yardımcı olmakta hem de ilgili kurumların kendilerini daha iyi tanıtmalarına imkân vermektedir (Ahuja ve Medury, 2010). Dahası firmalar, tüketicilerin erişimine açık olan platformlardan elde ettikleri geri bildirimler doğrultusunda ürün ve hizmetlerini iyileştirebilmektedirler. Çetin ve Eryiğit (2018, s. 44) bu durumu; "...kullanıcıların aldıkları ürün ve hizmetler ile ilgili görüşlerinin toplanması ve incelenmesi ve bu incelemeler ışığında her kurum veya firmanın kendine ait dersler çıkarabilmesi önemli bir ihtiyaç olarak karşımıza çıkmaktadır." şeklinde ifade etmektedir. Bahsedilen iyileştirmeler ve platformda paylaşılan geri bildirim göstergeleri, işletmeyi tercih etme ihtimali bulunan potansiyel müşteriler için de viral bir cazibe yaratmaktadır (Chen vd., 2004).

İnternet teknolojilerini kullanan tüketiciler akran etkisiyle sürekli olarak fikirlerini ve görüşlerini paylaşma yönünde güdülenmekte, bu durum da sosyal medya ve mikro bloglarda ürün ve hizmetlere yönelik yorumların artış göstermesine neden olmaktadır (Schouten ve Frasinca, 2016). Lee ve Bradlow (2011, s. 881) bu olguyu "müşteriyi müşterinin sesiyle çağırma" şeklinde ifade etmektedir. Ayrıca Barger vd. (2016)'ne göre günümüz tüketicisi sosyal medya ve mikro bloglardan gelen verilere yoğun ilgi göstermektedir. Bunun bir sebebi olarak tüketicilerin ürün ve markalar hakkında ilginç şeyleri paylaşıyor olmaları da gösterilebilir ki Berger ve Iyengar (2013, s. 568) bunun muhtemel iki sebebi bulunduğunu öne sürmektedir: (i) ürün ve markalar hakkında gönderileri kendilerine yansıtacak bir gelişim motivasyonu olarak görmeleri ve (ii) tüketicilerin mesaj yazmaya konuşmadan daha istekli olmaları. Yazmanın daha etkili bir yönelim olmasından ötürü, sosyal medya ve mikro bloglar temelinde yer alan veriler genel olarak metinsel ifadelerden oluşmaktadır. Çetin ve Eryiğit (2018, s. 44)'e göre bu yazılar genellikle tüketicilerin kendi dillerinde oluşturulmaktadır. Dolayısıyla sosyal medyada var olan tüketici görüşlerini içeren metinsel ifadeleri incelemek bir anlamda onların taleplerini üretim sürecine aktarmak anlamına gelmektedir. Buradan hareketle, elde edilen görüşleri incelemeyi mümkün kılacak bir takım veri madenciliği temelli tekniklere ihtiyaç duyulmuştur (Do vd., 2019). Nitekim bu görüşleri manuel olarak analiz edilmesinin zaman maliyeti yüksek olduğu gibi insanlar tarafından objektif bir yaklaşımla değerlendirilmesi güçtür (Yoldaş, 2021).

Duygu analizleri 2000'li yıllar itibariyle akademik ve endüstriyel alanlarda kullanılan trend yöntemlerden biri haline gelmiştir (Pang vd., 2002). Brun vd. (2016, s. 838) duygu analizlerinin doküman, cümle ya da hedef tabanında gerçekleştirildiğini ifade etmektedir. Bu düzeylerden hedef tabanlı duygu analizi (ABSA-Aspect Based Sentiment Analysis) bir metnin içinde yer alan farklı duyguların ilgili oldukları hedef varlıklar ile birlikte tespit edilmesidir (Çetin ve Eryiğit, 2018). İnce taneli bir analiz metodu olan bu analiz, genel olarak spesifik bir alana özgü büyük veri setleri üzerinde makine öğrenmesi temelli olarak gerçekleştirilmektedir (Liu vd., 2015). Dahası, hedef terim genellikle çeşitli kelimeler tarafından temsil edildiğinden, bu yöntem genellikle birden çok

sınıflandırma algoritmasının kullanımını gerektirmektedir (Schouten ve Frasinca, 2016). Bu yöntem, restoran ve oteller gibi tüketici duygularının birden çok hedefe işaret edebileceği işletmelere dair kullanıcı yorumlarında tercih edilen güçlü bir yöntemdir. Yöntemi gerçekleştirmek için kullanıcı yorumları (örneğin restoranlara ilişkin) sisteme girdi olarak verilmekte ve ilgili işletmedeki hedef ürün özelliklerine (örneğin yemek, servis ya da fiyat) bağlı olarak özetlenmektedir (Ma vd., 2019).

2016 yılında düzenlenen SemEval'15 ABSA (Aspect Based Sentiment Analysis) yarışmasında, hedef tabanlı duygu analizlerine ilişkin dört alt görev tanımlanmıştır. Bu görevler; hedef terim tespiti, hedef kategori tespiti, duygu teriminin tespiti ve duygu kutupsallığının tespit edilmesidir (Zhang vd., 2022). Bu çalışma, restoran hizmet bileşenine işaret eden ilgili alt görevlerden hedef terim tespiti, hedef kategori tespiti ve duygu teriminin tespitini konu edinmektedir. Bu alt görevlerin başarımı noktasında, bahsedilen yarışmada yarışmacılara sunulan ve Türkçe restoran yorumlarını içeren veri seti üzerinde çeşitli makine öğrenmesi yöntemleriyle denemeler yapılarak kullanılan yöntemlerin başarım düzeyleri test edilmiştir. Dolayısıyla araştırma soruları şu şekildedir:

- Daha önce eğitilmiş modellerden eğitilen kelime temsil vektörleri (Word2vec, Glove, Fasttext, Bert) ABSA 2016 veri seti için hedef terim tespitinde sınıflandırma başarısını artırabilir mi?
- Daha önce eğitilmiş modellerden eğitilen kelime temsil vektörleri (Word2vec, Glove, Fasttext, Bert) ABSA 2016 veri seti için hedef kategori tespitinde sınıflandırma başarısını artırabilir mi?
- Daha önce eğitilmiş modellerden eğitilen kelime temsil vektörleri (Word2vec, Glove, Fasttext, Bert) ABSA 2016 veri seti için duygu tespitinde sınıflandırma başarısını artırabilir mi?

2. LİTERATÜR

ABSA'nın asli alt görevlerinden biri olan hedef terim çıkarımı, belirli bir metinde ifade edilen görüşlere ilişkin hedef terimleri ayıklama olarak tanımlanabilir (Li vd., 2020). Hedef terimlerin tespiti, hedef tabanlı duygu analizlerinin başlangıcı olarak kabul edilmektedir. Giannakopoulos vd. (2017), duygu analizlerinde hedef terimin tespitinin gerekliliğini iki zorluğa bağlamaktadır. Bunlardan birincisi cümle düzeyindeki duygu analizinin nitelikli bilgiler sağlamada yaşadığı güçlülüdür (Li vd., 2018). İkincisi ise birçok cümle veya paragrafın, farklı hedeflere karşı zıt kutuplar içermesi ve doğru bir genel polarite atamanın oldukça zor oluşudur (Li ve Lam, 2017). Bu zorluklar metin derlemleri içinden hedef terimin tespitini gerekli kılmaktadır. "Pizza lezzetliydi fakat hizmet korkunçtu" şeklinde bir cümle, bir restoran işletmesi için "pizza" ve "hizmet" hedef terimlerinin çıkarılabileceği örnek cümle olarak gösterilebilir (Zhang vd., 2022). Hedef terim çıkarımı, ABSA ile ilgili literatürün en fazla odaklandığı konu olma özelliği taşımaktadır. Literatürde makine öğrenmesi temelli hedef çıkarımı çalışmalarının denetimli (Li vd., 2018), yarı-denetimli (Li vd., 2020) ve denetimsiz (He vd., 2017) makine öğrenmesi yöntemleriyle gerçekleştirildiği görülmektedir. Makine öğrenmesi ile hedef terim çıkarımını konu edinen çalışmaların ağırlıklı olarak denetimli makine öğrenmesi yöntemlerini tercih ettiği görülmektedir. Denetimli hedef çıkarımı çalışmalarında sınıflandırma metodu olarak HAST (Li vd., 2018); CL-BERT (Yang vd., 2020); Seq2Seq4ATE (Ma vd., 2019); MIN (Li ve Lam, 2017); B-LSTM (Giannakopoulos vd., 2017); CMLA (Wang vd., 2017) ve DE-CNN (Xu vd., 2018) yöntemlerinin kullanıldığı görülmektedir.

Bu yöntemlerden HAST (History Attention and Selective Transformation), Li vd. (2018) tarafından önerilen ve yorumların tarihsel sıralaması temelinde hedef terim temsili yapabilen bir yöntemdir. CL-BERT (Constituency Lattice Bidirectional Encoder Representation from Transformers) ön eğitilmiş bir doğal dil işleme yöntemi olan BERT yönteminin seçim örgüsü (constituency lattice) yöntemi ile birleştirilmiş olan versiyonudur (Yang vd., 2020). Bir kelimenin anlamını ardıl ve öncülleriyle semantik ilişkiler yardımıyla değerlendirmeyi sağlayan BERT yöntemi, nöral makine çeviri yöntemlerinin klasik ifade tabanlı dil işleme yöntemlerinden daha başarılı performans üretmesine olanak tanıyan dikkat (attention) mekanizması ile birleştirilmektedir. Dikkat sayesinde kod çözücüler birtakım gizli durumların oluşması durumunu hafifletmek için kaynak dizisine geri dönebilmektedir. Dikkati eşli çok katmanlı kullanan bir yöntem olan CMLA (Coupled Multi-Layer Attentions), hedef terim dikkati (aspect attention) ile fikir dikkatinden (opinion attention) oluşmaktadır. Yüksek standartlarda etiketlenmiş veri gerektiren bu yöntem, bu dikkat mekanizmalarına hangi 'token'ların ne olasılıkla denk gelecek bir temsil oluşturacağını belirlemeye odaklanmaktadır (Wang vd., 2017). Bunun dışında Seq2Seq4ATE (Sequence to Sequence for Aspect Term Extraction) yinelemeli sinir ağlarını bir sekans girdisi alan ve bir başka sekans çıktısı verilen ağların hedef terim belirlenmesinde belirlediği bir modeldir (Ma vd., 2019). Bir diğer yöntem olan MIN (Memory Interaction Network), hedef terim çıkarım görevlerinde başarılı sonuçlar üreten ve LSTM (Long Short Term Memory) temelli

çoklu derin öğrenme görevlerinde kullanılan bir yöntemdir (Li ve Lam, 2017). LSTM temelli bir diğer yöntem olan B-LSTM, ağırlı yinelenmeli olarak iki yönde eğitilmesi prensibine dayanmaktadır (Liu vd., 2015). Derin öğrenme temelli bir diğer yöntem olan DE-CNN (Double Embeddings-Convolutional Neural Network) çift gömülü evrimsel ağlar anlamına gelmektedir. Burada kullanılan ikinci gömülü katman, bir önceki katmanın ürettiği faydalı bilgilerin daha kolay elde edilmesini sağlamaktadır (Xu vd., 2018).

Yarı-denetimli hedef çıkarımı çalışmaları incelendiğinde koşullu artırım (Li vd., 2020) ve Softproto (Chen ve Qian, 2020) yöntemlerini kullanan çalışmalara ulaşılmıştır. Bu yöntemlerden koşullu artırım (conditional augmentation), hedef terim çıkarımında mevcut verilerden sentetik veriler üretmek veri setini artırmayı ön gören bir yöntemdir (Li vd., 2020). Softproto hedef terim tespitinde dış dünyadan bir prototip yazılım yardımıyla alınan cümlelerin kanıtlayıcı özelliğinin sistemin öğrenme başarısına yansıtılmasına imkân tanımaktadır (Chen ve Qian, 2020). Son olarak denetimsiz hedef terim çıkarımı çalışmaları incelendiğinde, WDEmbed (Yin vd., 2016); LCC+GBC (Liao vd., 2019) ve ABAE (He vd., 2017) yöntemlerinin kullanıldığı görülmektedir. Bu yöntemlerden WDEmbed (Word and Dependency Path Embedding), Yin vd. (2016) tarafından geliştirilen bir gömülü kelime temsil yöntemidir. LCC+GBC ise Liao vd. (2019) tarafından geliştirilmiş olan bir hedef terim çıkarma yöntemidir. Bu yöntemde küresel ve yerel çaptaki metin derlemleriyle eşlenen hedef terimi işaret eden göstergeler artırılma yoluna gidilmiştir. Yine He vd. (2017) tarafından kullanılan ABAE (Attention-Based Aspect Extraction), tıpkı CL-BERT ve CMLA gibi dikkat mekanizmasından yararlanan yöntemlerden biridir ve var olan gömülü hedef terimlerin en yakın komşularıyla birlikte anlamlandırılmasını sağlamaktadır.

ABSA'nın ikinci alt görevi olan hedef kategori tespiti, belirli bir cümlede verilen hedef kategorilerin belirli bir alana özgü ön tanımlı bir kategori kümesine ait olduğunu tespit etmektir (Pontiki vd., 2014). Bir önceki alt görevde verilen örneğin devamı olarak hedef kategori tespitinde, uygulanan modelin yemek ve hizmet kategorilerini tahmin etmesi gerekmektedir (Movahedi vd., 2019). Zhang vd. (2022), tüketicileri doğru anlayabilme noktasında hedef kategorinin tespitinin iki açıdan hedef terimin tespitinden daha faydalı olacağını savunmaktadır. Bunlardan birincisi, hedef terimin genelde bireysel terimleri tahmin etmede başarılıyken, hedef kategorinin kapsayıcı (şemsiye) terimi tahmin etmede başarılı olmasıdır (Ghadery vd., 2019). İkincisi hedef kategori tespitinin cümlede açıkça bahsedilmese bile hedef terimi belirleyebilecek yetiye sahip olmasıdır (Zhou vd., 2015). “Fiyatlar çok abartılı ve tadı güzel değil” gibi bir örnek cümlede, hedef kategori tespiti sayesinde sistem sırasıyla “fiyat” ve “yemek” kategorilerini tespit edebilecektir (Zhang vd., 2022). Makine öğrenmesi yöntemiyle hedef kategori tespitini ele alan literatürün ilgili görevi denetimli (Zhou vd., 2015) ve denetimsiz (Shi vd., 2020) yöntemler temelinde ele aldığı görülmektedir. Birinci alt göreve göre literatürde çok daha az yer bulan bu çalışmalardan denetimli makine öğrenmesi kullananların LICD (Ghadery vd., 2019) ve RepLearn (Zhou vd., 2015) gibi yöntemlere başvurduğu gözlemlenmiştir. Bu yöntemlerden LICD (Language-Independent Category Detection), kategori tespitinden dilden bağımsız olarak gerçekleştirilmesine olanak sağlayan bir yöntemdir. Bu yöntem, spesifik bir kategoriye ait olan belirli bir cümlenin, ilgili kategoriyi temsil edecek bir dizi anahtar kelimeye yüksek anlamsal benzerlik taşınması üzerine kuruludur (Ghadery vd., 2019). RepLearn (Representation Learning) yöntemi ise etiketlenmemiş verilerden oluşan büyük veri setlerinde kullanılan bir temsil öğrenmesi yöntemidir (Zhou vd., 2015). Bu yöntemde farklı kelimeler arasındaki anlamsal ilişkilerin kolaylıkla yakalanması mümkün olmaktadır. Bununla birlikte denetimsiz makine öğrenmesi kullananların ise SSCL (Shi vd., 2020) ve CAT (Tulkens ve van Cranenburgh, 2020) gibi yöntemleri seçtiği görülmektedir. Bu yöntemlerden SSCL (Self-Supervised Contrastive Learning), aynı yorum segmentinin iki farklı temsili arasındaki uyumun maksimize etmek için gömülü hedefleri karşıt bir şekilde öğrenebilmektedir (Shi vd., 2020). Diğer yöntem CAT (Contrastive Attention), bir cümlenin ilgili olduğu hedefle alakalı daha fazla karşıt bulunan bilgiyi yine cümle içinden çıkarmayı sağlayan ve bu noktada RadBas fonksiyonunu temel alan bir yöntemdir (Tulkens ve van Cranenburgh, 2020).

Bu çalışmada denemeleri yapılan son ABSA alt görevi, duygu terimi çıkarımıdır. En temel haliyle belirli bir hedefe yönelik duygu ifadesini belirleme görevi olarak tanımlanabilir (Winatmoko vd., 2020). Duygu terimi ve hedef terim her halükârda birlikte kullanıldığından, ilgili hedef terim dikkate alınmadan çıkartılan duygu terimleri anlamını yitirmektedir (Yu vd., 2019). Duygu terim çıkarımı, hedef terimin bir girdi ya da çıktı olarak kullanılma durumuna göre hedef duygu eş çıkarımı ve hedef yönelimli duygu kelimesi çıkarımı olmak üzere iki alt göreve ayrılmaktadır (Zhang vd., 2022). Bu alt görevlerden hedef duygu eş çıkarımı, hedef ve duygu terimlerini birlikte tahmin etmeyi amaçlamaktadır (Wang vd., 2017). Hedef yönelimli duygu kelimesi çıkarımı ise belirli bir hedef terime karşılık gelen duygu terimini çıkarmayı amaçlamaktadır (Fan vd., 2019). Duygu terimi çıkarımının ilki olan hedef duygu eş çıkarımını konu edinen çalışmaların CMLA (Wang vd., 2017), DeepWmaxSAT (Wu vd., 2020) ve HAST (X. Li vd., 2018) yöntemlerini kullandığı görülmektedir. İkinci boyut olan hedef yönelimli duygu

kelimesi çıkarımına odaklanan çalışmalarda ise PositionEmbed (Mensah vd., 2021), IOG (Fan vd., 2019) ve ONG (Veysch vd., 2020) yöntemlerinin tercih edildiği literatürden anlaşılmaktadır. Bu yöntemlerden daha önce açıklanmayan ilk yöntem olan DeepWmaxSAT, hedef terim çıkarımında derin ağırlıklandırma (deep weighted) yöntemi, maksimum anlamsal bağdaşmayı sağlayacak tatmin edici cümle sayısını artırmayı hedefleyen maxSAT (maximum satisfiable clause) yöntemlerinin birleştirilmesinden oluşmaktadır (Wu vd., 2020). PositionEmbed yönteminde, hedef duygunun çıkarımında hedef terimin gömülü kelimelere olan uzaklığı (yani göreceli pozisyonu) temel alınmaktadır (Mensah vd., 2021). Öte yandan IOG Fan vd. (2019) tarafından tasarlanan LSTM temelli bir sinir ağı modeli. Bu model veri setinin içinde ilgili hedef terimi içeren ve içermeyen (inward-outward) metin derlemine analize birlikte dâhil etmekte ve hedef duygunun çıkarımında veri setini küresel bağlamdaki ifadelerle kıyaslamaktadır. Son olarak ONG yöntemiyle (Veysch vd., 2020), hedef duygu tespitinde cümledeki kelimelerin model temelli olasılıklarının hesaplanmasını temel alan sıralı nöron (ordered neuron) ve LSTM yöntemlerini bir arada kullanmışlardır.

Literatürde ayrıca bu çalışmada izlenen yolla benzer biçimde ilk üç alt görevi bir arada ele alan çalışmalara da rastlanmaktadır. Bu çalışmalardan birinde Hercig vd. (2016) tarafından, Çek ve İngilizce dillerindeki restoran yorumlarına hedef tabanlı duygu analizi uygulanmıştır. Çalışmada yöntem olarak HAL, COALS, GloVe, CBOW, SKIP ve LDA yöntemleri ile denetimsiz modeller oluşturulmuştur. Çalışmada hedef terim tespitinde İngilizce ve Çek dilleri için sırasıyla %75,6 ve %71,4 F1 skoru değerlerine ulaşılırken, hedef kategorinin belirlenmesinde F1 skor değerleri sırasıyla %77,6 ve %71,7 olarak belirlenmiştir. Duygu kutupsallığı değerleri ise aynı diller için sırasıyla %67,4 ve %69,7 olarak belirlenmiştir.

Brun vd. (2014) tarafından yapılan bir diğer çalışmada SemEval 2014 yarışmasının veri seti üzerinde hedef terim tespiti, hedef kategori tespiti, duygu terim kutupsallığı tespiti ve bu çalışmada ele alınmayan (dolayısıyla performans ölçütüne ilişkin bilgi verilmeyen) kategori tespiti görevlerine odaklanılmıştır. XRCE sınıflandırma yöntemini kullandıkları çalışmalarında ilk iki alt görev için buldukları F1 skorları sırasıyla %84 ve %82 olmuştur. Üçüncü alt görev olan terim kutupsallığı için performans ölçümü olarak doğruluk değeri seçilmiş ve çalışmada izlenen metot sonucunda ulaşılan değerin yaklaşık %78 olduğu öne sürülmüştür.

Dört alt görevi birlikte konu edinen bir diğer çalışmada Castellucci vd. (2014), SemEval-2014 yarışmasında sunulan iki farklı veri seti (laptop ve restoran yorumlarını içeren) kullanarak ilgili alt görevlere ilişkin makine öğrenmesi temelli bir yaklaşım izlenmiştir. Yazarlar yapılandırılmış öğrenme esasına dayanan UNITOR ismini verdikleri yöntemle laptop ve restoran verileri için; hedef terim tespitinde sırasıyla %75 ve %84 F1 skoru değerlerine; hedef terim kutupsallığının tespitinde ise sırasıyla %80,95 ve %70,48 doğruluk değerlerine ulaşmışlardır. Hedef kategori tespitinde ise sadece restoran verileri üzerinde denemeler yapan yazarlar, en yüksek %89 F1 skoru performans değerine ulaşmışlardır.

Literatürde Türkçe dili için 3 alt görevi birlikte ele alan çalışmalarda ise Çetin ve Eryiğit (2018), hedef terim tespiti için F1 değerini %51, kategori tespitinde %59 ve duygu sınıflandırmasında ise doğruluk değeri olarak %76,1 olarak bulmuşlardır. Çalışmalarında kelime vektörleri, komşuluk değerleri ve koşullu rastgele alanlar yöntemini kullanmışlardır. Bu çalışmada ise farklı kelime temsil vektörlerinin ABSA 3 alt görevi için nasıl başarı göstereceğini cümle vektörünü de hesaba katarak analiz etmektedir.

3. YÖNTEM

3.1. Veri seti

Çalışmada SemEval ABSA 2016 kapsamında oluşturulmuş ve birçok çalışmada da kullanılmış olan Türkçe restoran yorumlarını içeren bir veri seti kullanılmıştır (SemEval, 2016). Bu veri setinde 1415 tane cümle bulunmaktadır. Bu cümlelerden 148'i herhangi bir duygu durumunu içermemektedir. Veri setinden örnek bir ekran görüntüsü Şekil 1'de verilmiştir. XML türünde dosyada yer alan veri setinde id=1008:1 olan cümlede sadece text verisi yani cümle bilgisi bulunurken, id=1008:2 olan cümlede ise Opinions etiketi içerisinde polarity özelliği ile duygu bilgisi bulunmaktadır. Veri setinde yer alan cümlelerde hedef terim barındırmayan ('null') cümleler değerlendirilmeye alınmamıştır.


Şekil 1. Veri Setinden Örnek Birkaç Cümle

```

<sentence OutOfScope="TRUE" id="1008:1">
  <text>Bir arkadaşımın tavsiyesi ile Ortaköy şubesine gittim.</text>
</sentence>
<sentence id="1008:2">
  <text>Fasulyesi ağızda dağılıyor adeta, lokum gibi.</text>
  <Opinions>
    <Opinion target="Fasulyesi" category="FOOD#QUALITY" polarity="positive" from="0" to="9" />
  </Opinions>

```

Veri setinde en çok yer alan hedef terimler Şekil 2’de verilmiştir.

Şekil 2. Veri Setinde En Çok Geçen Hedef Terimler

Kaynak: (Salur vd., 2022).

Şekil 1’de en çok geçen hedef terimlerin mekân, servis, yer ve fiyatlar olduğu görülmektedir. Restoran ile ilgili olabilecek ifadelerin hedef terim olarak öne çıktığı görülmektedir. Veri setinde toplam 9007 adet kelime bulunmaktadır. Eğitim ve test kümelerine göre kelime sayıları ise Tablo 1’de verilmiştir.

Tablo 1. Hedef Terimlerin Eğitim ve Test Veri Seti İçerisindeki Sayıları

	Eğitim	Test	Toplam
Hedef terim	1439	153	1592
Hedef terim değil	6699	716	7415

Tablo 1’de görüldüğü gibi veri, sınıflardaki dağılım farklılıklarından dolayı dengesizlikler içermektedir. Çünkü hedef terim sayısı, hedef terim olmayan diğer kelime sayısına göre oldukça azdır. Hatta hedef terimi ifade eden sayısı, toplam kelime sayısının beşte biri kadardır. Bu tür veri setlerinde dengesizlik özelliğinden modelin etkilenmemesi için çeşitli çözümler bulunmaktadır. Bu çalışmada bu çözümlerden ‘oversampling’ yöntemi kullanılmıştır. Bu yöntem ile örneklerin sayısını dengelemek amacıyla, daha az örneğe sahip sınıfa ait örneklerin kopyalanarak tekrarlanması ve daha fazla örneğe sahip sınıfın örnek sayısına eşitlenmesi işlemidir. Bu işlem, sınıflar arasında dengeyi sağlamak için kullanılır (Coşgun vd, 2019). Bu çalışmada da hedef terim olan cümle sayısı az olduğu için bu verilerden rassal olarak seçilen veriler kopyalanmış ve tekrar eklenmiştir.

Veri setinde hedef terimlere ait kategori bilgileri ise Tablo 2’de verilmiştir.

Tablo 2. Hedef Terimlere Ait Kategori Bilgileri

Kategori	Eğitim	Test
Yiyecek#Kalite (FOOD#QUALITY)	483	72
Ortam#Genel (AMBIENCE#GENERAL)	254	25
Servis#Genel (SERVICE#GENERAL)	237	19
Yiyecek#Stil (FOOD#STYLE_OPTIONS)	137	11
Restoran#Genel (RESTAURANT#GENERAL)	106	9
Restoran#Ücret (RESTAURANT#PRICES)	55	5
İçecek#Kalite (DRINKS#QUALITY)	53	3
Konum#Genel (LOCATION#GENERAL)	38	4
DRINKS#STYLE_OPTIONS	35	-
FOOD#PRICES	31	3
DRINKS#PRICES	9	1
RESTAURANT#MISCELLANEOUS	1	1

Tablo 2’de görüldüğü gibi kategori başına düşen veri sayısının birbirinden farklı olmasından ötürü veri setinin dengesiz olduğu görülmektedir. DRINKS#PRICES ve RESTAURANT#MISCELLANEOUS gibi kategorilerin ise veri setinde oldukça az sayıda yer aldığı da görülmektedir. Veri setinde hedef terimlere ait duygu bilgileri Tablo 3’de verilmiştir.

Tablo 3. Hedef Terimlere Ait Duygu İfadeleri Sayısı

	Eğitim	Test
positive	814	106
negative	506	41
neutral	119	6

Tablo 3’de görüldüğü gibi veri setinde en çok pozitif duygu yoğunluğuna sahip hedef terimler yer alırken, nötr duygu sınıfına sahip hedef terim sayısının oldukça az olduğu görülmüştür.

3.2. Önerilen Yöntem

Bu çalışmada ABSA 2016 yarışması kapsamında 3 temel görevler için bir model önerilmiştir. SemEval ABSA yarışmasında 3 temel görev olduğu belirtilmiştir. Bunlar; cümle düzeyi (sentence-level) ABSA, metin düzeyi (text-level) ABSA ve alan dışı (Out-of-Domain) ABSA olarak adlandırılmıştır. Cümle düzeyi ABSA görevi 3 alt bölüme ayrılmıştır. Bunlar; hedef terimin belirlenmesi, hedef kategorinin belirlenmesi ve duygu sınıfının belirlenmesi. Burada tespit edilen tüm tahminler cümle düzeyinde olmaktadır. Metin düzeyi ABSA kategorisinde analiz bir yorum üzerinden yapılmaktadır ki bu yorum genellikle birden fazla cümle içerebilir. Alan dışı ABSA kategorisinde ekiplere daha önce hiç görmedikleri bir alanda eğitim verisi sağlanmadan sistemlerini test etme imkânı verilmektedir. Yarışma sonuçları değerlendirilmesinde 2 aşama söz konusudur. İlk aşamada hedef terim, hedef kategori çiftinin bulunması, diğer aşamada ise duygu sınıfının bulunması yer almaktadır. Sonuçlar F1 sınıflandırma ölçütüne göre değerlendirilmektedir.

Polatgil vd. (2022) tarafından yapılan çalışmada hedef terim tespiti sadece kelime vektörlerinden yararlanılarak gerçekleştirilmiştir. Bu çalışmada önerilen modelde ise kelimenin kendisine ek olarak cümle vektörü de kullanılmıştır. Bu sayede önceden eğitilmiş modellerden elde edilen gömülü kelime temsil vektörleri ile desteklenmesi sonucunda hedef terimin, kategorisinin ve duygu sınıfının yüksek başarı ile tespit edilebileceği hipotezi test edilmek istenmiştir. Özetle bu araştırma, ABSA 2016 yarışmasında cümle düzeyi ABSA kategorisinin 3 alt görevine odaklanmıştır.

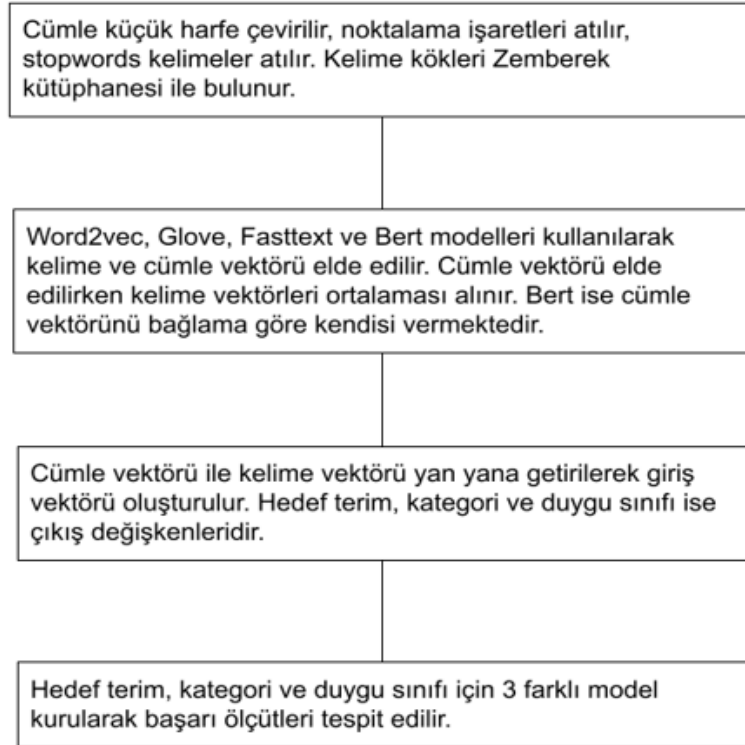
Çalışmada Keras Kütüphanesi kullanılarak oluşturulan sinir ağı modeli kullanılmıştır. Kullanılan sinir ağına ait tüm bilgiler Python kodu olarak aşağıda verilmiştir.

model = Sequential()


```
model.add(Dense(350, input_dim=1537, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(100, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(50, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(15, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(12, activation='sigmoid'))
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=["accuracy"])
```

Sinir ağı ile hedef terim, kategori ve duygu sınıflandırması yapılacağı için 3 farklı model oluşturularak kullanılmıştır. Sinir ağı modelleri hedef terim için 10 epoc ve 30 batch size ile kullanılırken, kategori ve duygu sınıflandırmasında 50 epoc ve 75 batch size değeri ile kullanılmıştır. Bu değerler modellerin başarısını artırmak için deneme yanılma yolu ile elde edilmiştir. Çalışmada önerilen yöntem Şekil 3’de gösterilmiştir.

Şekil 3. Çalışmada Önerilen İşlem Adımları



Şekil 3’de verildiği gibi hedef terimi elde etmek için önerilen model öncelikle ilgili cümlelerin kelimelere bölünmesi, sonrasında küçük harfe dönüştürülmesi, ardından noktalama ve durak (stopwords) kelimelerin atılması gibi bir takım metin ön işleme adımların uygulanması ile başlamaktadır.

Daha sonra her bir kelimenin kökü Zemberek Kütüphanesi yardımı ile elde edilerek bulunur (Akın ve Akın, 2007). Zemberek kütüphanesi ile veri setindeki bir örnek cümle <sentence> etiketleri ile şu şekilde yer almaktadır.

<sentence id="1000:0">

<text>Manzara sahane evet ama servis rezalet.

</text>

<Opinions>

<Opinion target="servis" category="SERVICE#GENERAL" polarity="negative" from="24" to="30" />

<Opinion target="Manzara" category="AMBIENCE#GENERAL" polarity="positive" from="0" to="7" />

</Opinions>

</sentence>

Bu şekildeki cümle için kök bulma işlemi sonuçları ise Şekil 3’de verilmiştir.

Şekil 3. ABSA Veri Setinde Bulunan Örnek Cümlelerin Zemberek ile İşlenmesi

	0	1	2	3
[manzara, sahne, evet, servis, rezalet]	manzara	manzara	1	
[manzara, sahne, evet, servis, rezalet]	sahne	sahne	0	
[manzara, sahne, evet, servis, rezalet]	evet	evet	0	
[manzara, sahne, evet, servis, rezalet]	servis	servis	1	
[manzara, sahne, evet, servis, rezalet]	rezalet	rezalet	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	soğuk	soğuk	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	isteyince	iste	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	soğuk	soğuk	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	bunun	bu	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	sular	su	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	disari	disar	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	cikardik	cikar	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	diyen	diye	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	garson	garson	1	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	siparişten	sipariş	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	saat	saat	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	sonra	sonra	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	gelen	gele	0	
[soğuk, isteyince, soğuk, bunun, sular, disari...]	yemekleri	yemek	0	

Kelime kökleri elde edildikten sonra her kelimenin Word2Vec, Glove ve Fasttext ve Bert yöntemleri ile daha önce hazır olarak eğitilmiş modellerden sırasıyla 400, 300, 300 ve 786 boyutlu gömülü vektör temsil modelleri elde edilmiştir. Kelimeler için bu vektörler kullanılırken cümleler için Bert modeli zaten cümle vektörünü vermektedir. Word2vec, Fasttext ve Glove için ise cümlede bulunan kelime vektörlerinin ortalaması alınarak cümleyi temsil eden vektörü oluşturulmuştur. Bu sayısal vektörler veri seti için giriş bilgisini oluştururken, ilgili terimin hedef terim olup olmadığı, kategorisi ve duygu sınıfı ise çıkış bilgisini oluşturmaktadır. Oluşturulan veri setinden ilk cümle için örnek Tablo 4’de verilmiştir.

Tablo 4. Veri Setinin Yapısı Örnek Cümle Gösterimi

Cümle	Kelime	Vektör	Hedef Terim	Kategori	Duygu
	Manzara	(0,43; 0,47; 0,010,22)	1	AMBIENCE#GENERAL	pozitif
Manzara, şahane, evet, servis, rezalet	Şahane	(0,12; 0,41; 0,590,45)	0	-	-
	Evet	(0,15; 0,52; 0,070,74)	0	-	-
	Servis	(0,59; 0,48; 0,020,36)	1	SERVICE#GENERAL	negatif
	Rezalet	(0,92; 0,14; 0,850,62)	0	-	-

Word2Vec kelime temsillerini elde etmek için daha önceden eğitilmiş bir modelden yararlanılmıştır. Türkçe Wikipedia derlemi kullanılarak eğitilen modelde CBOW yöntemi tercih edilmiş, kelime vektör uzunluğu 400, pencere boyutu ise 5 olarak belirlenmiştir (Köksal, 2022). Glove yöntemi ile oluşturulan diğer model ise 21 GB boyutundaki Commoncrawl verileri ile eğitilerek, 300 uzunluğundaki kelime vektörleri ile oluşturulmuştur (Çiftçi, 2022). Fasttext vektör temsillerini elde etmek için daha önce Grave vd. (2018) tarafından yapılmış bir çalışmada kullanılan ve Türkçe için eğitilmiş 300 uzunluklu kelime vektörüne sahip bir modelden yararlanılmıştır. Bert modeli içinde Transformers Kütüphanesi kullanılarak 768 boyutlu vektör üreten hazır model kullanılmıştır.

4. BULGULAR

ABSA yarışmasında restoran veri seti eğitim ve test olarak ayrılmıştır. Eğitim veri seti yardımıyla önerilen modeller eğitilmiş ve test veri kümesi ile de modellerin başarımları değerlendirilmiştir. Bu çalışmada da eğitim kümesi kullanılarak modeller kurulmuş ve test veri kümesi ile de başarı değerlendirilmiştir. ABSA yarışmasında hedef terim ve kategori tespitinde F1 skoru, duygu sınıflandırmasında ise doğruluk skoru verildiği için bu çalışmada da aynı başarı kriterleri kullanılmıştır. Hedef terim tespiti için gömülü vektörlerin sınıflandırma başarımları Tablo 5’de verilmiştir.

Tablo 5. Hedef Terim Tespiti İçin Gömülü Vektörlerin Sınıflandırma Başarımları

	Word2vec	Glove	Fasttext	Bert
Kesinlik	0,73	0,71	0,75	0,66
Duyarlılık	0,74	0,80	0,81	0,67
F-1 Skoru	0,73	0,752	0,78	0,66

Tablo 5’de gösterildiği gibi test kümesi üzerinde F1 skoru bakımından sırasıyla Word2Vec için ortalama %73, Glove için ortalama %75 ve Fasttext için ortalama %77 ve Bert için %66 başarı elde edilmiştir. Sonuçlardan da anlaşılacağı üzere en iyi başarı 0.78 F1 skoru ile Fasttext vektör temsili kullanılması durumunda elde edilmiştir.

Hedef kategori sınıflandırması için test verileri üzerindeki başarısı Tablo 6’da verilmiştir.

Tablo 6. Kategori Tespiti İçin Gömülü Vektörlerin Sınıflandırma Başarımları

	Word2vec	Glove	Fasttext	Bert
Kesinlik	0,41	0,41	0,6	0,40
Duyarlılık	0,4	0,4	0,59	0,36
F-1 Skoru	0,4	0,4	0,57	0,37

Tablo 6’da kategori tespitinde sınıflandırma başarımlarının hedef terim ve duygu sınıflandırmasına göre daha düşük olduğu görülmüştür. En iyi sonuçları Fasttext algoritması ile elde edilmiştir. Duygu durumu sınıflandırması için test verileri üzerindeki başarısı Tablo 7’de verilmiştir.

Tablo 7. Duygu Tespiti İçin Gömülü Vektörlerin Sınıflandırma Başarımları

	Word2vec	Glove	Fasttext	Bert
Accuracy	0,73	0,75	0,75	0,76

Duygu sınıflandırmasında farklı kelime temsil yöntemlerinin kullanıldığı modellerin başarımları hemen hemen birbirine yakın elde edilmiştir. BERT kelime temsil yönteminin kullanıldığı yöntem 0,76 skorla diğerlerine oranla en iyi başarımları göstermiştir.

5. TARTIŞMA

Bu çalışmada ABSA yarışmasında oluşturulmuş olan Türkçe restoran veri kümesi üzerinde hedef terim, kategori ve duygu sınıflandırması için yeni bir model önerilmiştir. Önerilen modelde cümle vektörü ve kelime vektörü birlikte kullanılmış, buradan hareketle hedef terim, kategori ve duygu sınıflandırması görevinde kullanılabileceği hipotezi araştırılmıştır. Hedef terim tespitine yönelik Türkçe restoran veri seti üzerinde farklı çalışmaların yapıldığı görülmektedir. SemEval ABSA tarafından hedef terim tespiti için temel bir yöntem zaten önerilmiş ve yarışma

ekiplerinden daha başarılı sonuçlar beklenmiştir. ABSA tarafından önerilen temel modelde kategoriler için bir sözlük oluşturulmuştur. Kategorilerde geçen terimler bu sözlük içine konulmuş ve bir terim ilgili kategori sözlüğünde yer alıyorsa hedef terim olarak sınıflandırılmıştır. Bu yöntemin başarısı ise %41,8 olarak belirtilmiştir. Yarışmada Türkçe verisi ile ilgili olarak başka başvuru olmamıştır.

Hedef terim tespit edilmesi için literatürde farklı yöntemler (Bayraktar vd., 2019; Çetin ve Eryiğit, 2018; Kama vd., 2016; Pontiki vd., 2016) ve farklı yöntemlerin birlikte kullanıldığı ensemble (topluluk) yöntemler (Ozyurt ve Akcayol, 2021; Salur vd., 2022; Salur ve Aydın, 2021) önerilmiştir. Önerilen yöntemlerin sınıflandırma başarısında özellikle ABSA temel yöntemine göre iyileştirmeler yapıldığı gösterilmiştir. Bu çalışmalar temel yöntemlere göre başarı göstermiş olsalar da bu çalışmada önerilen yöntem literatürde önerilen diğer yöntemlerden daha üstün performans göstermiştir. Çalışma %78'lik bir sınıflandırma başarımı ile hedef terim tespitinde Türkçe veri seti üzerindeki en yüksek başarıyı elde etmiştir. Kullanılan kelime temsil yöntemleri arasında en iyi sonuç Fasttext algoritması ile alınmıştır.

Hedef terimlerin ait olduğu kategorilerin tespit edilmesi ABSA alanındaki önemli bir başka görevdir. Bu çalışmada önerilen model yine aynı veri setinde kategori tespitinde de kullanılmış ve en iyi sonuç yine Fasttext algoritması ile %57 F1 skoru ile elde edilmiştir. Kategori tespitinde model başarısının biraz düşük kalmasında kategorilere düşen veri miktarının yetersiz olması önemli bir faktör olmuş olabilir. Örneğin DRINKS#STYLE_OPTIONS isimli kategori eğitim verisinde 35 kez bulunmakta iken test veri setinde hiç bulunmamaktadır. Buna rağmen model %57 F-1 skor değeri ile kategorileri sınıflandırmayı başarmıştır.

Hedef terim ve kategorinin tespit edilmesinden sonra duygu sınıfının belirlenmesi ABSA için yine önemli aşamalardan birisidir. Çalışmada önerilen model duygu sınıflandırması ile kullanılmış ve %76 doğruluk skoru ile duygu sınıflandırması başarılı bir şekilde gerçekleştirilmiştir. Pozitif ve negatif duygu sınıflarının tespitinde modelin daha başarılı olduğu görülürken nötr duygu sınıfının tespitinde başarının daha düşük olduğu görülmüştür.

Literatürde ABSA görevini ele alan çalışmalar ile karşılaştırıldığında bu çalışmada önerilen modelin diğer çalışmalarla benzer başarı gösterdiği hatta bazı noktalarda daha başarılı olduğu görülmüştür. Brun vd., 2014 tarafından gerçekleştirilen çalışmada ilk iki alt görev için daha başarılı sonuçlar %84 ve %82 bulunurken duygu sınıfı tespitinde ise yakın sonuçlar (yaklaşık %78) bulunmuştur (Castellucci vd., 2014). SemEval-2014 yarışmasında sunulan iki farklı veri seti (laptop ve restoran yorumlarını içeren) kullanarak ilgili alt görevlere ilişkin makine öğrenmesi temelli bir yaklaşım izlenmiştir. Yazarlar yapılandırılmış öğrenme esasına dayanan UNITOR ismini verdikleri yöntemle laptop ve restoran verileri için; hedef terim tespitinde sırasıyla %75 ve %84 F1 skoru değerlerine; hedef terim kutupsallığının tespitinde ise sırasıyla %80,95 ve %70,48 doğruluk değerlerine ulaşmışlardır. Hedef terim tespitinde Laptop veri seti için bu çalışmada önerilen model daha başarılı sonuç verirken restoran veri setinde de yine bu çalışmadaki model duygu tespitinde daha başarılı olmuştur. Ayrıca kategori tespitinde model daha başarılı sonuçlar vermiştir. Bu durum önerilen modellerin farklı veri setlerinde farklı başarılar gösterebilmesinin bir sonucu olarak görülebilir. Türkçe dili üzerinde yapılan çalışmalarda Semeval Absa 2016 verileri kullanıldığı için bu çalışmada da bu veri seti kullanılmıştır.

Hercig vd. (2016), İngilizce ve Çek dilleri için sırasıyla %75,6 ve %71,4 F1 skoru değerlerine ulaşılırken bu çalışmada %77 ile hedef terim tespiti yapılabilmektedir. Duygu kutupsallığı değerleri ise aynı dilleri için sırasıyla %67,4 ve %69,7 olarak belirlenirken bu çalışmada ise aynı başarı kriteri %76 olarak hesaplanmıştır. Hedef kategorinin belirlenmesinde F1 skor değerleri sırasıyla %77,6 ve %71,7 olarak bulunurken bu çalışmada daha düşük bir oran (%57) elde edilmiştir. Yani bu çalışmada önerilen yöntem hedef terim ve duygu sınıfı tespitinde daha başarılı sonuçlar elde etmiştir. Çalışmada kelime vektörüyle cümle vektörünün birlikte kullanılmasının ABSA yarışmasındaki üç temel kategorideki başarısı test edilmiştir. Araştırma sonuçları, önerilen yöntemin hedef terim ve duygu sınıfının tespitinde başarılı olduğunu ortaya koymuştur. ABSA ile ilgili çalışmalar bir ürün ya da ticarete konu olan çok boyutlu herhangi bir meta hakkında klasik duygu analizlerinden daha keskin sonuçlara ulaşılmasını sağlamaktadır. Bu sayede tüketicilerin geri bildirimlerinden hareketle ilgili ürüne ve bünyesinde barındırdığı özelliklere ilişkin detaylı bilgiler elde edilebilmektedir. Bu çalışmada elde edilen sonuçlar, literatürle paralellik gösterir biçimde, gömülü temsil yöntemlerinin ABSA görevlerinden hedef terim, kategori ve duygu belirlemede sınıflama algoritmalarından bağımsız olarak iyi bir öznitelik belirleyici olarak kullanılabileceğini desteklemektedir. Farklı ürünlere özgü farklı veri setlerinin oluşturulması ve bunlar üzerinde alternatif yöntemlerin denenmesi ile başarımların artırılacağı düşünülmektedir. Pazarlama biliminin çözüm aradığı sorunlardan biri müşterilerin geri bildirimlerini doğru ve hızlı biçimde değerlendirmektir. Bu noktada çalışma, birden çok boyutu olan hizmetlere ilişkin müşteri görüşlerinin anlaşılmasına yönelik etkin araçlardan biri olma

özelliği taşımaktadır. Nitekim müşteri geri bildirimlerinin hızlı analizi, işletmelerin ana ürünleri ile bu ürünlere ilişkin alt hedeflere ilişkin alınacak veri destekli kararların ortaya konma hızına pozitif yönde katkı sağlayabilecektir.

Literatürde ABSA görevinin Türkçe dili üzerinde gerçekleştirildiği çalışma sayısı oldukça sınırlıdır (Çetin ve Eryiğit, 2018). Hatta ABSA yarışmasında da Türkçe dili üzerinde yarışmaya katılım oldukça azdır. Bu yüzden Türkçe dili üzerinde ABSA görevinin analiz edilmesi ve yeni yöntemlerin önerilmesi oldukça önemlidir. Çalışma bu yönü ile literatüre katkı sağlamaktadır.

Bu yönüyle çalışmanın hem birden fazla alt boyutu olan ürün ve hizmet üreten işletmelere hem de metinsel geri bildirimler üzerinde çeşitli duygu analizi çalışmaları yürüten akademisyenlere ve firmalara katkı sağlayacağı düşünülmektedir. Günümüzde bazı önemli e-ticaret siteleri artık müşteri yorumlarında öne çıkan özellikleri gösterebilmektedir. Örneğin bir ürünü satın alırken ürüne yapılan binlerce yorum içerisinde ürünün fiyatı ya da beden ölçüsü gibi hedef terimleri vurgulayarak müşterilerin önem verdikleri kriter ile ilgili yorumları incelemesini sağlayabiliyorlar. Bu özellik ABSA içerisinde ki hedef terimin belirlenmesi işlemine bir örnektir. Ayrıca ilgili hedef terim bazında o terim ile ilgili duygu durumu yani puanlanamsı da yine ABSA içerisinde yer alan duygu sınıfının tespit edilmesi görevine karşılık gelmektedir. Dolayısıyla bu çalışmada önerilen model bu gibi durumlarda başarı ile uygulanabilir. Böylece insanlar alışveriş yaparken satın almayı düşündükleri ürün ile ilgili bilgilere daha spesifik olarak bakabilirler. Şirketler sosyal medya ortamında kendileri ile ilgili yapılan yorumları analiz ederek firmaları hakkında insanların hangi konuları öne çıkardıklarını tespit edebilir bu konulardaki duygu durumlarını inceleyerek tedbirler alabilirler.

6. SONUÇ

Bu çalışmada ABSA için yeni bir model önerilmiştir. Önerilen model üç alt görev için kelime vektörü ile cümle vektörünün yan yana eklenmesi ile daha başarılı olabileceğini göstermiştir. Özellikle hedef terim ve duygu sınıfının tespitinde önerilen model başarılı olurken kategori tespitinde ise başarı düşük kalmıştır. Ayrıca kelime ve cümle vektörleri oluşturulurken farklı yöntemlerde karşılaştırılmıştır ve en iyi sonuçlar Fasttext yöntemi ile elde edilmiştir. Çalışma sonucunda ABSA için kelime ve cümle vektörlerinin yan yana eklenmesinin model başarısını artırıcı bir unsur olacağına ve fasttext vektörlerinin sonuç üzerinde daha başarılı olduğuna ulaşılmıştır.

Bu çalışma, ABSA yarışması kapsamında sunulan veri seti ile gerçekleştirilmiştir. Bundan sonra ABSA için Türkçe dilinde yeni veri setleri yaratılmıştır. Bu veri setleri üzerinde de önerilen model test edilebilir. Ayrıca hedef terim, kategori ve duygu tespiti bir firmanın itibarının incelenmesinde, bir kişi ile ilgili analizlerde de kullanılabilir.

YAZARLARIN BEYANI

Katkı Oranı Beyanı: Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

Destek ve Teşekkür Beyanı: Çalışmada herhangi bir kurum ya da kuruluştan destek alınmamıştır.

Çatışma Beyanı: Çalışmada herhangi bir potansiyel çıkar çatışması söz konusu değildir.

KAYNAKÇA

Ahuja, V. ve Medury, Y. (2010). Corporate blogs as e-CRM tools – building consumer engagement through content management. *Journal of Database Marketing & Customer Strategy Management*, 17(2), 91-105.

Akın, M. D. ve Akın, A. A. (2007). Türk dilleri için açık kaynaklı doğal dil işleme kütüphanesi: ZEMBEREK. *Elektrik mühendisliği*, 431, 38-44.

Barger, V., Peltier, J. W. ve Schultz, D. E. (2016). Social media and consumer engagement: A review and research agenda. *Journal of Research in Interactive Marketing*, 10(4), 268-287.

Bayraktar, K., Yavanoglu, U. ve Ozbilen, A. (2019). A rule-based holistic approach for Turkish aspect-based sentiment analysis. *2019 IEEE International Conference on Big Data* (s. 2154-2158). Los Angeles, CA, USA.

- Berger, J. ve Iyengar, R. (2013). Communication channels and word of mouth: how the medium shapes the message. *Journal of Consumer Research*, 40(3), 567-579.
- Brun, C., Popa, D. N. ve Roux, C. (2014). XRCE: hybrid classification for aspect-based sentiment analysis. *Proceedings of the 8th International Workshop on Semantic Evaluation* (s. 838-842). Dublin, Ireland.
- Castellucci, G., Filice, S., Croce, D. ve Basili, R. (2014). UNITOR: aspect based sentiment analysis with structured learning. *Proceedings of the 8th International Workshop on Semantic Evaluation* (s. 761-767). Dublin, Ireland.
- Chen, P.-Y., Wu, S. ve Yoon, J. (2004). The impact of online recommendations and consumer feedback on Sales. *ICIS 2004 Proceedings* (s. 711-724). Washington, DC, USA.
- Chen, Z. ve Qian, T. (2020). Enhancing aspect term extraction with soft prototypes. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing* (s. 2107-2117). Punta Cana, Dominican Republic.
- Coşgun, E., Çelebi, A. ve Güllü, M. K. (3-5 Ekim 2019). Dengesiz Veri Kümeleri İçin Epileptik Nöbet Tahmini, Tıp Teknolojileri Kongresi, Kuşadası/Aydın.
- Çetin, F. S. ve Eryiğit, G. (2018). Türkçe hedef tabanlı duygu analizi için alt görevlerin incelenmesi – hedef terim, hedef kategori ve duygu sınıfı belirleme. *Bilişim Teknolojileri Dergisi*, 11(1), 43-56.
- Çiftçi, O. (2022). *Türkçe GloVe - Repository for Turkish GloVe word embedding*. <https://github.com/inzva/Turkish-GloVe> adresinden 18 Ekim 2022 tarihinde alınmıştır.
- de Oliveira Santini, F., Ladeira, W. J., Pinto, D. C., Herter, M. M., Sampaio, C. H. ve Babin, B. J. (2020). Customer engagement in social media: A framework and meta-analysis. *Journal of the Academy of Marketing Science*, 48(6), 1211-1228.
- Do, H. H., Prasad, P., Maag, A. ve Alsadoon, A. (2019). Deep learning for aspect-based sentiment analysis: A comparative review. *Expert Systems with Applications*, 118, 272-299.
- Fan, Z., Wu, Z., Dai, X.-Y., Huang, S. ve Chen, J. (2019). Target-oriented opinion words extraction with target-fused neural sequence labeling. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, Volume I (s. 2509-2518). Minneapolis, MN, USA.
- Ghadery, E., Movahedi, S., Jalili Sabet, M., Faili, H. ve Shakery, A. (2019). LICD: A language-independent approach for aspect category detection. L. Azzopardi, B. Stein, N. Fuhr, P. Mayr, C. Hauff, ve D. Hiemstra (Ed.), *Advances in information retrieval* içinde (s. 575-589). Springer International Publishing.
- Giannakopoulos, A., Musat, C., Hossmann, A. ve Baeriswyl, M. (2017). Unsupervised Aspect Term Extraction with B-LSTM & CRF using Automatically Labelled Datasets. *Proceedings of the 8th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis* (s. 180-188). Copenhagen, Denmark.
- Grave, E., Bojanowski, P., Gupta, P., Joulin, A ve T. Mikolov (2018). Learning word vectors for 157 languages. *Proceedings of the Eleventh International Conference on Language Resources and Evaluation* (s. 3483-3487). Miyazaki, Japan.
- He, R., Lee, W. S., Ng, H. T. ve Dahlmeier, D. (2017). An Unsupervised Neural Attention Model for Aspect Extraction. *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics-Volume 1* (s. 388-397). Vancouver, Canada.

- Hercig, T., Brychcín, T., Svoboda, L., Konkol, M., Steinberger, J., Hercig, T., Brychcín, T., Svoboda, L., Konkol, M. ve Steinberger, J. (2016). Unsupervised methods to improve aspect-based sentiment analysis in Czech. *Computación y Sistemas*, 20(3), 365-375.
- Kama, B., Ozturk, M., Karagoz, P., Toroslu, I. H. ve Ozay, O. (2016). A web search enhanced feature extraction method for aspect-based sentiment analysis for Turkish informal texts. S. Madria ve T. Hara (Ed.), *Big data analytics and knowledge discovery* içinde (s. 225-238). Springer International Publishing.
- Kim, K.-S., Yoo-Lee, E. ve Joanna Sin, S.-C. (2011). Social media as information source: Undergraduates' use and evaluation behavior. *Asis&t*, 48(1), 1-3.
- Köksal, A. (2022). *Turkish Pre-trained Word2Vec Model*. <https://github.com/akoksal/Turkish-Word2Vec> adresinden 19 Ekim 2022 tarihinde alınmıştır.
- Lee, T. Y. ve Bradlow, E. T. (2011). Automated marketing research using online customer reviews. *Journal of Marketing Research*, 48(5), 881-894.
- Li, K., Chen, C., Quan, X., Ling, Q. ve Song, Y. (2020). conditional augmentation for aspect term extraction via masked sequence-to-sequence generation. *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (s. 7056-7066). World Wide Online.
- Li, X. ve Lam, W. (2017). Deep multi-task learning for aspect term extraction with memory interaction. *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing* (s. 2886-2892). Copenhagen, Denmark.
- Li, X., Bing, L., Li, P., Lam, W. ve Yang, Z. (2018). Aspect term extraction with history attention and selective transformation. *ArXiv:1805.00760*, 4194-4200.
- Liao, M., Li, J., Zhang, H., Wang, L., Wu, X. ve Wong, K.-F. (2019). Coupling global and local context for unsupervised aspect extraction. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing* (s. 4579-4589). Hong Kong, China.
- Liu, P., Joty, S. ve Meng, H. (2015). Fine-grained opinion mining with recurrent neural networks and word embeddings. *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing* (s. 1433-1443). Lisbon, Portugal.
- Ma, D., Li, S., Wu, F., Xie, X. ve Wang, H. (2019). Exploring sequence-to-sequence learning in aspect term extraction. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics* (s. 3538-3547). Florence, Italy.
- Mensah, S., Sun, K. ve Aletras, N. (2021). An empirical study on leveraging position embeddings for target-oriented opinion words extraction. *arXiv:2109.01238*, 9174-9179.
- Movahedi, S., Ghadery, E., Faili, H. ve Shakery, A. (2019). Aspect category detection via topic-attention network, *arXiv:1901.01183*, 1-9.
- Omisakin, O. M., Bandara, C. ve Kularatne, I. (2020). Designing a customer feedback service channel through AI to improve customer satisfaction in the supermarket industry. *Journal of Information & Knowledge Management (JIKM)*, 19(03), 1-34.
- Ozyurt, B. ve Akcayol, M. A. (2021). A new topic modeling based approach for aspect extraction in aspect based sentiment analysis: SS-LDA. *Expert Systems with Applications*, 168, 114231.

- Pang, B., Lee, L. ve Vaithyanathan, S. (2002). Thumbs up? Sentiment classification using machine learning techniques. *Proceedings of the 2002 Conference on Empirical Methods in Natural Language Processing* (s. 79-86). Philadelphia, PA, USA.
- Pontiki, M., Galanis, D., Papageorgiou, H., Androutsopoulos, I., Manandhar, S., AL-Smadi, M., Al-Ayyoub, M., Zhao, Y., Qin, B., De Clercq, O., Hoste, V., Apidianaki, M., Tannier, X., Loukachevitch, N., Kotelnikov, E., Bel, N., Jiménez-Zafra, S. M. ve Eryiğit, G. (2016). *SemEval-2016 task 5: Aspect based sentiment analysis. Proceedings of the 10th International Workshop on Semantic Evaluation* (s. 19-30). San Diego, CA, USA.
- Pontiki, M., Galanis, D., Pavlopoulos, J., Papageorgiou, H., Androutsopoulos, I. ve Manandhar, S. (2014). SemEval-2014 task 4: Aspect based sentiment analysis. *Proceedings of the 8th International Workshop on Semantic Evaluation* (s. 27-35). Dublin, Ireland.
- Salur, M. U. ve Aydin, İ. (2021). An annotated Turkish aspect based sentiment analysis corpus for smart tourism. *Proceedings of Innovations in Intelligent Systems and Applications Conference* (s. 1-6). Elazig, Turkey.
- Salur, M. U., Aydın, İ. ve Jamous, M. (2022). An ensemble approach for aspect term extraction in Turkish texts. *Pamukkale University Journal of Engineering Sciences*, 28(5), 769-776.
- Schouten, K. ve Frasincar, F. (2016). Survey on aspect-level sentiment analysis. *IEEE Transactions on Knowledge and Data Engineering*, 28(3), 813-830.
- SemEval (2016). *Task 5: Aspect-Based Sentiment Analysis*. <https://alt.qcri.org/semeval2016/task5/> adresinden 17 Kasım 2022 tarihinde alınmıştır
- Shi, T., Li, L., Wang, P. ve Reddy, C. K. (2020). A simple and effective self-supervised contrastive learning framework for aspect detection, *arXiv:2009.09107*, 1-13.
- Tulkens, S. ve van Cranenburgh, A. (2020). Embarrassingly simple unsupervised aspect extraction. *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (s. 3182-3187). World Wide Online.
- Veyseh, A. P. B., Nouri, N., Derroncourt, F., Dou, D. ve Nguyen, T. H. (2020). Introducing syntactic structures into target opinion word extraction with deep learning, *arXiv:2010.13378*, 8947-8956.
- Wang, W., Pan, S. J., Dahlmeier, D. ve Xiao, X. (2017). Coupled multi-layer attentions for co-extraction of aspect and opinion terms. *Proceedings of the AAAI Conference on Artificial Intelligence*, 31(1), 1-7. San Francisco, CA, USA.
- Winatmoko, Y. A., Septiandri, A. A. ve Sutiono, A. P. (2020). Aspect and Opinion Term Extraction for Hotel Reviews using Transfer Learning and Auxiliary Labels, *arXiv:1909.11879*, 1-5.
- Wu, M., Wang, W. ve Pan, S. J. (2020). Deep weighted maxsat for aspect-based opinion extraction. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing* (s. 5618-5628). World Wide Online.
- Xu, H., Liu, B., Shu, L. ve Yu, P. S. (2018). Double embeddings and CNN-based sequence labeling for aspect extraction. *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics-Volume 2* (s. 592-598). Melbourne, Australia.
- Yang, Y., Li, K., Quan, X., Shen, W. ve Su, Q. (2020). Constituency lattice encoding for aspect term extraction. *Proceedings of the 28th International Conference on Computational Linguistics*, (s. 844-855). Barcelona, Spain (Online).

- Yin, Y., Wei, F., Dong, L., Xu, K., Zhang, M. ve Zhou, M. (2016). Unsupervised word and dependency path embeddings for aspect term extraction. *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence* (s. 2979-2985). New York, USA.
- Yoldaş, İ. N. (2021). Türkçe metinlerde duygu analizi: sözlük tabanlı yaklaşım ve insanların tepkilerinin karşılaştırılması. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 2(1), 1-6.
- Yu, J., Jiang, J. ve Xia, R. (2019). Global inference for aspect and opinion terms co-extraction based on multi-task neural networks. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 27(1), 168-177.
- Zhang, W., Li, X., Deng, Y., Bing, L. ve Lam, W. (2022). A survey on aspect-based sentiment analysis: Tasks, methods, and challenges, *arXiv:2203.01054*, 1-21.
- Zhou, X., Wan, X. ve Xiao, J. (2015). Representation learning for aspect category detection in online reviews. *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence* (s. 417-423). Austin, TX, USA.