

## GOOGLE MAPS İŞLETME YORUMLARININ DUYGU ANALİZİ

Sentiment Analysis of Google Maps Business Reviews

Caner EKİNCİ

Düzce Üniversitesi Bilgisayar Mühendisliği Bölümü, [canereknc37@gmail.com](mailto:canereknc37@gmail.com)

### ÖZET

Bu makalede Google Maps'te restoranlara yönelik yapılan yorumların duygu analizine yer verilmiştir. 1000 veri bulunduran veri kümesi; Selenium kütüphanesi ile restorana ait yorum, yorumun sahibi, restoranın ismi ve yorumun sahibinin verdiği puanlama verileri çekilerek oluşturulmuştur. Literatürün incelenmesi ve veri kümesinin analizi sonucunda veriler 5 kategoriye ve 3 duygu sınıfına ayrılmıştır. Veri kümesinin küçüklüğü ve verinin dengesiz dağılıma sahip olması nedeniyle veri çoğaltım teknikleri uygulanmıştır. Modelin eğitim aşamasında Keras-nlp kütüphanesinde bulunan BERT dil modeli kullanılmıştır. Modelin başarı performansına etki eden dizi uzunluğu ve çay sayısı parametreleri üzerinde değişiklikler yapılarak en iyi sonucu veren model bulunmuştur. Eğitilen BERT modelinin başarı değeri literatürde uygulanan modeller sonucundaki başarı değerleri ile karşılaştırılmıştır. En iyi sonucu veren model %98.5 doğruluk skoruyla bu çalışmada eğitilen BERT modeli olmuştur. Bu çalışmanın amacı, işletmelerin yapay zeka yardımıyla internet ortamında kendilerine yönelik yapılan yorumların analizini çıkarmalarını sağlamaktır.

**Anahtar Kavramlar:** Doğal Dil İşleme, Fikir Madenciliği, Duygu Analizi

### ABSTRACT

In this paper, sentiment analysis of restaurant reviews on Google Maps is presented. A dataset with 1000 data was created with Selenium library by extracting the comment of the restaurant, the author of the comment, the name of the restaurant and the rating data given by the author of the comment. As a result of reviewing the literature and analyzing the dataset, the data was divided into 5 categories and 3 emotion classes. Due to the small size of the dataset and the unbalanced distribution of the data, data augmentation techniques were applied. In the training phase of the model, the BERT language model in the Keras-nlp library was used. The parameters that affect the success performance of the model, such as sequence length and number of epochs, were varied and the model that gave the best results was found. The success value of the trained BERT model was compared with the success values of the models applied in the literature. The model that gave the best result was the BERT model trained in this study with an accuracy score of 98.5%. The aim of this study is to enable businesses to analyze the comments made about them on the internet with the help of artificial intelligence.

**Keywords:** Natural Language Processing, Opinion Mining, Sentiment Analysis

## 1 GİRİŞ

Fikir madenciliği (Opinion Mining) ya da duygu analizi, sosyal medyanın yaygınlaşmasıyla günümüzde popüler hale gelen doğal dil işlemenin alt disiplini [1]. Fikir madenciliği, fikrin özneliği, duygu sınıflandırması, fikir özetlemesi gibi konulardan meydana gelir [2]. Fikir madenciliği, yapısal olmayan verilerin anlaşılmasını amaçlar [3]. Sosyal medya kullanıcılarının bazıları, bazı durumlarda sosyal medyayı aracı olarak kullanarak bir konuya yönelik fikirlerini belirtmektedirler ve belirtilen bu fikirler diğer sosyal medya kullanıcılarının fikirlerini etkilemektedir. Örnek olarak bir müşteri bir ürünü satın almadan önce ürüne yönelik yorumlara bakması ve karar vermesi gösterilebilir.

Duygu analizi üç seviyede ele alınır. İlki doküman seviyesi duygu analizi, dokümanın geneline göre duygu sınıfının belirlenmesi işlemidir. İkincisi cümle seviyesi duygu analizi, dokümandaki her cümleye göre duygu sınıfının belirlenmesi işlemidir. Sonuncusu ise hedef seviyesi (aspect level) duygu analizi, dokümandaki nesne veya nesnelerin özelliğinin duygu sınıfını belirlenmesi işlemidir. Örneğin "Bu restoranın yemekleri oldukça lezzetliydi" cümlesinde nesne restoran, nesnenin özelliği ise lezzettir. Hedef seviyesi duygu analizi diğer duygu analizi seviyelerine göre daha ayrıntılı bilgiler edinmeyi sağlar [4].

Fikir madenciliğinde makine öğrenimi, sözlük tabanlı ve hibrit yaklaşımlar uygulanmaktadır. Sözlük tabanlı yaklaşım, terim sözlüğü kullanılarak fikir madenciliğinin uygulanmasıdır. Sözlük tabanlı yaklaşım, makine öğrenimine göre belirli bir alana bağlı kalmamaktadır fakat dolaylı olarak belirtilen fikirlerde makine öğrenimine göre düşük performans vermektedir [5]. Literatürde en çok kullanılan yöntem makine öğrenimi yöntemidir ve aynı zamanda diğer iki yöntemle göre daha başarılı sonuçlar verdiği görülmüştür [6]. Derin öğrenmede evrişimli sinir ağları (CNN) ve yinelemeli sinir ağları (RNN) kullanılarak fikir madenciliğinde modeller geliştirilmektedir [7]. Günümüzde doğal dil işleme çığır açmış olan XLNet ve GPT-3 gibi ön eğitilmiş dil modellerinden biri olan BERT dil modeli fikir madenciliğinde yaygın olarak kullanılmaktadır. BERT dil modeli, yapılan çalışmaya bağlı olarak külliyat veya külliyatlar ile eğitilmektedir ve ince ayarlamalara gereksinim duymaktadır [8].

Bu makalede Google Maps'te restoran işletmelerine yönelik yapılan yorumlar kullanılarak hedef tabanlı (aspect based) duygu analizi yapılmıştır. İşletmelerde müşteri memnuniyeti büyük öneme sahiptir. Müşterinin restoran hakkında olumsuz bir yorum yapması restorana kötü bir itibar sunar ve bu durumun işletmenin satışlarını etkimesi mümkündür [9]. Bu çalışmanın amacı, işletme hakkında yapılmış yorumların teker teker incelenmesinin büyük miktarda zaman gerektirmesi durumuna çözüm olarak duygu analizine yönelik yapay zeka sunmaktır.

Akshay Krishna ve ekip arkadaşları, Kaggle web sitesinde bulunan restoran incelemeleri veri kümesinde duygu analizi gerçekleştirdiler. Kelimeleri vektörlere dönüştürme aşamasında kelime torbası (BOW) yöntemi kullanılmıştır ve sınıflandırma modelini oluşturmada ise K En Yakın Komşu (KNN), Naive Bayes (NB), Rastgele Orman (RF), Karar Ağacı (DT) ve Destek Vektör Makineleri (SVM) modelleri kullanılmıştır. En iyi sonuç %94.56 doğruluk skoruyla SVM olmuştur [10].

Naimul Hossain ve ekip arkadaşları Bangladeş'te bulunan 2 restorana hakkında yapılan 1000 yorum ile duygu analizi yapmışlardır. Kelime gömmesi olarak Word2vec kullanılmış ve boyut olarak 300 atanmıştır. Model olarak CNN ve uzun-kısa süreli bellek (LSTM) katmanları kullanılmıştır. CNN düşük seviye özellikleri, LSTM ise yüksek seviye özellikleri yakalamaktadır. Gömme katmanı işlendikten sonra CNN ve maksimum havuzlama katmanları kullanılmıştır. En sonda LSTM katmanı, seyreltme ve tam bağlı katman kullanılmıştır. Optimizasyon algoritması olarak Adam, kayıp fonksiyon olaraksa binary crossentropy kullanılmıştır. Eğitim kümesi %75 ve test kümesi ise %25 olarak bölünmüş olup eğitimin doğruluk skorunun %94, testin doğruluk skoru ise %75 çıktığı belirtilmiştir. Bu çalışmada BERT kullanılsa da BERT'in metin sınıflandırmada daha iyi sonuca ulaşacağı belirtilmiştir [11].

Meesala Shobha Rani ve Sumathy Subramanian, SemEval2014 veri kümesi üzerinde hedef seviyesinde fikir madenciliği gerçekleştirmişlerdir. SemEval2014 veri kümesi, restorana yönelik yorum, bu yorumun restoranın hangi özelliğine yapıldığı ve bu özelliğin duygu sınıfı bilgilerini içerir. Restoran özellikleri olarak Atmosfer (Ambience), Yemek Food), Personel (Staff), Fiyat (Price), Kişisel Deneyimler (Anecdotes) ve Çeşitli (Miscellaneous) bulunmaktadır. Uygulamada geçitli yineleyen birim (GRU) ve evrişim katmanı kullanılmıştır. Bu katmanlardan sonra ilgi mekanizması eklenmiştir. Glove ve konuşma kısmı etiketlemenin (POS Tagging) yapılmasının sonuca etkisi incelenmiştir. En iyi sonucu %98.29 doğruluk skoru ile GPTAGRUAMCNN modeline aittir ve literatürdeki diğer çalışmalardan daha iyi sonuç vermiştir. GPTAGRUAMCNN, konuşma kısmı etiketleme işleminin yapılması ve Glove kelime gömmesinin kullanılması aşamalarını içerir. Bu model, GRU, ilgi mekanizması ve CNN katmanları kullanılarak oluşturulmuş ve eğitilmiştir [12].

Ahmed R. Abas ve ekip arkadaşları, üç veri kümesi üzerinde hedef tabanlı derin öğrenme modeli geliştirmişlerdir. Üç veri kümesinin içerikleri, restoran yorumları, Twitter film yorumları ve laptop yorumlarıdır. Laptop incelemeleri ve restoran incelemeleri veri kümesi SemEval2014 ile tanıtılmıştır. Kelime gömmesi olarak BERT kullanılmıştır. BERT, bir kelimenin yerel bağlama ya da küresel bağlama gireceğine karar vermektedir. BERT için ince ayarlamalar gerekmektedir ve ince ayarlamalar BiGRU katmanı ile sağlanmıştır. Aynı zamanda uzun vadeli bağımlılıkları bulmak için de BiGRU katmanı kullanılmıştır. Çok başlı ilgi katmanında ilgi skorları hesaplanmaktadır. İnce ayarlama kısmının son aşamasında evrişim katmanı uygulanmıştır. Çıkış katmanında maksimum havuzlama ve tam bağlantılı katman kullanılmıştır. Tam bağlantılı katmanda aktivasyon fonksiyonu olarak softmax kullanılmıştır. Oluşturulan modelin doğruluk skorunun %91.6 olduğu ve state of art modellerinden daha iyi bir sonuç verdiği gözlemlenmiştir [13].

Avinash Kumar ve ekip arkadaşları, BERT dil modelinin eğitiminin uzun sürmesi probleminde bahsetmişlerdir ve bu sebeple çalışmalarında BERT dil modelinden daha kısa sürede eğitilen model geliştirmişlerdir. Bu çalışmada SemEval veri kümesindeki laptop incelemeleri ve restoran incelemeleri veri kümesi kullanılmıştır. FastText ve Glove kelime gömmesinin kullanılması sonucuyla ortaya çıkan vektörler birleştirilip BiLSTM katmanına verilerek bahsi geçen model oluşturulmuştur. Sonuç kısmında laptop incelemeleri veri kümesi için en iyi sonuç state of art modellerden biri olan BERT-PT iken, restoran incelemeleri veri kümesi için ise önerilen model olmuştur. BERT-PT modeli, laptop veri kümesi için f1-skoru %84.26, önerilen modelin f1-skoru ise %84.01'dir. Restoran incelemeleri veri kümesi için BERT-PT modelinin f-skoru %89.63, önerilen modelin f1-skoru ise %89.96'dır [14].

## 2 VERİ KÜMESİ VE ANALİZİ

Veri biliminde veriyi anlamak ve verinin analizini çıkarmak, modellerin geliştirilmesinde önemli bir süreçtir. Bu çalışmada kullanılan veri kümesi, Google Maps'teki restoran yorumlarından oluşturulmuştur.

### 2.1 Verinin Toplanması

Veri kümesi Google Maps'teki restoran yorumları kullanılarak oluşturulmuştur. Yorumların daha iyi işlenmesi ve veri çoğaltımı amacıyla İngilizceye çevrilmiştir. Veri kümesi, 1121 adet veri içermektedir. Veri kümesinin hedef sınıfı ise "category\_sentiment" sütunu bilgisidir.

### 2.2 Verinin Açıklanması


Web kazıma tekniğiyle çekilen verilerle oluşturulan veri kümesinde 4 sütun bilgisi bulunmaktadır. Author, incelemenin sahibini temsil etmektedir. Review, inceleme yazısıdır. Restaurant\_name, yapılan incelemenin hangi

restorana yönelik olduğuna dair bilgidir. Category\_sentiment ise yapılan yorumun restoranın vurgulanan özelliğine yönelik duygu sınıfıdır. Bu sütun bilgisi, duygu sınıfı için Google Maps'teki restoran yorumlarında yapılan puanlamalar baz alınmıştır. 1 ve 2 puanları negatif, 3 nötr, 4 ve 5 puanları ise pozitif olarak değerlendirilmiştir. Kategori bilgisi için manuel etiketleme yapılmıştır. Kategoriler, Fiyat, Yemek, Atmosfer, Hizmet (Service), Çeşitli olarak 5'e ayrılmıştır. Bu kategoriler, literatürde kullanılan veri kümelerinin etiketlerinin incelenmesiyle ve web kazıma tekniğiyle çekilen yorumların analizi sonucuyla oluşturulmuştur. Tablo 1'de bu projede kullanılacak veri kümesinin bütün sütunlarını içeren 5 satır örnek verilmiştir.

Tablo 1: Açıklanan veri kümesine ait 5 örnek gösterilmektedir.

author	review	restaurant_name	category_sentiment
sait tas	We said really disgusting meat, it came without cooking, we didn't like it, I don't recommend it, unfortunately it didn't suit the service I feel like my money was stolen	Köfteci Yusuf	FOOD#NEGATIVE
Kerim Akgün	Everywhere in oil!The tables are very dirty, the tables are not swept full of garbage and the sewer smell from the sea	Burger King - Konak Pier AVM	AMBIENCE#NEGATIVE
Leyla BAYRAKTAR	Perfect quality place waiters are also tolerant and friendly	Sandal Restaurant	SERVICE#POSITIVE
Okan OKAN	Price performance is a venue. Normally, you need to request for butter that comes with the service.	Bursa Pideli Köfte	PRICE#POSITIVE
Nilüfer'in Koleksiyonu	It was very delicious, but it was very hot, even though we asked if there was an air conditioner on the top floor.We saw an air conditioner who had no good at the bottom of the toilets. We didn't get up because we were curious about the taste. but we were very overwhelmed. Hamburger menus do not have a drink, average 70-80 TL.	Quick Pizza Bolu	MISCELLANEOUS#NEUTRAL

Veri kümesindeki 5 özelliğin dağılımı şekil 1'de verilmiştir.



Şekil 1: Özelliklere ait dağılım grafiği

### 2.3 Verinin Temizlenmesi

Restoran incelemeleri veri kümesinde, yorum ve puanlama arasında çelişki içeren cümleler, kelimenin belirli bir karakterinin uzatılarak yazıldığı cümleler silinmiştir. Verilerin temizlenmesi sonucu veri kümesinde 1000 veri kalmıştır.

### 2.4 Verinin Çoğaltılması

Veri çoğaltımı tekniği elimizde bulunan verinin yetersiz olduğu ya da veri dağılımının dengesiz olduğu durumda kullanılan tekniktir. Görüntüler için veri çoğaltımı, görüntünün kırılması ya da görüntünün döndürülmesi gibi işlemlerden geçmesiyle veri çoğaltılır. Doğal dil işleme alanında, kelimelerin eş anlamlıları ile değiştirilmesi ya da cümleye kelime veya kelimelerin eklenmesiyle elde edilen veri çoğaltılmış olur [8]. Bu projede veri çoğaltımı tekniği olarak kelimelerin eş anlamlılarıyla değiştirilmesi yöntemi kullanılmıştır. Eş anlamlı kelimelerin değiştirilmesinde Wordnet kullanılmıştır. Yapılan bu işlem sonucu eğitim kümesinde 4000 çoğaltılmış veri ve test kümesinde ise 1000 gerçek veri bulunmaktadır.

## 3 MODELLERİN KARŞILAŞTIRILMASI

Bu çalışmada kullanılan veri kümesinin, literatürde bahsedilen veri kümelerinden farklı olması sebebiyle modellerin karşılaştırılması için literatürde uygulanmış aşamalar bu projede de uygulanacak ve çıkan sonuçlar değerlendirilecektir.

Andi Suciati ve Indra Budi, çalışmalarında web kazıma tekniği ile çekilmiş İngilizce ve Endonezya dilleriyle yazılmış yorumların karmasını içeren 2000 restoran incelemesi üzerinde hedef tabanlı duygu analizi yapmışlardır.

Etiketlerde özellik olarak Yemek, Fiyat, Hizmet ve Atmosfer, duygu sınıfı olarak ise pozitif, negatif ve nötr kullanılmıştır. Aynı zamanda nötr duygu sınıfı, yapılan incelemede bahsedilmeyen özellikler için de kullanılmıştır. Manuel olarak etiketlenen etiketlerin her bir özelliğinin kendi duygu sınıfı bulunur.

Veri ön işleme aşamasında, incelemede “:)” ifadesi pozitif kelimesine ve “:(“ ise negatif kelimesine çevrilmiştir. Kelimeleri küçük harfe dönüştürme, yazının denetimi ve kısaltılarak kullanılan kelimeleri uzun haline dönüştürme işlemi yapılmıştır. İncelemedeki linkler, kullanıcı adı ve noktalamalar temizlenmiştir. İncelemedeki ardışık yinelenen karakterler ve boşluklar temizlenmiştir.

Özellik çıkarım aşamasında BOW yöntemi kullanılmıştır. BOW yöntemi, kelimelerin sırasını gözetmeksizin her bir dokümandaki kelimelerin, bulunduğu dokümanda kaç kere bulunduğunu içeren sayısal bilgilerdir [15]. Vektör boyutu külliyattaki eşsiz kelime sayısı kadardır. BOW sonucu ortaya çıkan vektörde kelime frekansı düşük olan kelimeler çıkarılmıştır. BOW yönteminde parametre olarak n gram alanı bulunmaktadır. N gram, kelimelerin sırasına göre art arda n kelimenin dokümanda kaç kere bulunduğu anlamına gelir. Bahsedilen çalışmada bigram (2 gram) kullanılmıştır.

Bu çalışmada 4 senaryo bulunur. Bu senaryolar, etkisiz kelimelerin çıkartılması, kelimelerin köke ayrılması, iki yöntemin de kullanılması veya kullanılmamasını içermektedir. Başarı değerleri özelliklerin doğruluk skorlarına bakılarak değerlendirilmiştir. K katlamalı çapraz doğrulama değeri olarak 10 değeri kullanılmıştır. Ortalama en iyi sonucu %80,31 doğruluk skoru ile 2. senaryo vermiştir [16].

Çalışmada bahsedilen aşamalar bu projede uygulanmış ve en iyi senaryo olarak 2. senaryo bulunmuştur. Modellerin başarı değerleri tablo 2’de verilmiştir.

Tablo 2: Yukarıda bahsedilen yöntemlerin test kümesi üzerindeki doğruluk skorları

Model	Test Doğruluk Yüzdesi
Rassal Orman	%97.5
Naive Bayes	%82.5
Karar Ağacı	%73.7
Ekstra Ağaç	%98
Lojistik Regresyon	%93.1

Naimul Hossain ve ekip arkadaşları, SemEval2015, SemEval2016, Sentihood veri kümeleri üzerinde nesne ve özelliklerinin tespitini yapmışlardır. SemEval2016 veri kümesi, 1708 eğitim verisi ve 576 test verisi içermektedir.

Veri ön işleme aşamasında etkisiz kelimeler, ek boşluklar, özel karakterler ve noktalamalar kaldırılmıştır.

Word2vec, benzer anlamlı kelimelerin vektör uzayında yakın noktalarda bulunacakları fikrine dayandırılır. Doğal dil işleme alanında bir zamanlar dönüm noktası haline gelmiş kelime gömmelerinden biridir. Word2vec için 2 farklı mimari kullanılmaktadır. Bunlardan ilki olan Sürekli Kelime Torbası (CBOW), etrafındaki bağlam kelimelerinden hedef kelime tahmini yapar. Skip-gram ise hedef kelimedenden etrafındaki kelimelerin tahminini yapmaktadır [17]. Özellik çıkarımında Word2vec modeli külliyat ile eğitilmiş ve vektör boyutu ise 400 olarak belirlenmiştir.

Model, evrişim katmanı, ardışık 3 BiLSTM katmanı ve dikkat mekanizmasından oluşur. İlk LSTM katmanı 300 gizli birim iken son iki LSTM katmanı ise 250 gizli birim olarak belirlenmiştir. Son katmanda tam bağlı katman kullanılmıştır ve aktivasyon fonksiyonu olarak da softmax kullanılmıştır. Optimizasyon algoritması Adam seçilmiştir. Eğitim için çağ sayısı ve yığın boyutu 128 olarak belirlenmiştir.

LSTM katmanı, yinelemeli sinir ağlarının kaybolan gradyan problemine çözüm olarak ortaya çıkmıştır. Yinelemeli Sinir Ağları, bir dizi veriyle çalışır ve önceki çıkışlardan etkilenir. Örnek olarak metinler, videolar ve ses

verileri gösterilebilir. Veri girişinin büyük olması durumunda yinelemeli sinir ağları öğrenememektedir ve bu sorunun çözümünde LSTM geliştirilmiştir [18].

Derin öğrenme alanında önemli kavramlardan biri olan ve biyolojik sistemden esinlenerek yapılan dikkat mekanizması, büyük miktardaki bilgilerde ayırt edici kısımların odaklanılmasını sağlar [19].

Bahsedilen çalışmadaki sonuçlar SemEval2015 veri kümesi için %68.08, SemEval2016 veri kümesi için %68.08, Sentihood veri kümesi için %69.95 doğruluk skoru bulunmuştur [11].

Bahsedilen çalışmanın aşamaları bu projede uygulandı ve doğruluk skoru %11.2 olarak bulunmuştur.

Eman Saeed Alamoudi ve Norah Saleh Alghamdi, Yelp web sitesine ait 2 sınıflı ve 3 sınıflı olan 2 veri kümesi üzerinde duygu analizi yapmışlardır. Çalışma, geleneksel makine öğrenme, derin öğrenme, BERT ve ALBERT modelleri ile yapılmıştır.

Veri ön işleme aşamasında kelimeleri küçük harfe dönüştürme, alfabetik olmayan karakterleri kaldırma, zamirleri kaldırma, null veri ya da tekrarlı verinin kontrolünü yapma ve lemmatizasyon işlemini gerçekleştirmişlerdir. Lemmatizasyon, kelimeyi kök haline getirme işlemidir [20]. Önceden bahsedilmiş olan köke getirme işlemleri basit seviyede köke indirmektedir. Lemmatizasyon, dilin dil bilgisi kurallarına göre kelimeyi kök haline dönüştürmektedir. En son aşamada ise etkisiz kelimeler çıkarılmıştır.

Özellik çıkarım aşamasında, geleneksel makine öğrenme yöntemleri için BOW ve terim frekansı - ters metin frekansı (TF-IDF) kullanılmıştır. BOW yöntemi, terim frekansı (TF) ile vektör çıkartmaktadır. TF-IDF yöntemi, kelime frekansı bilgisi ve bir kelimenin diğer dokümanların kaçında bulunduğu bilgisini içerir. Bir kelimenin diğer dokümanların kaçında bulunduğu bilgisine ters metin frekansı (IDF) denir ve bu bilgi logaritma ile hesaplanır. Vektörler terim frekansı ve ters metin frekansının çarpımından meydana gelir [21]. Glove, genel ve yerel kelimelerin birlikte bulunma istatistiklerine dayanarak oluşturulmuş olan kelime gömmesi yöntemlerinden biridir [17]. Derin öğrenme yönteminde özellik çıkarımı için rastgele ağırlıklar, dondurulmuş ağırlıklar ile Glove ve ince ayar yapılmış Glove kelime gömmesi kullanılmıştır. Oluşturulan vektör 300 boyutludur. BERT ve ALBERT için ön eğitilmiş ağırlıklar kullanılmıştır.

Sınıflandırma aşamasında geleneksel makine öğrenme yöntemi için 2 model kullanılmıştır. Bunlar Naive Bayes ve Lojistik Regresyon modelleridir. Bu iki geleneksel makine öğrenmesi yönteminde özellik çıkarımı için TF-IDF kullanılmıştır. Çalışmada 2 durumdan bahsedilmiştir. İlk durum TF-IDF sonucu çıkarılan özellik miktarının sınırlandırılmaması, ikincisi ise TF-IDF sonucu ortaya çıkan vektörün özellik miktarının 20000 özelliğe sınırlandırılmasıdır. Derin öğrenme modeli 6 katmandan oluşmaktadır. İlk katman 100 boyutluk vektör üreten gömme katmanıdır. Bu katman rastgele ağırlıklar kullanılarak geliştirilen derin öğrenme modeli içindir. Sıradaki 2 katman ise evrişim katmanlarıdır. Aktivasyon fonksiyonu olarak relu kullanan bu katmanlarda filtre sayısı sırasıyla 256 ve 128, çekirdek boyutu (kernel size) ise 5 ve 3 olarak belirtilmiştir. Evrişim katmanlarından sonra ortalama havuzlama katmanı ve ardışık iki tam bağlı katman kullanılmıştır. Tam bağlı katmanların nöron sayısı sırasıyla 128 ve veri kümedeki sınıf sayısı kadardır, aktivasyon fonksiyonları ise relu ve softmax'tır. Evrişim katmanları ve 128 nöronlu tam bağlı katmanlarının uygulanmasından sonra yığın normalizasyonu gerçekleştirilmiştir. İlk evrişim katmanının uygulanması sonrası 0.25 seyreltme oranı ile seyreltme katmanı, ikinci evrişim katmanı ve 128 nöronlu tam bağlı katmanı uygulanmasından sonra ise 0.1 seyreltme oranı ile seyreltme katmanı uygulanmıştır. Eğitim için öğrenme oranı 0.001, yığın boyutu 256, çağ sayısı 4, optimizasyon algoritması olarak Adam seçilmiştir. BERT modelinin eğitimi 2 aşamada yapılmıştır. İlk aşamada eğitim için kullanılan veri kümesinin %25'i seçilmiştir. Giriş boyutu 256, optimizasyon algoritması olarak Adam, çağ sayısı 4, yığın boyutu 32, öğrenme oranı 0.00002 olarak belirlenip model eğitilmiştir. İkinci eğitim aşamasında veri kümesinin tamamı kullanılmıştır. Yığın boyutu 32,

öğrenme oranı 0.000001, çağ sayısı 1 olarak belirlenip BERT modeli eğitilmiştir. ALBERT modelinde BERT modeli eğitimi için bahsedilen yöntem kullanılmıştır. Öğrenme oranı ikili sınıflandırma için 0.000006, çoklu sınıflandırma için ise 0.000002 olarak belirlenmiştir.

İkili sınıflandırmanın en iyi sonucu %98.3 doğruluk skoru ile ALBERT, çoklu sınıflandırmanın en iyi sonucu %89.62 doğruluk skoru ile BERT modelidir [22].

Bahsedilen çalışmadaki yöntemler, bu projede uygulanıp başarı değerleri tablo 3’de gösterilmiştir.

Tablo 3: Yukarıda bahsedilen yöntemlerin test kümesi üzerindeki doğruluk skorları

Özellik Çıkarım Yöntemi	Model	Test Doğruluk Yüzdesi
TF-IDF	Lojistik Regresyon	%92.8
TF-IDF – 20000 Özellik	Lojistik Regresyon	%89.5
TF-IDF	Naive Bayes	%90.6
TF-IDF – 20000 Özellik	Naive Bayes	%91.1
Rastgele Ağırlıklar	CNN	%13.6
Glove – Ön eğitilmiş	CNN	%2.6
Glove – İnce Ayarlama	CNN	%14
Ön eğitilmiş Ağırlıklar	BERT	%47.99
Ön eğitilmiş Ağırlıklar	ALBERT	%15.6

Dönüştürücü (transformer) modelleri geçmişte sadece doğal dil işleme alanında uygulanırken, günümüzde ses işleme ve bilgisayarlı görü uygulamalarında etkili performanslar gösteren model olmuştur [23]. Dönüştürücü modellerinde kodlayıcı ve kod çözücü mimarisi bulunmaktadır. Kodlayıcı mimarisi, dizi verilerinin temsilini çıkarır. Kod çözücü, elde edilen temsiller ile dizi verileri üretir. Kodlayıcı mimarisi sınıflandırma amaçlı kullanılmaktadır. BERT, bu mimariyi kullanan dil modellerinden biridir. Kod çözücü mimarisi metin üretiminde kullanılmaktadır. GPT, bu mimariyi kullanan dil modellerinden biridir. Hem kodlayıcı hem de kod çözücü mimarisi çeviri amaçlı kullanılmaktadır ve BART modeli bu mimariye örnek gösterilebilir. Bu projede önerilen model olarak BERT modeli kullanılmıştır. BERT, Google araştırmacıları tarafından dönüştürücü mimarisinin kodlayıcı ağı kullanılarak oluşturulmuş bir dil modelidir. BERT tabanlı DistilBERT, Electra, Albert, RoBERTa gibi farklı türleri de bulunmaktadır [24]. Günümüzde Türkçe için BERT modelleri de geliştirilmektedir.

Önerilen modelde ön eğitilmiş ağırlıklar ile BERT modeli kullanılmıştır. Bert ön işleme için dizi uzunluğu 512 olarak seçilmiştir. Optimizasyon algoritması olarak Adam, öğrenme oranı ise 0.001 olarak kullanılmıştır. Eğitim için çağ sayısı 29, yığın boyutu 32 olarak belirlenmiştir. Eğitim verileriyle elde edilen sonuç 0.00047 kayıp değeri ve 1 doğruluk skorudur. Test sonuçları ise 0.1 kayıp değeri ve %98.5 doğruluk skorudur.

## REFERANSLAR

- [1] E. Cambria, B. Schuller, Y. Xia and C. Havasi, "New Avenues in Opinion Mining and Sentiment Analysis," in IEEE Intelligent Systems, vol. 28, no. 2, pp. 15-21, March-April 2013, doi: 10.1109/MIS.2013.30.Chelsea Finn. 2018. Learning to Learn with Gradients. PhD Thesis, EECS Department, University of Berkeley.
- [2] Sadi Evren SEKER, Duygu Analizi (Sentiment Analysis), YBS Ansiklopedi, v.3, is.3, pp 21-36, 2016
- [3] Onan, A. (2020). Evrişimli Sinir Ağı Mimarilerine Dayalı Türkçe Duygu Analizi . Avrupa Bilim ve Teknoloji Dergisi , Ejosat Special Issue 2020 (HORA) , 374-380 . DOI: 10.31590/ejosat. 780609
- [4] H. -C. Soong, N. B. A. Jalil, R. Kumar Ayyasamy and R. Akbar, "The Essential of Sentiment Analysis and Opinion Mining in Social Media : Introduction and Survey of the Recent Approaches and Techniques," 2019 IEEE 9th Symposium on Computer Applications & Industrial Electronics (ISCAIE), Malaysia, 2019, pp. 272-277, doi: 10.1109/ISCAIE.2019.8743799.Sam Anzaroot and Andrew McCallum. 2013. UMass Citation Field Extraction Dataset. Retrieved May 27, 2019 from <http://www.iesl.cs.umass.edu/data/data-umasscitationfield>



- [5] Özyurt, B. , Akcaçayol, M. A. "FİKİR MADENCİLİĞİ VE DUYGU ANALİZİ, YAKLAŞIMLAR, YÖNTEMLER ÜZERİNE BİR ARAŞTIRMA" . Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi 6 (2018 ) : 668-693 <<https://dergipark.org.tr/en/pub/sujest/issue/40421/481981>>
- [6] EKİM, H.E. & İNNER, A. B. (2021). DUYGU ANALİZİ VE FİKİR MADENCİLİĞİ YAKLAŞIMLARI VE UYGULAMALARI ÜZERİNE LİTERATÜR ARAŞTIRMASI. Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 24(2), 93-114.TUG 2017. Institutional members of the LaTeX Users Group. Retrieved May 27, 2017 from <http://wwwtug.org/instmem.html>
- [7] Shiliang Sun, Chen Luo, Junyu Chen, A review of natural language processing techniques for opinion mining systems, Information Fusion, Volume 36, 2017, Pages 10-25, ISSN 1566-2535, <https://doi.org/10.1016/j.inffus.2016.10.004>.
- [8] Zhengjie Miao, Yuliang Li, Xiaolan Wang, and Wang-Chiew Tan. 2020. Snippet: Semi-supervised Opinion Mining with Augmented&nbsp;Data. In Proceedings of The Web Conference 2020 (WWW '20). Association for Computing Machinery, New York, NY, USA, 617–628. <https://doi.org/10.1145/3366423.3380144>
- [9] Michelle Renee D. Ching and Remedios de Dios Bulos. 2019. Improving Restaurants' Business Performance Using Yelp Data Sets through Sentiment Analysis. In Proceedings of the 3rd International Conference on E-commerce, E-Business and E-Government (ICEEG '19). Association for Computing Machinery, New York, NY, USA, 62–67. <https://doi.org/10.1145/3340017.3340018>
- [10] Krishna, A., Akhilesh, V., Aich, A., Hegde, C. (2019). Sentiment Analysis of Restaurant Reviews Using Machine Learning Techniques. In: Sridhar, V., Padma, M., Rao, K. (eds) Emerging Research in Electronics, Computer Science and Technology. Lecture Notes in Electrical Engineering, vol 545. Springer , Singapore. [https://doi.org/10.1007/978-981-13-5802-9\\_60](https://doi.org/10.1007/978-981-13-5802-9_60)
- [11] N. Hossain, M. R. Bhuiyan, Z. N. Tumpa and S. A. Hossain, "Sentiment Analysis of Restaurant Reviews using Combined CNN-LSTM," 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT), Kharagpur, India, 2020, pp. 1-5, doi: 10.1109/ICCCNT49239.2020.9225328.
- [12] Rani, M.S., Subramanian, S. Attention Mechanism with Gated Recurrent Unit Using Convolutional Neural Network for Aspect Level Opinion Mining. Arab J Sci Eng 45, 6157–6169 (2020). <https://doi.org/10.1007/s13369-020-04497-4>
- [13] A. R. Abas, I. El-Henawy, H. Mohamed and A. Abdellatif, "Deep Learning Model for Fine-Grained Aspect-Based Opinion Mining," in IEEE Access, vol. 8, pp. 128845-128855, 2020, doi: 10.1109/ACCESS.2020.3008824.
- [14] Avinash Kumar, Aditya Srikanth Veerubhotla, Vishnu Teja Narapareddy, Vamshi Aruru, Lalita Bhanu Murthy Neti, Aruna Malapati, Aspect term extraction for opinion mining using a Hierarchical Self-Attention Network, Neurocomputing, Volume 465, 2021, Pages 195-204, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2021.08.133>.
- [15] W. A. Qader, M. M. Ameen and B. I. Ahmed, "An Overview of Bag of Words;Importance, Implementation, Applications, and Challenges," 2019 International Engineering Conference (IEC), Erbil, Iraq, 2019, pp. 200-204, doi: 10.1109/IEC47844.2019.8950616.
- [16] A. Suciati and I. Budi, "Aspect-based Opinion Mining for Code-Mixed Restaurant Reviews in Indonesia," 2019 International Conference on Asian Language Processing (IALP), Shanghai, China, 2019, pp. 59-64, doi: 10.1109/IALP48816.2019.9037689.
- [17] Sopuru, J. C., Alubo, A., Iloh, P. C., & Lottu, O. A. (2024). Comparative Analysis of Word2Vec and GloVe with LSTM for Sentiment Analysis: Accuracy and Loss Evaluation on Twitter Data. International Journal of Social Sciences and Scientific Studies, 3(6), 3458 - 3468. Retrieved from <https://www.ijssass.com/index.php/ijssass/article/view/255>
- [18] Yong Yu, Xiaosheng Si, Changhua Hu, Jianxun Zhang; A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. Neural Comput 2019; 31 (7): 1235–1270. doi: [https://doi.org/10.1162/neco\\_a\\_01199](https://doi.org/10.1162/neco_a_01199)
- [19] Zhaoyang Niu, Guoqiang Zhong, Hui Yu, A review on the attention mechanism of deep learning, Neurocomputing, Volume 452, 2021, Pages 48-62, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2021.03.091>.
- [20] M. Kowsher, A. Tahabilder, M. M. Hossain Sarker, M. Z. Islam Sanjid and N. J. Prottasha, "Lemmatization Algorithm Development for Bangla Natural Language Processing," 2020 Joint 9th International Conference on Informatics, Electronics & Vision (ICIEV) and 2020 4th International Conference on Imaging, Vision & Pattern Recognition (icIVPR), Kitakyushu, Japan, 2020, pp. 1-8, doi: 10.1109/ICIEVicIVPR48672.2020.9306652.
- [21] Sule Lamido University Journal of Science & Technology Vol. 4 No. 1&2 [July, 2022], pp. 27-33 <https://doi.org/10.56471/slujst.v4i.266>
- [22] Eman Saeed Alamoudi & Norah Saleh Alghamdi (2021) Sentiment classification and aspect-based sentiment analysis on yelp reviews using deep learning and word embeddings, Journal of Decision Systems, 30:2-3, 259-281, DOI: 10.1080/12460125.2020.1864106
- [23] ÇİFÇİ, O. S. (2023). Transformer (Dönüştürücü) Mimarisi Kullanarak Zaman Serilerinde Anomali Tespiti. Bozok Journal of Engineering and Architecture, 2(1), 1-7.
- [24] SEL, İ., & HANBAY, D. (2021). Ön Eğitimli Dil Modelleri Kullanarak Türkçe Tweetlerden Cinsiyet Tespiti. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 33(2), 675-684. <https://doi.org/10.35234/fumbd.929133>