



Ön Eğitimli Dil Modelleriyle Duygu Analizi

Ömer Yiğit YÜRÜTÜCÜ^{a1,*}, Şeniz DEMİR^{a2},

^a MEF Üniversitesi, Fen Bilimleri Enstitüsü, Bilişim Teknolojileri Yüksek Lisans Mezun Öğrenci, İstanbul, Türkiye

^b MEF Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, İstanbul, Türkiye

Istanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi (2023) 5 (1): 46:53

<https://doi.org/10.47769/izufbed.1312032>

ORCID ¹ 0000-0002-7745-0515, ² 0000-0003-4897-4616

YAYIN BİLGİSİ

Yayın geçmişi:

Gönderilen tarih: 09 Haziran 2023

Kabul tarihi: 08 Kasım 2023

Anahtar kelimeler:

Doğal dil işleme 1,

Duygu analizi,

BERT,

RoBERTa,

BERTweet.

ÖZET

Duygu analizi, çeşitli platformlarda bir konu hakkında düşünce, duygu ya da tutumu irdelemek, analiz etmek ve yorumlamak amacıyla kullanılan yöntemlerden biridir. Farklı konulardaki metinlerin öznel içeriklerine göre sınıflandırılabilirdiği duygu analizinde makine öğrenmesi ve derin öğrenme modellerinden sıklıkla faydalanılmaktadır.

Bu çalışmada, önceden eğitilmiş dil modellerinden yararlanılarak Covid-19 tweet metinleri üzerinde duygu analizi yapılmıştır. Naive Bayes sınıflandırıcıya ek olarak BERT, RoBERTa ve BERTweet dil modelleri kullanılarak farklı sınıflandırıcılar eğitilmiş ve tweet veri kümesi üzerinde elde edilen sonuçlar kıyaslanmıştır. Bildiride aktarılan çalışmanın ileride bu alanda yürütülecek araştırmalara bir zemin oluşturacağı öngörülmektedir.[†]

Sentiment Analysis with Pre-Trained Language Models

ARTICLE INFO

Article history:

Received: 09 June 2023

Accepted: 08 November 2023

Keywords:

Natural language processing,

Sentiment analysis,

BERT,

RoBERTa,

BERTweet.

ABSTRACT

Sentiment analysis is one of the methods used to examine, analyze and interpret thoughts, feelings or attitudes about a subject on various platforms. Machine learning and deep learning models are frequently used in sentiment analysis, where texts on different subjects can be classified according to their subjective content.

In this study, sentiment analysis was performed on COVID-19 tweet texts using pre-trained language models. In addition to the Naive Bayes classifier, different classifiers were trained using BERT, RoBERTa, and BERTweet language models and the results obtained on the tweet dataset were compared. It is envisaged that the study cited in the paper will form a basis for future research in this field.

1. Giriş

Küresel düzeyde iletişim kurabilme yeteneği sayesinde insanların sosyal ağları her geçen yıl daha da genişlemektedir. Özellikle sosyal medya, blog, haber siteleri, forum gibi platformlarda kullanıcı sayısının artması sosyal etkileşimi arttırmaktadır ve bireysel teknolojik cihazların gelişmesiyle birlikte insanlar daha çok paylaşım yapabilmektedir (Yıldırım, 2020). Sosyal platformların ortak noktası, kullanıcıların

duygu ve düşüncelerini rahatça ifade etme özgürlüğüne sahip olmasıdır. Bu sayede bir ürün markasına yönelik kaliteli yorumları, bir film hakkındaki görüşleri veya bir restoranla ilgili müşteri şikâyetlerini öğrenmek kolaylaşmıştır.

Günümüzde şirketler sosyal medyayı, müşteri sadakatini, satışlarını, gelirlerini, müşteri memnuniyetini, marka bilinirliğini ve müşteri trafiğini artırmak ve itibar kazanmak gibi amaçlarla kullanmaktadır (Culnan vd., 2010; Kietzmann

* Sorumlu yazar.

E-mail adresi: yigityurutucu@gmail.com (Ömer Yiğit Yürütücü)

[†] Bu çalışma "The Use of Pretrained Language Models in Sentiment Analysis" isimli yüksek lisans tezinden yararlanarak hazırlanmıştır.

vd., 2011; Sinderen & Almeida, 2011; Weber, 2009; He vd., 2013). Bu bağlamda, paylaşılan fotoğraflar, konum, duygu ve düşünceler gibi büyük hacimli veri kümeleri toplanmakta ve genellikle makine öğrenmesi ya da metin madenciliği teknikleri ile analiz edilmektedir. Metinlerden anlamlı bilgiler elde etmek için duygu analizi, metin sınıflandırma, birliktelik kuralı öğrenme veya kelime bulutları çıkarma gibi çalışmalar sıklıkla yürütülmektedir (Kapucugil & Özdağoğlu, 2015). Doğal Dil İşleme (NLP) yöntemleri de son yıllarda ön plana çıkmaya başlamıştır.

Doğal Dil İşleme alanındaki araştırma konularından birisi olan duygu analizinde hedef, belirli bir içeriğe sahip metinleri incelemek ve genel hatlarıyla olumlu, olumsuz veya tarafsız öğeleri tespit etmektir (Azzouza vd., 2020). Bu kapsamda metindeki öğeleri ve bu öğelerin birbirleriyle olan ilişkilerini tanımlayan bir model tahmini yapılmaktadır (Krizhevsky vd., 2012; Goodfellow vd., 2016). Duyguların analizi sırasında metinlerin söz dizimi ve söz varlığı gibi pek çok faktör dikkate alınmaktadır (Abid, vd. 2019). Duygu analizi üzerine yürütülen araştırmalar 1990'ların sonlarında başlamıştır ve günümüze kadar, sosyal medyadaki görüşlerin çıkartılması, pazar duyarlılığının belirlenmesi ve ürünler hakkındaki görüşlerin analiz edilmesi gibi çeşitli alanlarda başarıyla uygulanmıştır (Bakliwal vd. 2013; Zhang & Skiena 2010; Ghiassi, Skinner & Zimbra 2013).

Bu çalışmanın amacı, önceden eğitilmiş dil modelleri kullanarak duygu analizi yapmak ve farklı modellerin başarımını değerlendirmektir. BERT, RoBERTa ve BERTweet dil modelleri üç farklı duygu analizi aracının eğitiminde kullanılmıştır. Eğitimler için Twitter'da uzun süre gündemdeki yerini kaybetmeyen Covid-19 salgını ile ilgili tweet metinlerinden oluşan bir veri kümesinden faydalanılmıştır. Derin öğrenme tabanlı duygu analizi araçlarının performansları hem birbirleriyle hem de makine öğrenmesinde sıklıkla kullanılan Naive Bayes yöntemi ile eğitilmiş bir duygu analizi aracı ile kıyaslanmıştır. Elde ettiğimiz sonuçların ve bilgi birikiminin ileride bu alanda yürütülecek çalışmalara katkıda bulunacağı öngörülmektedir.

2. Literatür Taraması

Duygu analizi yapılırken sadece doğal dil işleme tekniklerinden değil aynı zamanda veri madenciliği ve web madenciliği gibi yaklaşımlardan da faydalanılmaktadır (Mundalık, 2018). Yürütülen çalışmalar hem hedef alınan analiz seviyesine hem de kullanılan yöntemlere göre farklılıklar göstermektedir. Analiz seviyesine göre duygu analizi çalışmaları iki başlık altında toplanmaktadır. Cümle düzeyindeki duygu analizinde, her bir cümle ayrı bir birim olarak ele alınmakta ve cümlenin yalnızca bir görüş içermesi gerektiği varsayılmaktadır (Jagtap & Pawar, 2013). Hedef tabanlı duygu analizinde ise, metinde geçen öğelerin analizi ayrı ayrı yapılmakta ve her öğeye farkı duygu ve görüşler atanabilmektedir (Patil vd., 2018).

Duygu tespiti aşamasında kullanılan yöntemler üç ana başlık altında toplanabilmektedir. Sözlük tabanlı yaklaşımlar, genel hatlarıyla kelimeler ve onlara atanmış duyguları içeren sözlüklerden faydalanmaktadır. Belirli bir alana ait sözlükler ve alan bağımsız dile ait genel sözlükler geçmiş çalışmalarda değerlendirilmiştir. 2004 yılında Hu & Liu, tarafından

oluşturulan duygu sözlüğü ile başlayan çalışmalar sonucunda geniş kapsamlı WordNet, SentiWordNet, MPQA Subjektiflik Sözlüğü, SenticNet ve SentiFul gibi sözlükler ortaya çıkartılmıştır. Makine öğrenmesi tabanlı yaklaşımlarda ise denetimli, yarı denetimli ve denetimsiz yöntemler temizlenmiş veriler (örneğin noktalama işaretlerinden arındırılmış ve kelimelere ayrılmış veriler) üstünde eğitilmiştir. Son yıllarda gittikçe önem kazanan derin öğrenme tabanlı yaklaşımlarda ise farklı mimarilere sahip sınıflandırıcılar eğitilmektedir. Bu sınıflandırıcılar geniş bir kullanıma sahip önceden eğitilmiş dil modelleri ile güçlendirilmektedir.

Literatürde duygu analizi alanında birçok çalışma bulunmaktadır. Bu kapsamdaki ilk çalışmalara örnek olarak Pang, Lee & Shivakumar (2002) verilebilir. Bu çalışmada, unigram, bigram, part-of-speech (POS) özellikleri değerlendirilmiş ve bu özelliklerin farklı kombinasyonları kullanılarak kontrollü makine öğrenmesi algoritmaları ile bir sınıflandırma yapılmıştır. Veri seti olarak IMDb'den film yorumlarını kullanılmış ve yorumlar olumlu ve olumsuz olarak işaretlenmiştir. Ayrıca duygu sınıflandırmasının geleneksel konu sınıflandırmasından çok daha zor olduğu da belirtilmiştir. Hu & Liu (2004), müşteri görüşleri ile değerlendirilen ürün özellikleri için bir sistem önermiştir. DDİ tekniklerini kullanarak cümleler olumlu ve olumsuz olarak sınıflandırılmış ve analizlerdeki cümle polaritesi sayesinde yüksek doğruluk elde edilmiştir. Blitzer, Dredze & Pereira (2007) duygu sınıflandırmasında alan uyarlaması için farklı bir sistem geliştirmiştir. Structural Correspondence Learning (SCL) algoritması ile dört farklı ürün kategorisinden oluşan bir veri seti oluşturmuş ve analiz edilmiştir. Ayrıca, az miktarda etiketlenmiş hedef etki alanı verisi kullanarak yapısal uyumsuzlukların nasıl düzeltileceği de gösterilmiştir. Çelikiyılmaz & Feng (2010) Twitter'da bir duygu analizi çalışması yürütmüştür. Bu çalışmada tweet metinleri polar ve polar olmayan formlara ayrılmıştır. Buna göre olumlu ve olumsuz tweet metinleri belirlenmiş ve ayrıca insanların duygularını anlamak için geniş bir kutupsal sözlüğe ihtiyaç olup olmadığı da tartışılmıştır. Becker, Erhart, Skiba & Matula (2013) 2012-2013 yıllarına ait 475 bin etiketsiz SMS ve tweet verisi üzerinde Polarity Bag-of-Word, Pos Tag yöntemleri ile SVM ile üretilen polarite sözlüğü yöntemlerini test etmiştir. İkili sınıflandırmalarda yüksek başarı elde edilirken, nötr kelimelerde sonuçlar daha düşük kalmıştır. Upadhyay & Singh (2016), Twitter üzerinden elektronik ürünler hakkında görüş bildiren bir araştırma gerçekleştirmiştir. Çalışmada, isim ve sembol gibi gereksiz kelimeleri ayırdıktan sonra her düşünceli, düşüncesiz tweet metni, pozitif, negatif ve nötr kelimelerden oluşan veri tabanı ile karşılaştırılmıştır. Yöntem olarak Naive Bayes, SVM ve maksimum entropi kullanılmıştır. Ghag & Shah'ın (2018) çalışmasında duygu analizi için Bag-of-Words yaklaşımı kullanılmıştır. Çalışma, incelemedeki cümlelerin sözdizimsel ve anlamsal yapısını dikkate alarak duyguların sınıflandırılmasına odaklanmıştır. Çalışmada uygulanan yöntemlerden biri olan Kavramsal Duygu Analizi Modeli'nin performansı diğer tekniklere göre en yüksek performansı göstermiştir. Yılmaz & Orman (2021), Twitter'da Covid-19 ile ilgili tweetlerin duygu analizini gerçekleştirmiştir. Çalışmada derin öğrenme yöntemlerinden biri olan LTSM sisteminden yararlanılmıştır. Bu çalışmada %97 başarı oranı elde edilmiştir.

Önceden eğitilmiş dil modellerinin kullanıldığı çalışmaların makine öğrenmesi yöntemleriyle kıyaslanır sonuçlar verdiği gözlemlenmiştir. Örneğin, Pak & Paroubek (2010), Twitter API'sini kullanarak tweet metinlerini otomatik olarak toplamış ve ardından duyguları açıklayan bir bütüncü geliştirmiştir. POS etiketleme adımı için Tree Tagger kullanılmıştır ve Multinomial Naive Bayes sınıflandırıcısı ile bir duygu analizi yapılmıştır. Sel & Hanbay (2021), BERT, DistilBERT ve Electra gibi önceden eğitilmiş dil modelleri kullanarak Türkçe tweet metinleri üzerinden cinsiyet tespiti gerçekleştirmiştir. Yürütülen deneyler sonucunda en yüksek başarımın BERT modeli ile elde edildiği bildirilmiştir. Masarifoğlu vd. (2021), bankacılık hizmetlerini kullanan müşterilerden toplanan yorumları BERT tabanlı duyarlılık sınıflandırma modelleri ile incelemiş ve bankacılık alanında kullanılan geleneksel yöntemlerle karşılaştırılmıştır. Çalışmada BERT ve XLM-ROBERTA kullanılmıştır. BERTurk tabanlı modelin geleneksel modellerden daha iyi performans gösterdiğini ve performansının eğitim veri boyutundaki azalmadan daha az etkilendiğini gösterilmiştir.

3. Yöntem ve Bulgular

Sosyal medyanın en temel özellikleri iletişim, işbirliği ve içerik paylaşımıdır (Anttiroiko & Savolainen, 2011). Kişiler kendi görüntülerini oluşturarak hızlı bir iletişim imkânı sağlayan çevrimiçi platformlarda duygu ve düşüncelerini aktarmaktadır. Üyelerin geri bildirimleri bu platformlarda hareketlilik sağlamaktadır, çünkü oy vermek, yorum yapmak, bilgi paylaşmak kolaydır ve çift yönlü iletişim de kurulabilmektedir. Bu nedenle sosyal medyada aktif olan kişiler bir grubun üyesi gibi davranmaktadır. Ayrıca aktif olan bireylerde sadakat duygusu da gelişmiştir (Mayfield, 2008).

Sosyal medya kullanımının artmasıyla birlikte sosyalleşme ve iletişim kavramları değişmeye başlamıştır. Geçmişten günümüze sosyalleşme ve iletişimin en etkili olduğu alan medya ile karşı karşıya kalınan ortamlar olmuştur. Ancak son yıllarda iletişim kurmak ya da duygu ve düşünceleri paylaşmak için sanal medya ya da dijital platformlarında etkili olduğu anlaşılmıştır.

Sosyal medyada birçok platform bulunmaktadır. Bunlardan en çok kullanıcıya sahip olanlardan biri de Twitter'dır. Twitter, 2006 yılında Jack Dorsey tarafından kurulmuş bir sosyal ağ ve mikroblog sitesidir. Tweet adı verilen mesajlar 140 karakterden oluşmaktadır. Aynı zamanda tweet'ler # (hashtag) işareti ile etiketlenebilmektedir. Kullanıcılar duygu ve düşüncelerini kelime, sembol ve hashtag'ler aracılığıyla ifade etmektedir. Ancak kullanıcıların temel şikâyeti tweetlerde karakter sınırlamasıdır çünkü bu kural duygu ve düşüncelere kısıtlayabilmektedir. Buna rağmen Twitter en çok kullanılan platformlardan biri olmayı başarmıştır.

Twitter'ın bir özelliği de gündem konu başlıklarının oluşmasıdır. Bu başlıkların bir kısmı kısa süreli olsa da bazıları oldukça geniş bir zaman aralığında güncelliğini devam ettirmektedir. Son iki yıldır gündem olan konulardan biri Covid-19 virüsüdür. Bu nedenle bu çalışmada da Covid-19 tweetlerinden oluşan veri kümesinden faydalanılmıştır. Duygu analizi yapmak için ön eğitilmiş dil modelleri kullanılmıştır. Ön eğitilmiş dil modellerinden BERT,

BERTweet ve RoBERTa temel modeli, ön eğitim ve ince ayar sürecine dayanan büyük ölçekli transformatör modellerindedir. BERT, çift yönlü ve Maskeleyen Dil Modelleme (MLM) ile Sonraki Cümle Tahmini (NSP) teknikleriyle eğitilmektedir (Uçar, 2020). RoBERTa, orijinal BERT trafo modeline göre geliştirilmiş bir dil modelidir. BERTweet, daha fazla iyileştirme ve yeni uygulamalar için diğer araştırmacılara sunulan ilk modeldir (Baker, 2021). Bu sistemin görevi, kelimeleri, o metinde yer alan en baskın duygu veya kutupluluğa göre sınıflandırılacak şekilde analiz edilmesidir.

Duygu analizi ise, Doğal Dil İşleme'nin (NLP) bir alt alanıdır. Duyarlılık analizi, sosyal medyadaki görüşlerin çıkarılması ve belirlenmesi, pazar duyarlılığının analiz edilmesi ve ürünler hakkındaki görüşlerin analiz edilmesi gibi çeşitli alanlarda uygulanabilmektedir. Bu çalışmanın duygu analizinde uygulanacak adımlar şu şekildedir:

- Veri setinin elde edilmesi
- Metnin ön işleme tabi tutulması ve analize uygun hale getirilmesi,
- Analiz için kullanılacak niteliklerin seçilmesi
- Sınıflandırma
- Sözlüklere göre kelimelerin duygu puanının belirlenmesi,
- Her duygu kategorisine göre toplam duygu puanının hesaplanması,
- En yüksek duyarlılık puanına sahip kategoriye göre sınıflandırılması.

Sosyal medya araştırmalar için önemli bir kaynaktır. Bu yüzden Twitter üzerinde bir duygu analizi çalışması yapılmıştır. Araştırma konusu olarak Covid-19 tweetlerinden bir veri seti hazırlanmıştır. NLP'de analiz yapmak için birçok farklı yöntem kullanılmaktadır. Bu çalışmada önceden eğitilmiş modeller kullanılmıştır. Seçili modellerin performansları karşılaştırılmıştır. Önceden eğitilmiş alternatif modellerden BERT-base-uncased, RoBERTa ve BERTweet'i ile uygulama yapıldıktan sonra sonuçlar ve modeller arasındaki benzerlik ve farklılıklar yorumlanmıştır.

3.1 Veri kümesi

Bu çalışmada veri kümesi Twitter'da Covid-19 ile ilgili tweetlerden elde edilmiştir. Veri kümesine ulaşmak için Kaggle (<https://www.kaggle.com/datattle/covid-19-nlp-text-classification>) üzerinden paylaşılan Covid-19 Duygu Analizi Verilerinden yararlanılmıştır. Veriler, 03.02.2020 ile 04.14.2020 tarihleri arasında ortalama 1,5 ay boyunca "Covid-19" konulu tweetlerden oluşmuştur.

İlk olarak tüm modellerin genel performansını iyileştirmek için veri kümesinde düzenleme yapılmıştır. Twitter mesajlarında hashtag, link, kısaltma ve sembol gibi birçok anlamsız karakter bulunmaktadır. Eğitim setinin doğru sınıflandırma işlemini tamamlaması için bu karakterler veri setinden çıkarılmıştır. Ayrıca retweetler ve tekrar eden tweetler ile cümlelerin sonundaki noktalama işaretleri de silinmiştir. Ek olarak İngilizce olmayan karakterler temizlenmiş ve tüm küçük ve büyük harfler küçük harf olarak düzeltilmiştir. Beş kelimedenden az olan tweetler temizlenerek anlamlı tweetlerin veri kümesinde yer alması sağlanmıştır.

Tüm modellerde, önceden eğitilmiş BERT dil modellerini uygulayabilmek için tokenizer kullanılmış ve BERT için ince ayar yapılmıştır.

Eğitim kümesinde 41.157 adet veri içeren bir veri seti oluşturulmuştur. Derlenen verilerin %60'ı bir eğitim veri kümesine bölünmüştür. Verilerin %20'si bir test veri kümesi ve diğer %20'si bir doğrulama veri kümesini oluşturmuştur. Veri ön işlemeden sonra 40.923 tweet elde edilmiş ve derlenen verilerde 11381 olumlu, 9889 olumsuz ve 7560 tarafsız yorum tespit edilmiştir.

Tablo 1. Duygu Sütunu

| | |
|---------------|-------|
| Pozitif | 11381 |
| Negatif | 9889 |
| Nötr | 7560 |
| Aşırı Pozitif | 6618 |
| Aşırı Negatif | 5475 |

3.2 Modeller

Son yıllarda ELMo, ULMFIT, OpenAI dönüşümü gibi birçok ön eğitilmiş dil modeli geliştirilmiştir. BERT bu modellerin en yenisidir. BERT (Bidirectional Encoder Representations from Transformers) Google AI Language araştırmacıları tarafından geliştirilmiştir. En önemli özelliği başta SQuAD v1.1 (soru cevaplama) ve MNLI (Doğal Dil Çıkarılma) olmak üzere NLP görevlerine yeni bir yaklaşım getirmesidir (Horev, 2018).

Sözlüğün ana görevi, açıklaması verilen hedef kelimeyi bulmaktır. BERT ön eğitilmiş dil modeli kullanılmıştır (Devlin vd., 2016). Doğal Dil İşleme (NLP) de Çift Yönlü Kodlayıcı Temsilleri Dönüştürücüler (BERT) gibi bir model kullanarak metin dizilerindeki bilgileri kodlar. Bu şekilde metin tanıma ve sınıflandırma için sonuç elde edilir (Pota, vd., 2021; Cesconi, 2020).

BERT çift yönlü olmasının yanı sıra Maskeli Dil Modelleme (MLM) ve Sonraki Cümle Tahmini (NSP) adı verilen iki teknik ile eğitilmektedir (Uçar, 2020). Maskeli dil modelinde cümlelerdeki kelimelerin %15'i rastgele maskelenir ve bu kelimelerin çift yönlü bir şekilde doğru tahmin edilmesi sağlanır. Bir sonraki cümle tahmini ise kendisinden önceki cümleyi takip edip etmediğidir (Çelikten & Bulut, 2021). BERT, byte-pair-encoding (BPE) alt kelime kodlamasına dayanmaktadır. Cümleyi alt kelimelere böldüğü için kelimeler arasındaki veri seyrekliği de azaltılabilir.

RoBERTa Modeli, maskelenmiş dil modellemesi (MLM) kullanan ön eğitilmiş bir modeldir. Bu model küçük ve büyük harflere duyarlıdır. Dolayısıyla RoBERTa, İngilizce veriler üzerinde kendi kendine denetlenen ve ön eğitilmiş bir dönüştürücü modeldir. Bir cümle için iki yönlü temsili öğrenmeye olanak tanır (Singh, 2021).

BERTweet Modeli, İngilizce tweetler için önceden eğitilmiş ilk genel büyük ölçekli dil modelidir. BERTweet, BERT-base ile aynı model yapılandırmasına sahip RoBERTa ön eğitim prosedürü kullanılarak eğitilmiştir (Liu, vd., 2019). Yapılan deneylerde BERTweet'in iyi performans gösterdiği anlaşılmıştır (Conneau, vd., 2020). BERT taban modeli ile

aynı yapıda olan maskelenmiş dili modelleme amacı ile eğitilmiştir. BERTweet, BioBERT'in Bio NLP alanı ve SciBERT'in Bilimsel NLP alanı gibi birçok Tweets NLP görevinde en gelişmiş performansı elde etmiştir (Nguyen, 2020).

3.2.1 Naive Bayes

Veri kümeleri duyarlılık analizi için test edilmiş ve sınıflandırma doğruluğu için Bayes yöntemi kullanılmıştır. Bir tweet'in hassasiyetini tahmin etmek için, tweet'teki kelimelerin log öncesi ile birlikte mantıklı olma olasılığının özetlemesi yeterli olmaktadır (Mashalkar, 2020). Bu çalışmada da önce Naive Bayes ile bir sınıflandırma yapılmıştır. Önceden eğitilmiş BERT modellerini kullanmadan önce, temel modellerin Naive Bayes Sınıflandırıcı modeli de duygu sınıflandırması yapmak için eğitilmiştir. Naive Bayes skorları yeterli sonuçları vermiştir (Tablo 2).

Tablo 2. Naive Bayes Skor Sınıflandırma

| | Kesinlik (Precision) | Duyarlılık (Recall) | F1 skoru (F1-score) | Support |
|---------------------|----------------------|---------------------|---------------------|---------|
| Negatif | 0.75 | 0.78 | 0.74 | 1629 |
| Nötr | 0.57 | 0.43 | 0.49 | 614 |
| Pozitif | 0.73 | 0.73 | 0.73 | 1544 |
| Doğruluk (Accuracy) | | | 0.70 | 3787 |
| Makro ortalama | 0.67 | 0.64 | 0.65 | 3787 |
| Ağırlıklı ortalama | 0.70 | 0.70 | 0.70 | 3787 |

Tablo 2'de görüldüğü gibi algoritma performansı yeterli düzeydedir. F1 puanı, daha kalabalık sınıflar için (Olumsuz ve Olumlu duygular) %70 civarında ve nötr sınıf için biraz daha düşük (F1=0.49) çıkmıştır. Genel doğruluk oranı %70, kesinlik değeri ise %70 çıkmıştır. Mevcut değerler 1 değerine ne kadar yakın ise o derecede model tahmininde kesinliğin daha fazla olduğu anlaşılmaktadır.

3.2.2 BERT Model

Önceden eğitilmiş BERT modeli, modeller kitaplığından (Huggingface) içe aktarılmıştır. BERT transformatorüne ince ayar yapabilmek için, önceden eğitilmiş BERT modeline uyum sağlamak için özel işlev uygulanmıştır. Veri kümesinin 3 farklı sınıfının (3 duygu) sınıflandırılmasını gerçekleştirmek için gerekli olan 3 nöronlu bir çıktı katmanı eklenmiştir. Buna göre, BERT için tasarlanan modelin başarı değerleri hesaplanmıştır (Tablo 3).

Tablo 3. BERT İçin Sınıflandırma Skoru

| | Kesinlik (Precision) | Duyarlılık (Recall) | F1 skoru (F1-score) | Örnek Sayısı |
|----------------------------|----------------------|---------------------|---------------------|--------------|
| Negatif | 0.91 | 0.87 | 0.89 | 1629 |
| Nötr | 0.77 | 0.83 | 0.80 | 614 |
| Pozitif | 0.90 | 0.91 | 0.91 | 1544 |
| Mikro ortalama (Micro avg) | 0.88 | 0.88 | 0.88 | 3787 |
| Makro ortalama (Macro avg) | 0.86 | 0.87 | 0.87 | 3787 |
| Ağırlıklı ortalama | 0.88 | 0.88 | 0.88 | 3787 |
| Örnekleme ortalama | 0.88 | 0.88 | 0.88 | 3787 |

Eğitim sonucunda toplam F1 skoru %91 (pozitif), %89 (negatif) ve %80 (nötr) olarak tespit edilmiştir. En yüksek F1

puanı sınıfı pozitif duygu sınıfı iken, nötr duygu sınıfındaki başarı oranı diğer sınıflara göre daha düşük çıkmıştır.

Veri eğitimi 4 bölüme ayrılarak gerçekleştirilmiştir. Model eğitilirken, tüm veriler aynı anda eğitime katılmadığından eğitime belirli sayıda katılmaktadır. İlk kısım eğitilmiş, modelin başarısı test edilmiş ve başarıya göre geri yayılım ile ağırlıklar güncellenmiştir. Ardından yeni eğitim seti ile model yeniden eğitilmiş ve ağırlıklar tekrar güncellenmiştir. Bu işlem, model için en uygun ağırlık değerlerini hesaplamaya çalışmak için her eğitim adımında tekrarlanmıştır. Bu eğitim adımlarının her birine bir çağ denilmektedir. İlk dönemlerde başarı düşük olmuş ve dönem sayısı arttıkça başarı artmıştır. Epoch (eğitim tur sayısı) değerleri, öğrenme algoritmasının tüm eğitim veri kümesi boyunca kaç kez çalışacağını tanımlayan bir hiper parametredir. Belirli bir adımdan sonra modelin öğrenme durumu önemli ölçüde azalacağı için tur sayısına dikkat edilmiştir, çünkü Tur Sayısının artırılması daha iyi verim sağlamayabilir ve tam tersine eğitim verisini ezberlemeye başlamasına neden olabilmektedir. Dolayısıyla yeni bir veride (eğitim verisinde olmayan) sonuçlar istenilen performansta olmamasına yol açacaktır. Bununla birlikte Tur Sayısının az olması da istenilen performansa ulaştırmayabilir. Değerlerdeki değişiklik, her bir antrenman turu (dönem) için meydana gelen kayıpların, turlar sırasında değiştiğini göstermektedir (Tablo 4). Tur sayısı 4 olduğunda en başarılı sonuçlar elde edilmiştir. Eğitimin doğruluğu %93,28 olarak bulunmuştur.

Tablo 4. BERT Eğitim Modelinde Elde Edilen Kayıp Ve Doğruluk Oranları

| | Eğitim kayıp | Doğruluk kayıp | Doğruluk (Valid. Accur.) |
|--------------------|--------------|----------------|--------------------------|
| Tur sayısı (Epoch) | | | |
| 1 | 0.5616 | 0.3480 | 0.8730 |
| 2 | 0.2865 | 0.2658 | 0.9057 |
| 3 | 0.1907 | 0.2335 | 0.9222 |
| 4 | 0.1312 | 0.2125 | 0.9328 |

Modellere ait tahminsel sonuçların değerlendirilmesi için metrik fonksiyonlarından faydalanılmıştır. Metrik fonksiyonlarının temelini karar matrisi (confusion matrix) oluşturmaktadır. BERT modelinin tahmin edilmesiyle bir karar matrisi elde edilmiştir (Şekil1).

| | | BERT Duygu Analizi Karar Matrisi | | |
|---------|--|----------------------------------|------|---------|
| Test | | Tahmin | | |
| | | Negatif | Nötr | Pozitif |
| Negatif | | 1419 | 96 | 114 |
| Nötr | | 57 | 511 | 46 |
| Pozitif | | 80 | 55 | 1409 |

Şekil 1. BERT Karar Matrisi

RoBERTa Modeli, Maskeli Dil Modellemeyi (MLM) kullanan önceden eğitilmiş bir modeldir. Bu model küçük ve büyük harflere karşı duyarlıdır. Dolayısıyla RoBERTa, İngilizce veriler üzerinde kendi kendini denetleyen ve önceden eğitilmiş bir transformatör modelidir. Bir cümlenin iki yönlü temsili öğrenmeyi sağlamaktadır (Singh, 2021).RoBERTa, BERT'de kullanılanlarla birlikte 160 GB metin kullanmaktadır. Ek verilerle kullanım alanı genişlemektedir. Bu çalışmadaki veri kümesine göre RoBERTa için tasarlanan modelin başarı değerleri (Tablo5) hesaplanmıştır.

Tablo 5. RoBERTa Sınıflandırma skoru

| | Kesinlik (Precision) | Duyarlılık (Recall) | F1 skoru (F1-score) | Örnek Sayısı |
|----------------------------|----------------------|---------------------|---------------------|--------------|
| Negatif | 0.87 | 0.93 | 0.90 | 1629 |
| Nötr | 0.80 | 0.80 | 0.80 | 614 |
| Pozitif | 0.93 | 0.87 | 0.90 | 1544 |
| Mikro ortalama (Micro avg) | 0.88 | 0.88 | 0.88 | 3787 |
| Makro ortalama (Macro avg) | 0.87 | 0.86 | 0.86 | 3787 |
| Ağırlıklı ortalama | 0.88 | 0.88 | 0.88 | 3787 |
| Örneklem ortalama | 0.88 | 0.88 | 0.88 | 3787 |

Eğitim sonucunda toplam F1 puanı %90 (pozitif), %90 (negatif) ve %80 (nötr) olarak hesaplanmıştır. En yüksek F1 puanı sınıfı pozitif duygu sınıfı iken, nötr duygu sınıfındaki başarı oranı diğer sınıflara göre daha düşük değer elde edilmiştir. RoBERTa için tasarlanan modelin Tur Sayılarına ilişkin değişkenler Tablo 6'de gösterilmiştir. Tur sayısı 4 olduğunda en başarılı sonuçlar elde edilmiştir. Eğitimin doğruluğu %92,63 olarak bulunmuştur.

Tablo 6. RoBERTa Eğitim Modelinde elde edilen kayıp ve doğruluk oranları

| | Eğitim kayıp | Doğruluk kayıp | Doğruluk (Valid. Accur.) |
|--------------------|--------------|----------------|--------------------------|
| Tur Sayısı (Epoch) | | | |
| 1 | 0.5734 | 0.3818 | 0.8624 |
| 2 | 0.3403 | 0.3117 | 0.8985 |
| 3 | 0.2549 | 0.2565 | 0.9130 |
| 4 | 0.1902 | 0.2372 | 0.9263 |

Ardından, BERT modelinde olduğu gibi RoBERTa için tasarlanan modelin tahmin edilmesiyle oluşturulan karar matrisi elde edilmiştir (Şekil2).

RoBERTa Duygu Analizi
Karar Matrisi

| | | | | |
|-------------|---------|---------------|------|---------|
| Test | Negatif | 1510 | 57 | 62 |
| | Nötr | 81 | 490 | 43 |
| | Pozitif | 136 | 68 | 1340 |
| | | Negatif | Nötr | Pozitif |
| | | Tahmin | | |

Şekil 2. RoBERTa Karar Matrisi

3.2.4. BERTweet Model

BERTweet Modeli, İngilizce tweet'ler için önceden eğitilmiş ilk halka açık büyük ölçekli dil modelidir. BERTweet, BERT-base ile aynı model konfigürasyonuna sahip RoBERTa ön eğitim prosedürü kullanılarak eğitilmektedir (Liu vd., 2019). Deneylerde BERTweet'in iyi bir performans sergilediğini göstermektedir (Conneau vd., 2020). BERTweet, BERT temel modeli ile aynı yapıda olan maskeli dili modellemek amacı ile eğitilmiştir. Bu çalışmada tasarlanan BERTweet modelinin sınıflandırma skorları Tablo 7'de gösterilmiştir.

Tablo 7. BERTweet sınıflandırma skoru

| | Kesinlik (Precision) | Duyarlılık (Recall) | F1 skoru (F1-score) | Örnek Sayısı |
|----------------------------|----------------------|---------------------|---------------------|--------------|
| Negatif | 0.92 | 0.90 | 0.91 | 1629 |
| Nötr | 0.75 | 0.84 | 0.79 | 614 |
| Pozitif | 0.93 | 0.90 | 0.91 | 1544 |
| Mikro ortalama (Micro avg) | 0.89 | 0.89 | 0.89 | 3787 |
| Makro ortalama (Macro avg) | 0.87 | 0.88 | 0.89 | 3787 |
| Ağırlıklı ortalama | 0.89 | 0.89 | 0.89 | 3787 |
| Örneklem ortalama | 0.89 | 0.89 | 0.89 | 3787 |

Eğitim sonucunda toplam F1 puanı %91 (pozitif), %91 (negatif) ve %79 (nötr) şeklindedir. En yüksek F1 puanı sınıfı pozitif duygu sınıfı iken, nötr duygu sınıfındaki başarı oranı diğer sınıflara göre daha düşük olduğu tespit edilmiştir. Eğitimin doğruluğu %93,43 olarak bulunmuştur (Tablo 8).

Tablo 8. BERTweet Eğitim Modelinde elde edilen kayıp ve doğruluk oranları

| | Eğitim kayıp (Training loss) | Doğruluk kayıp (Valid loss) | Doğruluk (Valid. Accur.) |
|--------------------|------------------------------|-----------------------------|--------------------------|
| Tur sayısı (Epoch) | | | |
| 1 | 0.5357 | 0.3532 | 0.8739 |
| 2 | 0.2931 | 0.2564 | 0.9096 |
| 3 | 0.2123 | 0.2305 | 0.9215 |
| 4 | 0.1657 | 0.2086 | 0.9343 |

Diğer modellerde olduğu gibi BERTweet için tasarlanan modelin tahmin edilmesiyle bir karar matrisi elde edilmiştir (Şekil 3).

BerTweet Duygu Analizi
Karar Matrisi

| | | | | |
|-------------|---------|---------------|------|---------|
| Test | Negatif | 1474 | 89 | 66 |
| | Nötr | 57 | 515 | 42 |
| | Pozitif | 79 | 80 | 1385 |
| | | Negatif | Nötr | Pozitif |
| | | Tahmin | | |

Şekil 3. BERTweet Karar Matrisi

4. Tartışma ve Sonuç

Bu çalışmada, önceden eğitilmiş üç dil model ile Covid-19 salgını tweetlerinden oluşan veri kümesinde duygu analizi yapılmıştır. Deneylerde Twitter'da Covid-19 ile ilgili atılan tweetlerin üç farklı dil modeline göre sonuçları değerlendirilmiştir.

Her üç algoritmanın da sınıflandırma başarısı birbirine yakın çıkmıştır. Her üç algoritmanın da %90 civarında performans puanları ile sınıflandırma görevinde iyi performans gösterdiği tespit edilmiştir. Ayrıca sınıflandırma başarı oranları da yeterlidir. BERT modellerinin yüksek doğruluk oranları olmasının nedeni saf Bayes ve Lojistik Regresyonda bağlamın anlamsal ve yapısal bilgilerini ihmal edilmekte, karakteristik kelimeler ve kategoriler arasındaki nedenselliğe odaklanılmaktadır. Önceden eğitilmiş BERT modelleri ise metnin anlamsal ve bağlamsal bilgilerini hesaba katmaktadır. BERTweet modelinin en yüksek F1 puanını (%91) ve Hassasiyeti (%90) olduğu tespit edilmiştir, ancak diğerler iki model de benzer başarıyı yakalamıştır. Tweetlerdeki yorumların içinde nötr yorumlar en düşük duygu yoğunluğuna sahip olduğu anlaşılmıştır. Modellerin başarı oranlarında daha yüksek doğruluk değerleri elde etmek için mevcut veri seti yeterlidir, ancak daha fazla veriden oluşan bir başka analizle yenilebilir.

Çalışmadaki yöntem ve deneylerin farklı veri setlerinde uygulanması mümkün olmamıştır. İleride yapılacak çalışmalarda farklı önceden eğitilmiş dil modelleri ile farklı veri setleri üzerinde yeni çalışmalar yapılabilir. Gelecek çalışmalarda ülke ve bölge bazında yeni tweet analizleri ile Covid-19 virüsünün pozitif vaka ve ölüm oranları arasındaki ilişkinin belirlenmesi için yeni deneyler yapılabilir. Önceden eğitilmiş dil modelleri ile yapılan analizler, klasik makine öğrenmesi modellerinden daha başarılı olabilir. Elde edilen sonuçlar hem sözlüklerin geliştirilmesine hem de ileride yapılacak çalışmalarda araştırmacıların analizlerinin

değerlendirilmesine katkı sağlayıcıdır. Bu araçlar kullanılarak istenilen esneklikte yeni algoritmalar ve sözlükler geliştirilebilir. Bu çalışmanın sonuçları diğer çalışmalara referans niteliğindedir. Ayrıca, bu çalışmada önerilen diğer mevcut veri setleri ve yöntemler ile Duygu Etiketleri ve Kelime Torbası gibi yöntemler ile çalışmaların yapılmasının sonuçları iyileştireceği beklenmektedir.

Kaynaklar

- Abid, F., Alam, M. Yasir, M. & Li, C. (2019). Sentiment analysis through recurrent variants latterly on convolutional neural network of Twitter, *Future Generation Computer Systems*. 95, 292-308. Doi: <https://doi.org/10.1016/j.future.2018.12.018>
- Anttiroiko, A. V. & Savolainen, R. (2011). Towards Library 2.0: The Adoption of Web 2.0 Technologies in Public libraries. *Libri*, 61(2), 87-99.
- Azzouza, N.; Akli-Astouati, K. & İbrahim, R. (2020). TwitterBERT: Framework for Twitter Sentiment Analysis Based on Pre-Trained Language Model Representations. F. Saeed et al. (Eds.): *IRICT 2019, AISC 1073*, 428-437. https://doi.org/10.1007/978-3-030-33582-3_41
- Baker, W. (2021). Using Large Pre-Trained Language Models to Track Emotions of Cancer Patients on Twitter. *Computer Science and Compute Engineering Undergraduate Honors Theses Retrieved from <https://scholarworks.uark.edu/csceuh/92>*
- Bakliwal, A., Foster, J., van der Puil, J., O'Brien, R., Tounsi, L., Hughes, M. (2013). Sentiment analysis of political tweets: Towards an accurate classifier. *Association for Computational Linguistics*. 49-58.
- Becker, L., Erhart, G., Skiba, D. & Matula, V. (2013). AVAYA: Sentiment Analysis on Twitter with Self-Training and Polarity Lexicon Expansion. *Second Joint Conference on Lexical and Computational Semantics (*SEM)*.
- Blitzer, J., Dredze, M. & Pereira, F. (2007). Biographies, Bollywood, Boom-Boxes and Blenders. *Domain Adaptation for Sentiment Classification, Proceedings of the 45th Annual Meeting of the Association for Computational Linguistics*, 440-447.
- Cesconi F. (2020). Natural language processing: Explaining BERT to business people. <https://hackernoon.com/natural-language-processing-explaining-bert-to-business-people-obz3uno> (accessed: 18.12.2022).
- Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzmán, F., Grave, E., Ott, M., Luke Zettlemoyer, L., & Stoyanov, V. (2020). Unsupervised Cross-lingual Representation Learning at Scale. In *Proceedings of ACL*, page to appear.
- Culnan, M., McHugh, P. & Zubillaga, J. (2010). How large U.S. Companies Can Use Twitter and Other Social Media to Gain Business Value *MIS Quarterly Executive*, 9 (4), 243-259.
- Çelikyılmaz A., Hakkani-Tür, D. & Feng, F. (2010). Probabilistic Model-Based Sentiment Analysis of Twitter Messages, in *2010 IEEE Workshop on Spoken Language Technology, SLT 2010 – Proceedings*.
- Çelikten, A. & Bulut, H. (2021). Turkish Medical Text Classification Using BERT. *29th Signal Processing and Communications Applications conference at İstanbul*. <https://doi.org/10.1109/SIU53274.2021.9477847>
- Devlin, J., Chang, M., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *Proceedings of the 2019 conference of the north American chapter of the association for computational linguistics: human language technologies*. 1. Minneapolis, Minnesota, 4171-4186. <https://www.aclweb.org/anthology/N19-1423>
- Ghag, K. V., & Shah, K. (2018). Conceptual sentiment analysis model. *International Journal of Electrical and Computer Engineering (IJECE)*, 8(4), 2358-2366. <https://doi.org/10.11591/ijece.v8i4.pp2358-2366>
- Ghiassi, M., Skinner, J. & Zimbra, D. (2013). Twitter Brand Sentiment Analysis: A Hybrid System Using N-Gram Analysis and Dynamic Artificial Neural Network. *Expert Systems with Applications*, 40(16), 6266-6282. <https://doi.org/10.1016/j.eswa.2013.05.057>
- Goodfellow, I., Bengio, Y., Courville, A.; & Bengio, Y. (2016). *Deep learning*, 1. MIT press Cambridge.
- He, W., Zha, S. & Li, L. (2013). Social media competitive analysis and text mining: A case study in the pizza industry. *International Journal of Information Management*, 33(3), 464-472.
- Horev, R. (2018). BERT Explained: State of the art language model for NLP. Retrieved from <https://towardsdatascience.com/bert-explained-state-of-the-art-language-model-for-nlp-f8b21a9b6270> (accessed: 18.12.2022).
- Hu, M. & Liu, B. (2004). Mining and Summarizing Customer Reviews. *Proceedings of the Tenth. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 168-177.
- Jagtap, V. S. & Pawar, K. (2013). Sentence-Level Analysis of Sentiment Classification. *National Conference on Emerging Trends in Engineering, Technology & Architecture*.
- Kapucugil, A. & Özdağoğlu, G. (2015). Text mining as a supporting process for VoC clarification. *Alphanumeric Journal*, 3(1), 25-40.
- Kietzmann, J.H., Hermkens, K., I.P. & McCarthy, B.S. (2011). *Silvestre Social Media? Get Serious! Understanding The Functional Building Blocks of Social Media*. *Business Horizons*, 54 (3), pp. 241-251.
- Krizhevsky, A., Sutskever, I. & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *NIPS Advances in Neural Information Processing Systems Conference*. 1-9.
- Liu, Y.; Ott, M.; Goyal, N. Du, J.; Joshi, M.; Chen, D.; Levy, O.; Lewis, M.; Zettlemoyer, L., & Stoyanov, V. (2019). RoBERTa: A Robustly optimized BERT pretraining approach. *Computer Science Computation and Language*, arXiv:1907.11692
- Masarifoğlu, M., Tigrak, U., Hakyemez, S.; Gül, G.; Bozan,

- E.; Buyuklu, A. H. & Özgür, A. (2021). Sentiment Analysis of Customer Comments in Banking using BERT-based Approaches. *Signal Processing and Communication Applications Conference (SIU)*. <https://doi.org/10.1109/SIU53274.2021.9477890>
- Mashalkar, A. (2020). Sentiment Analysis using Logistic Regression and Naive Bayes. <https://towardsdatascience.com/sentiment-analysis-using-logistic-regression-and-naive-bayes-16b806eb4c4b> (accessed: 07.02.2022).
- Mayfield, A. (2008). What is Social Media? [icrossing.co.uk/ebooks](http://www.icrossing.com/uk/sites/default/files/uk/insight_pdf_files/What%20is%20Social%20Media_iCrossing_ebook.pdf). http://www.icrossing.com/uk/sites/default/files/uk/insight_pdf_files/What%20is%20Social%20Media_iCrossing_ebook.pdf
- Mundalik, A. (2018). Aspect Based Sentiment Analysis Using Data Mining Techniques Within Irish Airline Industry MSc Research Project Data Analytics.
- Nguyen, D. Q.; Vu, T., & Nguyen, A. (2020). BERTweet: A pre-trained language model for English Tweets. *Computer Science*. <https://doi.org/10.18653/v1/2020.emnlp-demos.2>
- Pak, A. & Paroubek, P. (2010). Twitter as a Corpus for Sentiment Analysis and Opinion Mining. *Proceedings of the 7th International Conference on Language Resources and Evaluation*, 320-1326.
- Pang, B., Lee, L. & Vaithyanathan S. (2002). Thumbs up? Sentiment Classification Using Machine Learning Techniques *Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 79-86.
- Patil, P. P., Phansalkar, S. & Kryssanov, V. V. (2018). Topic Modelling for Aspect-Level Sentiment Analysis. *Proceedings of the 2nd International Conference on Data Engineering and Communication Technology*, 221-229.
- Pota, M., Ventura, M., Catelli, R., & Esposito, E. (2021). An effective BERT-based pipeline for twitter sentiment analysis: A case study in Italian. *Sensor (Basil)*, 21(1), 133. <https://doi.org/10.3390/s21010133>
- Sel, İ. & Hanbay, D. (2021). Gender Identification from Turkish Tweets Using Pre-Trained Language Models. *Firat Üniversitesi Müh. Bil. Dergisi*, 33(2), 675-684. <https://doi.org/10.35234/fumbd.929133>
- Sharma, R.; Nigam, S. & Jain, R. (2014). Opinion Mining of Movie Reviews a Document Level. *International Journal on Information Theory (IJIT)*, 3(3), 13-21. Doi: <http://dx.doi.org/10.5121/ijit.2014.3302>
- Sinderen, M.V. & Almeida, J.P.A. (2011). Empowering Enterprises Through Next-Generation Enterprise Computing. *Enterprise Information Systems*, 5 (1), 1-8. <https://doi.org/10.1080/17517575.2010.528802>
- Singh, A. (2021). Evolving with BERT: Introduction to RoBERTa. <https://medium.com/analytics-vidhya/evolving-with-bert-introduction-to-roberta-5174ec0e7c82> (date of access: 07.01.2022).
- Uçar, T. (2020). BERT modeli ile Türkçe metinlerde sınıflandırma yapmak. <https://medium.com/@toprakucar/bert-modeli-ile-t%C3%BCrk%C3%A7e-metinlerde-s%C4%B1n%C4%B1fland%C4%B1rma-yapmak-260f15a65611> (accessed: 24.11.2021).
- Upadhyay, N. & Singh, A. (2016), Sentiment Analysis on Twitter by using Machine Learning Technique. *International Journal for Research in Applied Science & Engineering Technolog (IJRASET)*, 4(5), 488-494.
- Weber, L. (2009). *Marketing to The Social Web: How Digital Customer Communities Build Your Business*. (2nd ed.), Wiley, Hoboken, NJ.
- Yıldırım, O. (2020). Internet and Social Media Use in the Period of Social Isolation and Voluntary Quarantine which comes to the Agenda Due to The New Coronavirus Outbreak. *İletişim Kuram ve Araştırma Dergisi*, 52. <https://doi.org/10.47998/ikad.788255>
- Yılmaz, M. C., & Orman, Z. (2021). Sentiment analysis from twitter data during the Covid-19 pandemic era with LSTM deep learning approach. *ACTA INFOLOGICA*, 5(2), 359-372. <http://dx.doi.org/10.26650/acin.947747>
- Zhang, W., Skiena, S. (2010). Trading Strategies to Exploit Blog and News Sentiment, In: *Proceedings of the Fourth International AAI Conference on Weblogs and Social Media*.