


## BiGRU-CNN Tabanlı Derin Öğrenme Modeliyle Türkiye'deki Covid-19 Aşılarına Yönelik Twitter Duygu Analizi

Serpil Aslan

Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Yazılım Mühendisliği  
Bölümü, Malatya, Türkiye  
serpil.aslan@ozal.edu.tr 

Makale gönderme tarihi: 14.03.2022, Makale kabul tarihi: 26.04.2022

### Öz

Günümüzde, sosyal medya platformları duyguları ifade etmenin en iyi yoludur. Yaklaşık iki yıldır, Covid-19 yeni koronavirüs salgının ortaya çıkması tüm dünyada olduğu gibi ülkemizde de insanların üzerinde benzeri görülmemiş karmaşık duygular yarattı. Covid-19'a karşı aşı çalışmalarının başlamasından sonra insanların duyguları daha karmaşık hale geldi. Daha yakın zamanda, Covid-19'un Delta, Omicron vb. varyantlarının çıkması da toplumda yeniden büyük bir korku yarattı. İnsanlar, bu süreçte duygu ve düşüncelerini paylaşmak üzere Twitter gibi sosyal medya araçlarına yöneldi. Twitter'da duygu analizi yapmak çok önemli ve zorlu bir görevdir. Bu çalışmada amacımız, derin öğrenme mimarilerinin gücünden faydalanarak Türk halkının aşılama süreciyle ilgili farklı duygularını araştırmak ve halkın mevcut aşılama girişimlerine yönelik tepkilerine genel bir bakış sunmaktır. Çalışmada, Twitter'da 16 Haziran 2021 ve 18 Eylül 2021 arasında paylaşılan Türkçe tweetler toplanmıştır. İnsanların her türden aşılama ile ilgili duyguları, doğal dil işleme (NLP) aracı olan TextBlob kullanılarak değerlendirildi. Daha sonra, duygu sınıflandırması için yeni bir model önerildi. Önerilen model, Glove kelime gömme vektörüyle tek katmanlı Çift-yönlü Geçitli Tekrarlayan Birim (Bi-GRU) ve Evrişimli Sinir Ağı (CNN) modelini kullanan BiGRU-CNN modelidir. Önerilen yöntemin deneysel sonuçları en son modellerle kıyaslandığında umut vericidir. Bu çalışma, halkın COVID-19 aşılı hakkında görüşlerinin anlaşılmasını geliştirmekte ve koronavirüsü dünyadan yok etme hedefini desteklemektedir.

**Anahtar Kelimeler:** Covid-19 aşı, duygu analizi, derin öğrenme, Glove, CNN, BiGRU

## Twitter Sentiment Analysis for Covid-19 Vaccines in Turkey based on BiGRU-CNN Deep Learning Model

### Abstract

Nowadays, social media platforms are the best way to express emotions. For nearly two years, the emergence of the Covid-19 new coronavirus epidemic has created unprecedented complex emotions on people in our country as well as all over the world. People's emotions became more complex after the start of vaccine studies against Covid-19. More recently, Covid-19's Delta, Omicron etc. The emergence of variants also created a great fear in the society again. In this process, people turned to social media tools to share their feelings and thoughts. Achieving sentiment analysis on Twitter is a very important and challenging task. The aim of this study is to investigate the different feelings of the Turkish people about the vaccination process by making use of the power of deep learning architectures and to provide an overview of the public's reactions to the current vaccination initiatives. In the study, Turkish tweets shared on Twitter between 16 June 2021 and 18 September 2021 were collected. People's feelings about vaccines of all kinds were assessed using TextBlob, a natural language processing (NLP) tool. Next, a new model for emotion classification was proposed. The proposed model is the BiGRU-CNN model using a single-layer Bi-directional Gateway Recurrent Unit (Bi-GRU) and Convolutional Neural Network (CNN) model with the Glove word embedding vector. The experimental results of the proposed method are promising when compared with the latest models. This work improves understanding of the public's views on COVID-19 vaccines and supports the goal of eradicating the coronavirus disease from the world.

**Keywords:** Covid-19 vaccines, sentiment analysis, deep learning, Glove, CNN, BiGRU

## GİRİŞ

Koronavirüs hastalığı (Covid-19), ilk olarak Aralık 2019'da Çin'in Wuhan şehrinde bildirilen yeni koronavirüs SARS-CoV-2'nin neden olduğu bulaşıcı bir hastalıktır. Başlangıçta 2019 Koronavirüs Hastalığı olarak bilinen bu hastalık, 11 Mart 2020'de Dünya Sağlık Örgütü (DSÖ) tarafından pandemi olarak ilan edildi (WHO,2020). Son istatistiklere dayanarak, dünya çapında 423 milyondan fazla insan koronavirüsten etkilenmiş ve yaklaşık 5,8 milyon ölüm vakası meydana gelmiştir (Woldometer,2022). Türkiye' de ise ilk koronavirüs vakasının görüldüğü 11 Mart 2020 tarihinden itibaren vaka sayısı 14,3 milyondan fazla iken koronavirüs sebebiyle gerçekleşen ölüm sayısı ise yaklaşık 92 bindir.

COVID-19 salgını 2020 yılının felaketi olarak yorumlanmaktadır (Şengür, 2021). Covid-19 sağlık sektörüne ciddi zararlar vermiş ve güvenlik kavramını hayatımızın her alanında değiştirmiştir. Sosyal mesafe, koronavirüsün yayılmasını azaltmak için etkili bir yöntemdir. Maske takmak, el yıkamak gibi diğer tedbirlerde oldukça önemlidir. Bununla birlikte, tüm bu tedbirler yalnızca koronavirüsün yayılmasını azaltabilir, tamamen ortadan kaldırmaz. Burada aşı, koronavirüse karşı en etkili şekilde savaşılabilecek salgınla mücadelenin kilidi ve muhtemelen onu ortadan kaldıracak tek çözüm olarak gün ışığına çıkmaktadır. Covid-19'a karşı aşuların geliştirilmesi, Dünya Sağlık Örgütü (DSÖ)'nün pandemi olarak ilan etmesinden bu yana küresel bir amaç olmuştur. Covid-19 için 115'in üzerinde aşı çalışması araştırılmakta ve denenmektedir (Rehman ve ark.,2020). Bir aşının geliştirilmesi genellikle yıllar alır. Covid-19 aşı çalışmalarının diğer aşulara nispeten daha hızlı gelişimi, SARS-Cov-2' ye %80 benzeyen SARS-CoV aşuları üzerine yapılan önceki çalışmalara dayanmaktadır (Badgular ve ark., 2020). Covid-19 aşuları sayesinde kazanılacak bağışıklık ile salgının şiddeti azaltılabilir. Covid-19 aşularının piyasaya sürülmesi, virüsün etkisiyle sosyal ve ekonomik açıdan yıpranmış toplumlarda pek çok kişide rahatlama ve iyimserlik duygusu uyandırmıştır. Türkiye'de SinoVac (İnaktik SARS-CoV-2 aşısı),

Pzifer-BioNTech (RNA tabanlı aşı) ve yerli üretim TURKOVAC olmak üzere üç çeşit Covid-19 aşısı uygulanmaktadır.

Covid- 19 pandemi sürecinin birçok insan üzerinde yıkıcı etkisi oldu, şiddetli endişe, korku ve beraberinde karmaşık duygular yarattı. Aşuların başlamasından sonra duygular daha karmaşık hale geldi. Aşılama sürecine geçildikten sonra, toplum kendi içerisinde aşı yanlısı, aşı karşıtı ve kararsız olmak üzere üç farklı gruba ayrılmıştır. Toplum içerisinde aşıyla ilgili ciddi endişeler ve güvensizlik vardır. İnsanlar en başından beri tüm aşılama süreci hakkında karışık duygular içindeydiler; hatta kendi aile üyelerimizle bile bu tür çatışmalar veya sorularla karşılaştık. Yakın zamanda, insanların aşı olmayı neden iki kereden fazla düşündükleri bilimsel makalelerde geniş çapta tartışılmıştır. Nedenlerden bazıları, aşuların çok hızlı icat edilmesi, üzerinde yeterince araştırma yapılamaması, kansere (Trapani ve Curigliano,2021) veya kısırlığa neden olabilmesi, 2. dozu almanın etkinliğine ilişkin endişeler, alerjik reaksiyonlar (Cabanillas ve Novak, 2021) vb. elde edilmiştir. Ayrıca, çevrimiçi sosyal medya platformlarında aşularla ilgili yapılan eksik veya yanlış yorumların bireylerin aşı tutumlarında ciddi etkiler yarattığı tespit edilmiştir. Koronavirüs aşularıyla ilgili paylaşılan uygunsuz tweetler aşı reddi yaşayan bireylerin tutumlarını pekiştirdiği gibi aşılama konusunda kararsızlık yaşayan bireylerinde fikirlerinin aşı reddine dönüşmesine sebep olmaktadır. Şekil 1'den, Türkiye'de halkın çoğunun aşılanmadığı veya ilk dozdan sonraki dozları uygulamadığı açıkça görülmektedir.

Çalışmanın amacı, Twitter verilerinin gücünden faydalanarak Türkiye'deki Twitter kullanıcıları arasında Covid-19 aşularıyla ilgili atılan tweetlerin ve bu tweetlere yapılan yorumların duygularını derin öğrenme tabanlı doğal dil işleme teknikleri yardımıyla araştırmaktır. Çalışmada, Twitter'da 16 Haziran 2021 ve 18 Eylül 2021 arasında paylaşılan Türkçe tweetler toplanmıştır. İnsanların her türden aşularla ilgili duyguları, doğal dil işleme (NLP) aracı olan TextBlob kullanılarak

Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1087486

değerlendirildi. Daha sonra, duygu sınıflandırması için yeni bir model önerildi. Önerilen model, Glove kelime gömme vektörüyle tek katmanlı Geçitli Tekrarlayan Birim (gRU) ve Evrişimli Sinir Ağı (CNN)'na dayalı hibrit BiGRU-CNN modelidir. Önerilen model, evrişimli sinir ağının ve tekrarlayan sinir ağının özelliklerini ve avantajlarını birleştirir. Önerilen modelde, GRU bir tweetteki sıralı bilgileri ve uzun mesafe bağımlılıklarını yakalarken, CNN ise konumda değişmez özellikleri yakalamaktadır. Bu sayede en etkin özellikler çıkarılabilmektedir. Modelde, Bi-GRU katmanının çıktılarını, CNN'in girişi olarak birleştirilir. BiGRU katmanından sonra, her vektör tüm cümlenin çift yönlü bilgisini içerir. Daha sonra, uygulanan CNN katmanı daha soyut konumla değişmeyen bilgileri yakalamak için daha elverişli bir model olacaktır.

Önerilen modelin doğruluğu hem makine öğrenmesi algoritmaları hem de modeli oluşturan temel derin sinir ağı modelleriyle kıyaslanmıştır. Ayrıca modelde kullanılan Glove kelime gömme yaklaşımının gücünü göstermek amacıyla modeller TF-IDF kelime gömme yaklaşımı kullanılarak test edilmiştir. Sayısal deneylerin sonucu, önerilen modelin, son teknoloji yöntemlerden daha iyi ölçüm performansı elde ettiğini göstermektedir. Çalışmanın deneysel sonuçları aşısıyla ilgili paylaşılan olumsuz içerikli tweetlerin tespitini kolaylaştıracaktır. Bu sayede, hükümet ve sağlık kurumlarının salgınla mücadelenin kilidi olan aşılama çalışmalarını daha verimli uygulayabilecektir.

Çalışmanın geri kalan kısımları aşağıdaki gibidir: Bölüm 2'de koronavirüs ve aşısıyla mücadeleyi ele alan çalışmalardan ve bu alanda yapılan duygu analizi çalışmalarından bahsedilir, Bölüm 3'de önerilen yöntem için toplanan veri seti, bu veri seti üzerinde uygulanan ön işleme adımları ve duygu analizi anlatılır. Bölüm 4'te önerilen yöntem detaylandırılmıştır. Bölüm 5'te gerçek veri seti üzerine uygulanan yöntemimizin deneysel sonuçları analiz edilmiştir. En son, Bölüm 6 da çalışma sonlandırılmıştır.

## İLGİLİ ÇALIŞMALAR

Duygu analizi bir metin üzerinden iletilen öznel bilgilerin otomatik olarak çıkarılmasıdır (Agarwal ve ark., 2011). Duygu analizi yoluyla, bir metnin olumlu veya olumsuz bir öznel yönelimi olup olmadığı hakkında fikir sahibi olabiliriz. Duygu analizi, üç seviyeye ayrılabilir. Bunlar: (1) belge düzeyi (Pang ve Lee, 2004), (2) cümle düzeyi (Hu ve Liu, 2004) ve (3) ifade düzeyi (Aygün ve ark., 2021). Belge düzeyinde duygu analizinde verilen belgenin genel duygu polariteleri tespit edilir. Buradaki en önemli nokta, belgenin tek bir konuya veya tek bir varlığa odaklandığını varsayar. Cümle düzeyinde duygu analizinde ise, bir cümlenin olumlu, olumsuz veya tarafsız görüş içerip içermediği araştırılır. Bunlara ek olarak, cümlenin öznel ya da nesnel duygu içerdiğini de araştırır. İfade düzeyinde duygu analizinde ise, varlık/nesne tanımlama, öznellik/nitelik çıkarma ve öznellik polarite olmak üzere üç ana adım kapsamında incelenir. Ortak duygu analizi modelleri, büyük ölçüde duygu sözlüklerine dayanır. Duygu sözlüğü, her kelimenin öznel yöneliminin olumlu ve olumsuzluğuna göre etiketlendiği bir kelime grubudur. Tüm bunlara ek olarak, farklı tipte sözlükler iki şekilde sınıflandırılabilir: anlamsal yönelim etiketleme (sözcüklerin olumlu ya da olumsuz olarak bölündüğü veya daha önceden tanımlanmış kurallara göre nicel bir puanlama yapılması. LIWC (Pennebaker ve ark., 2015), HULIUO (Hu ve Liu, 2004) yaygın olarak kullanılan bağlamdan bağımsız sözcüklerden oluşan sözlüklerdir. ANEW (Bradley ve Lang, 1999), SenticNet (Baccianella ve ark., 2010) ve SentiWordNet (Cambria ve ark., 2012) ise duyarlılık yoğunluğuna dayanan, nicel puanlamanın yapıldığı sözlüklerdir.

Günümüzde sosyal medya, doğru bilgilerin hızla yayılmasına olanak sağladığı gibi yanlış bilgilerinde yayılması için en çok tercih edilen araç haline gelmiştir. Twitter bu bağlamda en çok tercih edilen platformlardan biridir. Araştırmacılar, bireylerin duygu ve düşüncelerini analiz etmek amacıyla Twitter'da duygu analizi uygulamaları yapmaya başlamıştır. Twitter'da tweetlerin analiz edilip duygu

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486

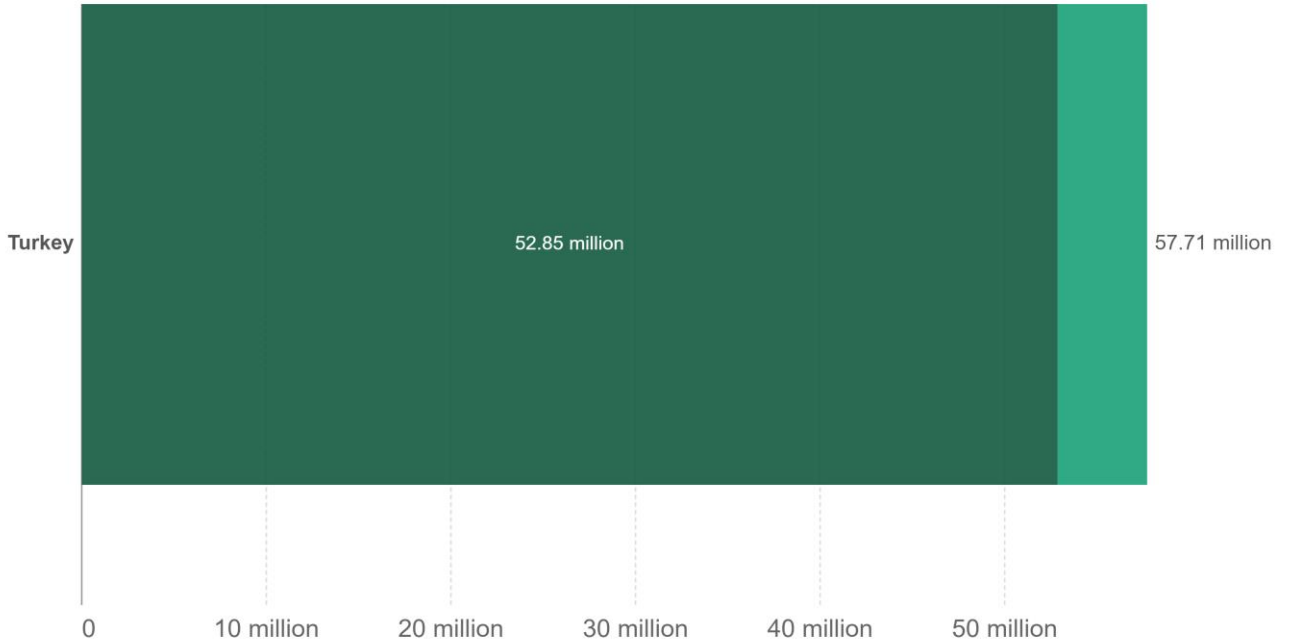
analizlerinin gerçekleştirilmesi toplumda olumsuz duygular uyandıracak tweetlerin tespitinde büyük kolaylık sağlayacaktır. Bugün yaşananlar, duygu analizinin sadece olumlu ve olumsuz duygulardan geçebilen değil, aynı zamanda farklı konu ve diller için davranış ve hislerle de ilgilenebilen bir noktaya ulaştığını göstermektedir. Duygu analizi çalışmalarında birçok farklı teknik kullanılmıştır.

Joshi ve ark. (2016) Twitter film yorumlarını incelemek amacıyla Destek Vektör Makinaları (DVM) ve Naive Bayes ve Maximum Entropi yöntemlerini kullanarak karşılaştırma gerçekleştirmiştir. Parikh ve ark. (2009) twitleri sınıflandırmak için iki Naive Bayes 1-gram modeli, bir Naive Bayes 2-gram modeli ve Maximum Entropy modeli uygulamıştır.

## Number of people vaccinated against COVID-19, Mar 4, 2022

Our World  
in Data

■ People with a complete initial protocol ■ People only partly vaccinated



Source: Official data collated by Our World in Data

CC BY

Note: Alternative definitions of a full vaccination, e.g. having been infected with SARS-CoV-2 and having 1 dose of a 2-dose protocol, are ignored to maximize comparability between countries.

**Şekil 1.** Türkiye’de Aşı Dozlarının Uygulanma İstatistikleri

Go ve ark. (2009) çalışmalarında, 1-gram, 2-gram ve n-gram gibi farklı veri temsili yapılarıyla, Naive Bayes, MAXEnt ve Destek Vektör Makinaları (DVM) makine öğrenmesi sınıflandırıcılarını kullanarak duygu analizi gerçekleştirmiştir. Çalışmalarında Destek Vektör Makinalarının diğer sınıflandırıcılardan daha iyi sonuçlar verdiğini

bildirmişlerdir. Duncan ve Zhang, (2015), tweetlerdeki duyguları sınıflandırmak için sinir ağı modelini kullandılar. Literatürdeki çalışmalara dayanarak, metin boyutu küçük olan veri setlerinde metni sınıflandırmak için çoğunlukla Naive Bayes ve sinir ağları kullanırken, veri boyutunun arttığı veri setlerinde doğruluğu arttırmak ve büyük veriyle

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486

oluşturulan sinir ağının işlenmesi için derin öğrenme mimarisi kullanılmaktadır. Derin öğrenme yaklaşımı aracılığıyla metinde içerisinde ki duygu özellikleri otomatik tanımlamalarla tespit edilir. Bu çalışmada, derin öğrenme mimarisi kullanarak Twitter'dan toplanan büyük veri seti üzerinde duygu analizi tahminleri yapan bir model önerilmiştir.

Sosyal medya platformları ve medya araçları, toplumu bölmeye ve toplumda korku, endişe, stres gibi olumsuz duygular uyandıracak asılsız bilgiler sunmak yerine yapıcı ve olumlu duygular uyandıracak doğruluğu kanıtlanmış tarafsız bilgiler sunmalıdır. Paylaşılan bu tarz bilgilerin analizini inceleyen birçok çalışma yapılmıştır. Covid-19 tüm dünya için büyük bir ızdıraptır. Bu olayla ilgili haberle, sosyal medyadaki diğer haberleri baskın olarak geride bırakmıştır. Bu haberler aynı zamanda sahte, doğrulanmamış ve insanların önyargılarına tabi olanları da içermektedir. Bu nedenle Covid-19 haberlerindeki olumsuzlukları belirleme çalışmaları yerinde ve zamanında çalışmalardır. Chakraborty ve ark. (2020) Twitter sosyal medya platformunda koronavirüs salgınıyla ilgili atılan tweetleri derin öğrenme sınıflandırıcılarıyla inceleyen bir duygu analizi çalışması önermiştir. Önerilen çalışmada, olumsuz içerikli paylaşılan tweetlerin bireyler üzerinde korku, dehşet, üzüntü gibi psikolojik etkileri büyük olan duygular oluşturduğunu, bunların tespitinin salgınla mücadele yolunda büyük avantajlar sağlayacağını savunmuşlardır. Barkur ve Vibha (2020), Hindistan'da Covid-19 haberlerine ilişkin topladıkları 2400 tweetten oluşan bir veri setini incelemiştir. Bu çalışmada, R programla dili kullanarak paylaşılan tweetlerin duygu analizini gösteren kelime bulutu çıkartılmıştır. Li ve ark. (2020) ise Covid-19'un insan davranışı üzerindeki psikolojik etkisine odaklanmıştır. Covid-19 haberleri nedeniyle insanların gergin olduğunu ve depresyon düzeylerinin arttığı bildirilmiştir. Süral ve ark. (2019), sürekli duygusal zekâ olarak tanımladığı zekânın sorunlu sosyal medya kullanımı ile ilgili olduğunu ve doğrudan doğruya sosyal medyada popüler bir taraf sunmak ve zaman geçirme

güdüleriyle ilişkili olduğunu göstermiştir. Bu çalışma, sürekli duygusal zekâ puanı düşük olan bireylerin gerçek hayattaki sorunlarıyla başa çıkmak için sosyal medya platformlarını bir başa çıkma stratejisi olarak kullandıklarını savunmuştur. Xue ve ark (2020), 1 Mart 2020'den 21 Nisan 2020'ye kadar 25 farklı etiket kullanarak Covid-19 ile ilgili atılan tweetleri toplamışlardır. Çalışma, 4 milyon tweetten oluşan veri seti üzerinde gerçekleştirilmiştir. Gizli Dirichlet Ayırımı (GDA) algoritması kullanılarak tweetlerdeki popüler konu başlıkları tespit edilmiştir. Feng ve Zhou (2020), Twitter'da paylaşılan tweetlerdeki duyguları incelemek amacıyla tekli ve çoklu etiketlere odaklanan BERT modeli kullanmışlardır. Önerilen modelin kilit noktası, duyguları ifade etmenin etkili bir yolu olan emojileri dikkate almaktır. Hornung ve ark. (2018), duygusal zekâ ve Facebook kullanımı arasında orantılı bir ilişki olduğunu savunan bir çalışma sunmuştur. Önerilen çalışmada farklı yaş gruplarından oluşan bir veri seti toplanmıştır. Bu veri seti üzerinde yapılan duygu analizi çalışmaları sonucu duygusal zekâ ve Facebook kullanımı arasındaki ilişkinin veri setindeki genç grup için olumlu yaşlı grup için olumsuz olduğunu belirtilmiştir. Depoux ve ark. (2020) koronavirüs salgınıyla mücadelede ortaya çıkan sosyal medya paniğiyle ilgili alınması gereken bir takım önlemleri tartışmıştır. Birçok toplumun maruz kaldığı stresli karantina günlerinde artan sosyal medya kullanımıyla birlikte sosyal medyada panik etkisi yaracak paylaşımlarda artmıştır. Bu tarz paylaşımların sağlık bakanlığının ve kurumlarının alacağı önlemlerle engellenip sosyal medyanın akıllıca kullanılması bireylerin ruhsal dengelerini korumalarına yardımcı olacağı vurgulanmıştır. Jelodar ve ark. (2020) sosyal medyada ifade edildiği şekliyle Covid-19 ile ilgili konu modellemesi için NLP kullandılar. Daha sonra çalışmalarında LSTM-RNN (LSTM- Recurrent Neural Networks) modelini kullanarak sınıflandırma yapmışlardır. Pano ve Kashev (2020), Covid-19 salgınının Bitcoin fiyatları üzerindeki etkisini araştırmıştır. Lu ve Zhanh (2021) duygu analizinde uzun eğitim süresini kısaltmak

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486

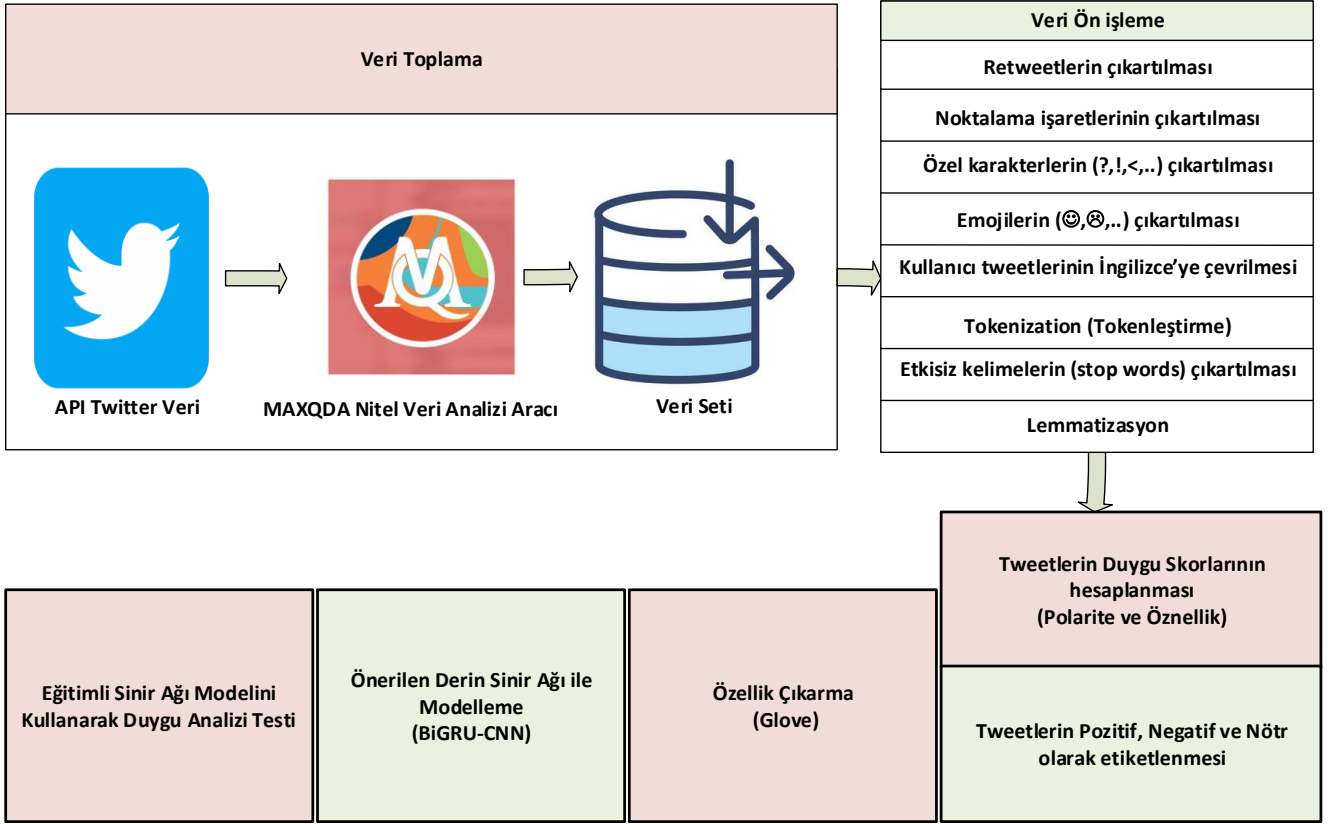
amacıyla AT-BiGRU modeline dayalı dikkat mekanizmalı bir model önermiştir.

Aşılama, salgınla bulaşan hastalıklarla mücadelede şüphesiz en önemli buluşlardan biridir (Alıcılar ve Çöl, 2021). Aşılamayla birlikte toplum bağışıklığı adında yeni bir kavramda ortaya çıkmıştır. Toplumun salgın hastalıklara yakalanıp antikor üretmesiyle doğal bağışıklık sağlanabilir. Fakat bu durum birçok kişinin hastalığa yakalanmasına ve gereksiz ölümlere sebep olabilir. Bunun yerine aşılamayla birlikte toplum bağışıklığının kazanılması daha akılcıdır. Son yirmi yılda, aşı çalışmalarının artmasıyla birlikte, tüm dünyada aşıyla ilgili olumlu tutumların yanı sıra belirgin bir aşı karşıtı hareketi arttı. Aşıyla ilgili bilinen eksik yanlış bilgiler ve duyulan endişe aşılama kapsamının azalmasına ve birçok ülkede kızamık gibi salgın hastalıklar da artışa neden oldu (Kwok ve ark., 2021). Aşıyla ilgili yapılan olumsuz haberler ve aşı karşıtı sosyal medya paylaşımları, aşıya bağlı toplum bağışıklığı

sağlanmasına engel olabilir. Örneğin, aşılardan olumsuz etkileriyle ilgili yapılan yanlış ve eksik bilgiler içeren paylaşımlar, genellikle aşı karşıtı kişiler tarafından hareketlerini körüklemek amacıyla manipüle edilir (Ortiz-Sánchez ve ark. 2020). Covid-19 aşılı geliştirilmeye başlamadan önce bile aşı geliştirmeye karşı komplo teorileri üretilmiştir. Bu nedenle, aşı kabulünü etkileyen faktörlere dayalı olarak aşılarmaya teşvik etmek için Covid-19 aşısı hakkında çevrimiçi sosyal medya platformlarında paylaşılan gönderilerin duygularının araştırılması ve gözden geçirilmesi gerekmektedir.

### ÖNERİLEN YÖNTEM

Bu çalışma, Glove kelime gömme yaklaşımıyla BiGRU-CNN modelini kullanarak duygu sınıflandırmasını iyileştirmek için yeni bir yaklaşım geliştirmeyi amaçlamaktadır. Bu bölümde önerilen modelin yapısı detaylı olarak tartışılmaktadır. Şekil 2, önerilen yöntemin genel yapısını göstermektedir.



### Veri Toplama

Çalışmada veri kaynağı olarak, 2021 yılının ilk çeyreği itibarıyla günlük 199 milyon aktif kullanıcısıyla (Twitter,2021) dünyanın en büyük sosyal medya platformu olan Twitter seçilmiştir. Veriler Twitter’da herkese açık olarak paylaşılan tweet verilerinden toplanmıştır. Bu veri seti için alana göre herkese açık olarak paylaşılan tweetler’de sadece Türkçe paylaşılan aşı ile ilgili veriler saklanmıştır. Çalışmada, Twitter verilerini toplamak için MAXQDA (MAXQDA,2020) nitel veri analizi aracı kullanılmıştır. Bu platformda 16 Haziran 2021 ve 18 Eylül 2021 tarihleri arasında yayınlanan Covid-19 aşısıyla ilgili tweet’ler, retweet’ler ve bu tweetlere yapılan yorumlar toplanmıştır. Hedef tweetlere ulaşmak için, Twitter’da aşıyla ilgili en çok tweet atılan etiketler belirlendikten sonra “covid19aşı OR biontech OR Sinovac OR covid19vaccine OR coronavac” ve “aşihayatkurtarıcı OR aşımğdurları

OR aşıl OR aşıyanetkileri” arama terimleri kullanıldı. Son olarak, toplanan veriler daha sonra ön işleme ve duygu sınıflandırma adımlarında kullanılmak üzere csv dosyasına dönüştürüldü. Boolean “AND” ve “OR” operatörleri, “aşı” köküne ait kelimelerin yanı sıra “koronavirüs” veya “COVID” köküne ait kelimeleri içeren tweet’lerin aranabileceğini de göstermiştir. Sonuç olarak, 16 Haziran ve 18 Eylül 2021 tarihleri arasında 176345 Türkçe tweetten oluşan bir veri seti toplanmıştır. Bu veri setinin doğruluğunu sağlamak amacıyla bir sonraki aşamada detayları verilen ön işleme aşaması gerçekleştirildi.

### Veri Temizleme ve Ön-İşleme

Twitter sosyal medya platformundan toplanan veriler genellikle temiz değildir. Metin temizleme, metnin anlamının çıkarılması veya analiz edilmesi zor olan kelimeleri veya diğer bileşenleri temizlemek

için yapılan metin madenciliği işlemlerinden biridir. Analiz aşamasında deneysel sonuçları olumsuz yönde etkileyebilecek gereksiz birçok özel karakter, ifade, link, etiket, emoji vs. içerir. Bu karakterler fazla bilgi vermediği gibi duygu analizi için de işlenmesi zor karakterlerdir. Bu aşamada aşağıda verilen işlemler uygulanarak veri seti üzerinde ön işleme yapılmıştır:

- Tekrarlanan tweetler veri setinden çıkartılır.
- Numaralar kaldırılır.
- Noktalama işaretleri kaldırılır.
- Twitter RT, @ ve cümlelerdeki bağlantılar temizlenir.
- Metin küçük harfe dönüştürülür, böylelikle “aşı” ve “Aşı” gibi kelimeler analiz için aynı kelime olarak kabul edilir.
- Özel karakterler ve duygu ifade etmek için kullanılan yüz ifadeleri (emojiler) kendilerine özel kodları kullanılarak metin içerisinde tespit edildikten sonra kaldırılır.
- Her bir tweet Google Çeviri Python kütüphanesi Googletrans kullanılarak İngilizce metine çevrilir. Googletrans, Google Translate API'sini uygulayan ücretsiz ve sınırsız bir python kütüphanesidir. Bu kütüphane, metni anlama ve çevirme gibi yöntemler için Google Translate Ajax API'sini kullanır.
- Her bir tweet için tokenleştirme işlemi uygulanır. Tokenleştirme, metin içerisindeki kelimelerin boşluklara göre ayrılması işlemidir.
- Daha sonra tweetlerden “bir”, “bu”, “şu”, “filan” vb. gibi etkisiz kelimeler (stopwords) çıkartılır.
- Her bir tweet içerisindeki kelimeler köklerine ayrılır. Lemmatizasyon kelimelerin morfolojik analizlerini kullanır. Örneğin, “doktorum” kelimesi “doktor” olarak güncellenir.

Ön-işleme uygulamanın amacı metnin temel anlamını bozmadan metin içerisinde geçen kelime sayısının azaltılmasıdır. Toplanan ham veri setinde duygu analizi aşamasında kullanılmayacak gereksiz kelime ve ifadeler bulunmaktadır. Bu nedenle, herhangi bir veri analizi yapmadan önce ön işleme gerçekleştirilmesi gerekir.

### Polarite ve Öznellik

Twitter sosyal medya platformundan toplanan veriler genellikle temiz değildir. Metin temizleme, metnin anlamının çıkarılması veya analiz edilmesi zor olan kelimeleri veya

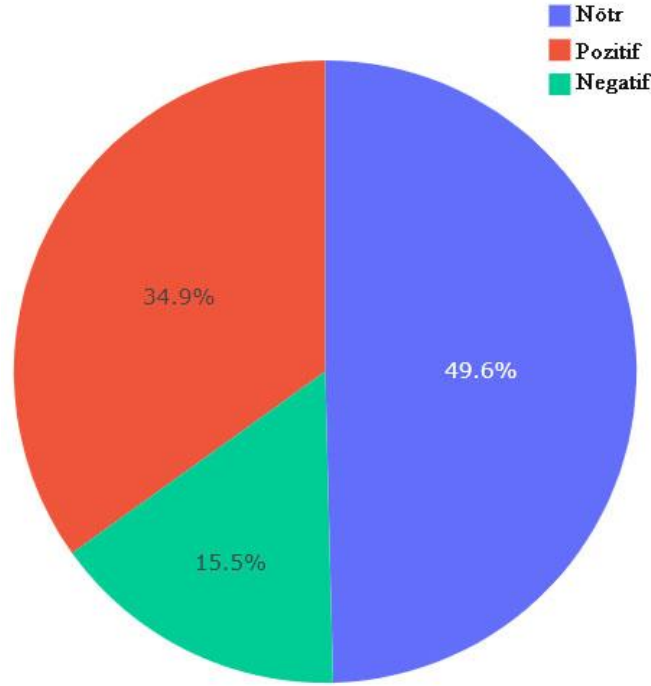
Tweetlerin temizlenmesinden sonra, NLTK ve TextBlob kütüphaneleri kullanılarak her bir tweet'in polaritesi ve özneliği hesaplanır. TextBlob, konuşma parçası etiketleme, duygu analizi, kelime kökü çıkarma, çeviri, sınıflandırma ve daha pek çok doğal dil işleme (NLP) görevlerinde kullanılan bir Python kütüphanesidir (Loria,2018). TextBlob kütüphanesi “Polarite” ve “Öznellik” olmak üzere iki özellik döndürür.

*Cümle Özneliği:* Nesnel bir cümle dünya hakkında bazı olgusal bilgileri ifade ederken, öznel bir cümle bazı kişisel duygu ve inançları ifade eder. Öznel cümleler genellikle inanışlar, arzular, görüşler, şüpheler, sevinçler, korkular vb. gibi kişisel duyguları yansıtır. Öznellik, [0,1] aralığında değer alan değişken bir parametredir. Öznellik değeri sıfıra ne kadar yakınsa cümle o kadar gerçeklerle alakalıdır. Öznellik değeri arttıkça fikir olmaya yaklaşır.

*Cümle Polaritesi:* Polarite, yazılı veya sözlü dilde olumlu, olumsuz ve tarafsız duygu yönelimlerini ifade eder. Polarite, [-1,1] aralığında bir değer alır. -1, 0 ve 0 polarite puanları sırasıyla negatif, nötr ve pozitif ifadeleri temsil etmektedir.

Şekil 3, pozitif, negatif ve nötr sınıf etiketlerine göre ayrılan tweetlerin sayılarını göstermektedir.





Şekil 3. Türkiye’de Covid-19 Aşılarıyla İlgili Duygu Dağılımı

#### Kelime Temsili Yaklaşımları: TF-IDF ve Glove

Herhangi bir tahmin modelini uygulamak için Twitter metin verilerini sayılara dönüştürmek gerekir. Bu işlem, metin vektörleştirme olarak bilinir. Metin analizi ve Doğal Dil İşleme (NLP) makine öğrenimi sürecinde temel bir adımdır. Literatürde, kelime çantası (Bag-of-Words), Word2Vec, Doc2Vec, TF-IDF vb. çeşitli özellik çıkarma yöntemleri mevcuttur (Madusa,2019). Terim Frekansı- Ters Doküman Frekansı (TF-IDF) metindeki en belirgin kelimelere odaklandığı ve kelime sayısına bağlı olma sınırlamasını aştığı için daha fazla tercih edilmektedir.

TF-IDF, verilen metinde sıkça geçen kelimeleri ve kalan veri setinde sık görülmeyen kelimeleri tanımlar. Bu sayede metinler daha kısa bir belge olarak değerlendirilebilir. TF ve IDF' nin çarpımı, kelimenin bir belgede ne sıklıkta bulunduğu, kelimenin ne kadar benzersiz olduğu ile çarpılarak bir ölçüm sağlar ve bu, TF-IDF ölçüsüdür. Her metinde ortak olan “bu”, “ne” ya da “eğer” gibi sözcükler, bu metin cümleleri için pek bir anlam ifade etmedikleri

için bu sözcükler birçok kez karşımıza çıksa da yoğunluk sıralamasında alt sıralarda yer alır.

TF-IDF, bilgi erişimi ve metin madenciliği için denetimsiz bir terim ağırlıklandırma şemasıdır (Kamyab ve ark., 2021). Bir  $t$  terimin doküman içerisindeki önemini gösteren istatistiksel yöntem ile hesaplanmış ağırlık faktörüdür. TF-IDF, verilerde ki bir kelimenin önemini ölçmek için puanlandırma yapar. Terim frekansı ve ters belge frekansı ölçüklerini kullanarak hesaplanır.

Matematiksel fonksiyonlar Denklem (1), (2) ve (3)'de gösterilmiştir:

TF, kelimenin belgede görünme sayısı olan Terim Sıklığı'nın kısaltmasıdır. Aşağıdaki gibi tanımlanır:

$$tf_{(t,d)} = \frac{count_{t,d}}{totalcount_d} \quad (1)$$

Denklem 1’de  $count_{t,d}$ :  $t$  teriminin  $d$  dokümanı içerisindeki sayısı,  $count_d$ :  $d$  dokümanı içerisindeki toplam terim sayısıdır.

Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1087486

IDF, farklı belgelerde geçen kelimenin ağırlığını azaltan Ters Döküman Sıklığı'nın kısaltmasıdır (Sohangir ve ark., 2018). **IDF**, kelimelerin ne kadar benzersiz olduğunu ölçer, yani bir kelimenin tüm belge kümesinde ne kadar yaygın veya nadir olduğu anlamına gelir. Aşağıdaki gibi hesaplanır:

$$Idf(t, d) = \frac{N}{Df_t} \quad (2)$$

Denklem 2'de N: veri setindeki toplam doküman sayısı,  $Df_t$ : t terimini içeren doküman sayısıdır. Son olarak, TF-IDF su şekilde tanımlanabilir:

$$TF - IDF_{t,d} = tf_{(t,d)} * \log(Idf(t, d)) \quad (3)$$


GloVe (Global Vectors for Word Representation), Pennington ve ark. (2014) tarafından kelime vektör temsillerini elde etmek için word2vec yaklaşımına alternatif olarak sunulan word2vec tabanlı sözcük temsildir. Kelime temsillerinin oluşturulmasında birlikte kullanılan kelimelerin istatistiklerinden faydalanır. 200-boyutlu bir kelime vektör matrisi oluşturmak için yaklaşık 2 milyar tweetle oluşturulmuş önceden eğitilmiş Glove modeli kullanıldı (Kamyab ve ark., 2021). Her bir kelime girişi  $T(t_1, t_2, \dots, t_k)$  ile temsil edilerek d-boyutlu kelime vektörüne dönüştürülür. Bu dönüşümden sonra,  $R^d$  her bir kelimenin boyut uzayıdır ve her bir giriş metni  $R^{k \times d}$  boyut uzayıyla ve her bir giriş metni matrisi  $T(t_1, t_2, \dots, t_k) \in R^{k \times d}$  ile temsil edilir. Son olarak,  $f_v$  Glove'dan elde edilmiş kelime vektör matrisi matematiksel olarak aşağıdaki gibi temsil edilir:

$$f_v = \omega_1 \oplus \omega_2 \oplus \omega_3 \dots \oplus \omega_n \quad (4)$$


### Geçitli Tekrarlayan Birim (GRU) ve BiGRU

Geçitli tekrarlayan birim (GRU), ayrı bir bellek hücresi olmayan modüle edilmiş LSTM modeli versiyonudur. LSTM'nin doğal dil işleme alanındaki hızlı gelişmesi ve veri setlerinin büyümesiyle birlikte uzun eğitim süresi, parametre fazlalığı ve yüksek hesaplama karmaşıklığı gibi sorunlar ortaya çıkmıştır. Bu problemlere dayanarak, Cho ve ark. 2014'te basit bir GRU modeli önerdi. Giriş geçidini ve unutma geçidini tek bir güncelleme kapısında birleştirir (Cho ve ark., 2014). Önerilen GRU modeli orijinal LSTM modelinin yapısını koruyup daha basit bir yapı, daha az parametre ve daha iyi bir yakınsama modeli olmuştur. Güncelleme kapısı ve sıfırlama kapısı olmak üzere iki kapıdan oluşur. Güncelleme katmanı, önceki gizli katmanın çıktısının geçerli katmanı ne derece etkilediğini hesaplar. Değer ne kadar büyükse etki o kadar yüksektir. Sıfırlama kapısı ise önceki gizli katman bilgilerinin ne ölçüde yok sayılacağını hesaplar. Sıfırlama kapısı değeri ne kadar küçükse, bilgi o kadar göz ardı edilir.

GRU, bir tür tek yönlü sinir ağı yapısıdır. Tek yönlü sinir ağı modelleri ileri beslemelidir ve çıkış her zaman bir önceki katmandan alınır. Bununla birlikte, duygu analizinde mevcut anın çıktısı önceki ve sonraki anlarla bir ilişki içerisindedir. BiGRU modeli, iki GRU mimarisinin birleştirilmiş versiyonudur. Her durumda, giriş ters yönde iki GRU sağlar ve çıkış iki adet tek yönlü GRU tarafından belirlenir. GRU ve BiGRU modellerinin temel yapısı sırasıyla Şekil 4 ve Şekil 5'te gösterildiği gibidir Şekil 4 ve 5'ten de görüldüğü gibi BiGRU, bir ileri ve bir geri olmak üzere aynı çıktı katmanına bağlı iki adet GRU sinir ağından oluşur.



Şekil 4. GRU Modelinin Temel Yapısı



Şekil 5. BiGRU Modelinin Temel Yapısı

### Evrişimli Sinir Ağı (CNN)

CNN, son yıllarda oldukça dikkat çeken derin öğrenme mimarisi türüdür. CNN görüntü tanıma, doğal dil işleme ve evrişimli çekirdek ile yerel özellikleri tanıma yeteneğine sahip diğer alanlarda

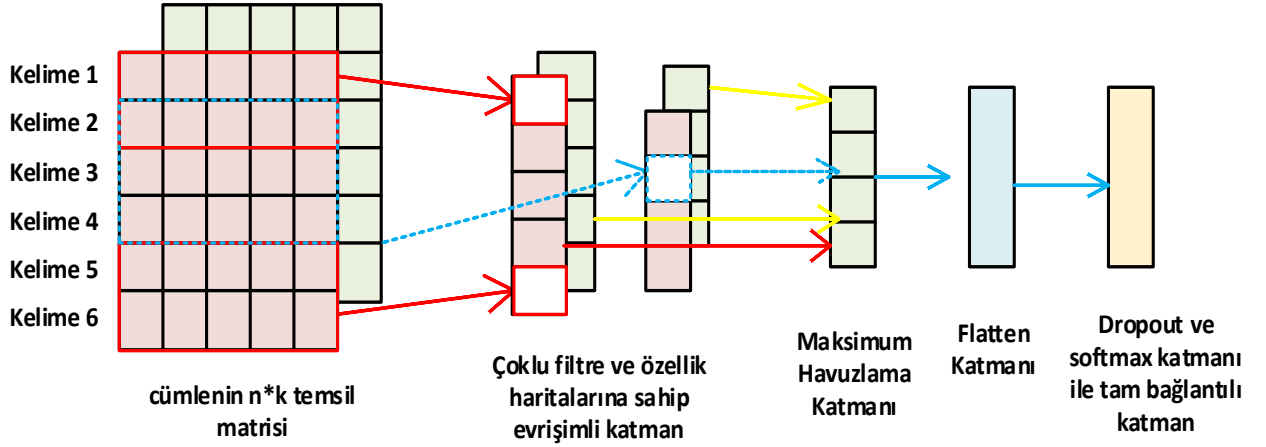
yaygın olarak kullanılmaktadır (Yan ve ark., 2015). Ayrıca, CNN mimarileri sınıflandırma yapacak özellikleri otomatik olarak öğrenme yeteneğine sahiptir. Denetimsiz CNN mimarisi, çok katmanlı ileri beslemeli sinir ağıdır. CNN, bir giriş katmanı,

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486


bir çıkış katmanı, bir veya daha fazla konvolüsyonel katman, alt örnekleme katmanı, havuzlama katmanı ve bir veya daha fazla tamamen bağlı katmandan oluşur. CNN modeli, hesaplama karmaşıklığını azaltmak için havuzlama katmanı kullanır. Flattened katman ise havuzlama katmanının çıktısını besler. Aynı zamanda onu bir sonraki katmana eşler. CNN mimarisinin son katmanı tamamen bağlı katmanlardan oluşur. Şekil 6 metin sınıflandırma

çalışmalarında kullanılan temel CNN mimarisini göstermektedir.

Şekil 6’da görüldüğü gibi  $n$  boyutlu bir  $S$  cümlesi  $x = [w_1, w_2, \dots, w_n]$  matrisiyle temsil edilir.  $w_i$  de ki  $i$ . Eleman  $S$  cümlesinde ki  $i$ . Kelimenin  $k$  boyutlu vektörel temsildir.  $x \in R^{n \times d}$  matrisi konvolüsyonel katmanın girişidir.



Şekil 6. Temel CNN Mimarisi



Şekil 7. Önerilen Modelin Derin Sinir Ağı Modeli (BiGRU-CNN)

### Önerilen BiGRU-CNN Derin Sinir Ağı Modeli

Bu çalışmada, Twitter verilerinin gücünden faydalanarak Türkiye’deki Twitter kullanıcıları arasında Covid-19 aşılılarıyla ilgili atılan tweetlerin ve bu tweetlere yapılan yorumların duygularını araştırmak için derin öğrenme tabanlı yeni bir hibrit model öneriyoruz. Şekil 7, duygu sınıflandırması için önerilen modelin adımlarını göstermektedir. Çalışma, üç aşamadan oluşmaktadır. İlk aşama, ön-işleme ve kelime temsili adımdır. Bu adımda, bir önceki Şekil 2’de detayları verilen ön-işleme adımları uygulandıktan sonra her bir tweet, son yıllarda Twitter gönderilerinde duygu analizi çalışmalarında oldukça başarılı sonuçlar elde eden Glove kelime gömme yaklaşımı kullanılarak vöktörelere dönüştürülür. Bu adımdan sonra her bir tweet, vektörel kelime temsili yapısındadır. Sonraki adımda,

elde edilen vektörel kelime temsilleri RNN tabanlı BiGRU katmanına, BiGRU katmanının çıktısı da CNN modelinin konvolüsyonel katmanına girdi olarak verilir. BiGRU modeli, tweetleri sırasıyla ileri ve geri yönde okuyup, tweetlerdeki kelimelerin bağlamsal özelliklerini, anlamsal özelliklerini ve gramer özelliklerini çıkarır. CNN modelinden önce uygulanan BiGRU modeli, CNN'nin temel özellikleri daha iyi çıkarmasına yardımcı olacaktır. Tüm bu problemlerin üstesinden gelmek amacıyla, Şekil 7’de detayları verilen BiGRU-CNN modelini tasarladık.

### Değerlendirme Ölçekleri

Derin öğrenme ve makine öğrenmesi modellerinin performansını değerlendirmek için, dört farklı performans ölçeği kullandık. Bu çalışmada yaygın olarak kullanılan değerlendirme ölçütleri arasında yer alan “Doğruluk (Accuracy), Kesinlik

Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1087486

(Precision), Hatırlama (Recall) ve F1-skorunu” kullanılmaktadır.

Doğruluk, tahminin doğruluğu olarak kullanılır ve şu şekilde hesaplanır:

$$\text{Doğruluk (Accuracy)} = \frac{\text{Doğru tahminlerin sayısı}}{\text{Toplam tahmin sayısı}} \quad (5)$$

İkili sınıflandırma içinse doğruluk, pozitif ve negatif olarak aşağıdaki gibi hesaplanır:

$$\text{Doğruluk (Accuracy)} = \frac{DP+DN}{DP + YN+YP+DN} \quad (6)$$

Denklem 6’ da  $DP$ ,  $DN$ ,  $YP$  ve  $YN$ , gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatifi temsil eder ve aşağıdaki gibi tanımlanır (Ashraf ve ark., 2018).

$DP$  (Doğru Pozitif): Sınıflandırıcı tarafından pozitif olarak sınıflandırılan ve gerçek test veri setinde de pozitif olan tahminlerin sayısıdır.

$DN$  (Doğru Negatif): Sınıflandırıcı tarafından negatif olarak sınıflandırılan ve gerçek test veri setinde de negatif olan tahminlerin sayısıdır.

$YP$  (Yanlış Pozitif): Sınıflandırıcı tarafından pozitif olarak sınıflandırılan ve gerçek test veri setinde ise negatif olan tahminlerin sayısıdır.

$YN$  (Yanlış Negatif): Sınıflandırıcı tarafından negatif olarak sınıflandırılan ve gerçek test veri setinde ise pozitif olan tahminlerin sayısıdır.

**Kesinlik (Precision):** Bir sınıflandırıcının kesinliği olarak adlandırılır ve tüm kümelerin yüzde kaçının pozitif olarak etiketlendiğini ve bunların gerçekten pozitif olduğunu gösterir. Aşağıdaki gibi hesaplanır:

$$\text{Kesinlik (Precision)} = \frac{DP}{DP + YP} \quad (7)$$

**Hatırlama (Recall):** genellikle tamlık ölçüsü olarak adlandırılır ve doğru olarak etiketlenen gerçek pozitif tahminlerin yüzdesini gösterir. Aşağıdaki gibi hesaplanır:

$$\text{Hatırlama (Recall)} = \frac{DP}{DP + YN} \quad (8)$$

Dengeli bir veri seti olmadığından doğruluk değerlendirme ölçütü iyi bir ölçüt olmayabilir. Bu gibi durumlarda F1-skoru kullanılır (Demir, 2021). Çünkü F1-skoru sonuçları her bir hedef sınıfa göre sağlar. Sınıflandırıcının hem kesinliğini hem de hatırlama ölçütlerini dikkate alan istatistiksel bir sınıflandırma analizi ölçütüdür. Aşağıdaki gibi hesaplanır:

$$F1 - \text{skor} = 2 \frac{\text{Kesinlik} \times \text{Hatırlama}}{\text{Kesinlik} + \text{Hatırlama}} \quad (9)$$

## DENEYLER

Bu çalışmada, BiGRU-CNN ağ modelinin başarısı, modeli oluşturan (GRU, BiGRU, CNN) derin öğrenme mimarileri ve üç farklı makine öğrenmesi algoritması ile karşılaştırılmıştır. Karşılaştırılan makine öğrenmesi sınıflandırıcıları: Destek Vektör Sınıflandırıcısı (SVC- Support Vector Classifier) (Corinna Vladimir, 1995), Rassel Orman (RF-Random Forest) (Pal, 2005) ve Lojistik Regresyon (LR- Logistic Regression) (Hilbe, 2009). Ayrıca, önerilen modelde kullanılan kelime gömme vektörünün performansını karşılaştırılan derin öğrenme modellerini TF-IDF ve Glove kelime temsili yaklaşımlarıyla test ettik. Deneyler Google Collaborate platformunda Python programlama dili kullanılarak test edilmiştir. Deneylerde pandas, keras, numpy ve sklearn python programlama kütüphaneleri kullanılmıştır. Tüm deneyler Intel Core i7 Windows 10 işletim sistemli 16 GB RAM bilgisayarda test edilmiştir.

## DeneySEL Sonuçlar

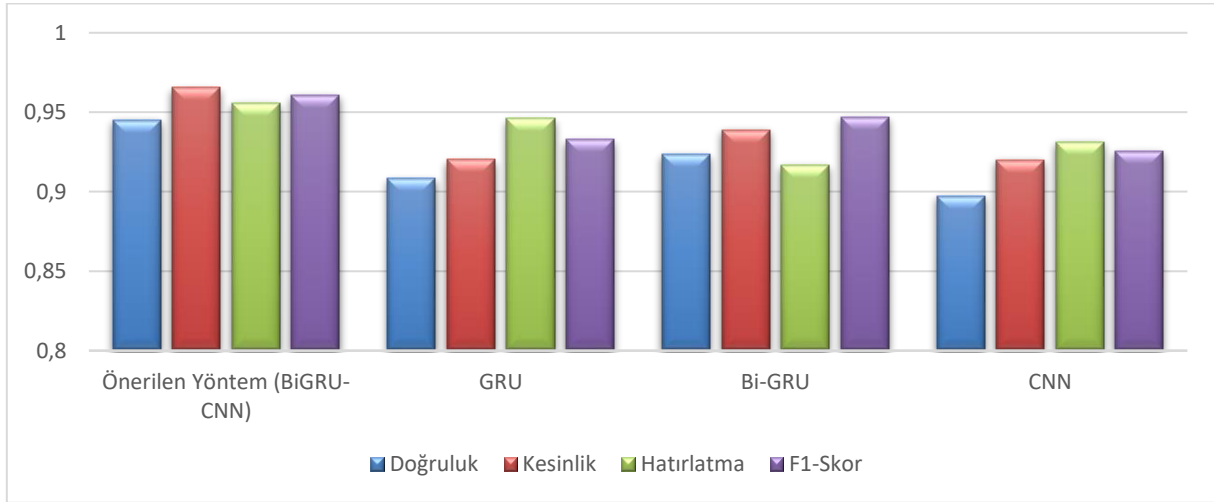
Bu bölümde, MAXQDA nitel veri analizi aracılığıyla Twitter’den Covid-19 aşı uygulamaları hakkında paylaşılan tweetleri toplayarak oluşturduğumuz veri kümesi üzerinde makine ve derin öğrenme sınıflandırıcıları ile elde edilen sonuçlar sunulmuştur.

Şekil 8, önerilen modelin kendini oluşturan derin sinir ağı modelleriyle karşılaştırılmasını göstermektedir. Şekil 8’ de görüldüğü gibi, önerilen


Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486

model diğer tüm modellere kıyasla en büyük başarı oranına sahiptir. CNN, yerel konumda değişmeyen özellikleri yakalamada iyidir, ancak bir cümlede kelime sırası bilgisini yakalamada başarısız olur. Bu, bir cümlenin anlamsal temsilini önemli ölçüde düşürür. Bu nedenle, CNN modelinin deneysel sonuçları her iki kelime gömme yaklaşımı için de diğer modellere kıyasla daha düşük performansa sahiptir. GRU ve BiGRU modellerinin deneysel sonuçları incelendiğinde BiGRU modelinin daha yüksek performansa sahip olduğu görülür. Bunun en önemli nedeninin, BiGRU modelinin tweetleri sırasıyla ileri ve geri yönde okuması sayesinde

tweetlerdeki kelimelerin daha etkili bağlamsal özelliklerini, anlamsal özelliklerini ve gramer özelliklerini çıkarmasından kaynaklı olduğu öngörülür. Şekil 9, Glove ve TF-IDF kelime gömme vektörlerinin doğruluk değerlendirme ölçütüne göre karşılaştırılmasını göstermektedir. Karşılaştırılan tüm derin öğrenme modelleri için Glove kelime gömme yaklaşımının TF-IDF kelime yaklaşımına dayalı eğitilen varyasyonlarından daha yüksek performansta olduğu açıkça görülmektedir. Tüm bu sebeplerden kaynaklı önerilen modelimizde kelime gömme yaklaşımı olarak Glove tercih edilmiştir.



Şekil 8. Önerilen Modelin Kendini Oluşturan Derin Sinir Ağı Modelleriyle Performans Karşılaştırılması

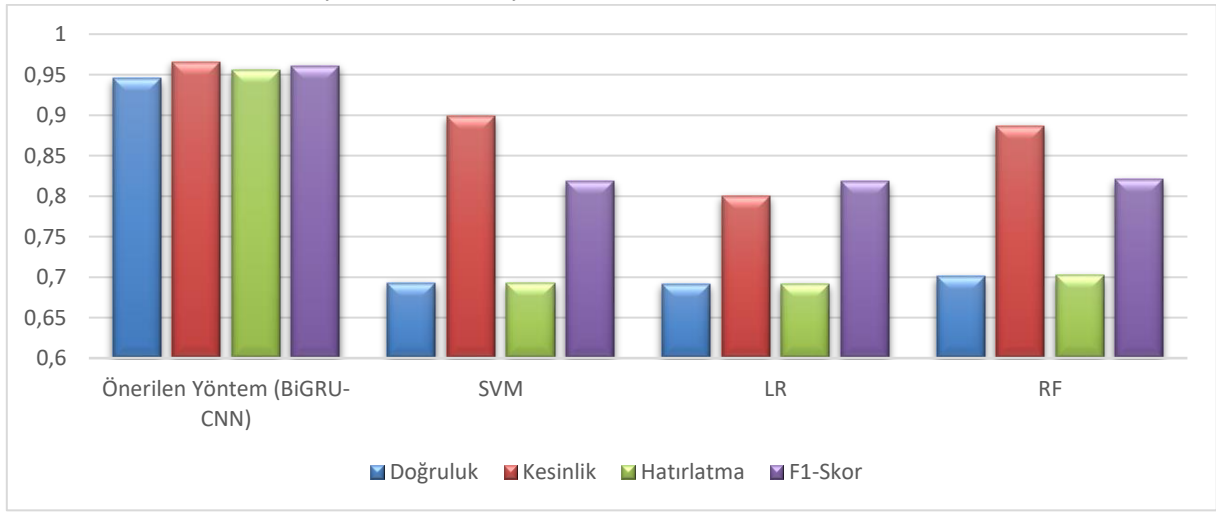


Şekil 9. Farklı Kelime Gömme Vektörlerine göre Önerilen Modelin Kendini Oluşturan Derin Sinir Ağı Modelleriyle Doğruluk Performansı Karşılaştırılması


Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486

Şekil 10, önerilen modelin temel makine öğrenmesi algoritmalarıyla performans karşılaştırmasını göstermektedir. Şekil 10'dan da görüldüğü gibi derin öğrenme tabanlı algoritmalarla karşılaştırıldığında makine öğrenmesi algoritmalarının ciddi bir performans zayıflığı vardır. Bunun en önemli nedeni, makine öğrenmesi yöntemlerinde öğrenme işlemi küçük adımlara bölünüp, her adımın sonuçları tek bir çıktıda birleştirilirken derin öğrenme yöntemlerinde öğrenme işlemi uçtan uca ilerleyerek işlenir. Ayrıca

makine öğrenmesi yöntemleri, sonuç yanlış olduğu zaman öğretilmeye gereksinim duyarken derin öğrenme yöntemleri sinir ağlarının çok seviyeli katmanları sayesinde veriyi farklı kavramlardan oluşan hiyerarşiye yerleştirip, kendi hatalarından öğrenme sağlar. Şekil 11, önerilen modelin ve karşılaştırma yapılan temel makine öğrenmesi algoritmalarının Glove ve TF-IDF kelime gömme vektörlerinin doğruluk değerlendirme ölçütüne göre karşılaştırılmasını göstermektedir.



Şekil 10. Önerilen Modelin Makine Öğrenmesi Modelleriyle Karşılaştırılması



Şekil 11. Farklı Kelime Gömme Vektörlerine göre Önerilen Modelin Makine Öğrenmesi Modelleriyle Doğruluk Performansı Karşılaştırılması



Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1087486

## TARTIŞMA

Çalışmamızda, geleneksel makine öğrenimi ve derin öğrenme algoritmalarından farklı olarak hibrit bir derin öğrenme (BiGRU-CNN) modeli öneriyoruz. Bu model, yerel konumda değişmeyen kelime özelliklerinin yanında sıralı bilgileri ve uzun mesafe bağımlılıklarını da yakalayabilir. CNN modelinden önce uygulanan BiGRU modeli, CNN'nin daha etkili özellikler çıkarmasını sağlamaktadır. Kapsamlı deneyler, önerilen modelin daha iyi performans gösterdiğini kanıtlamaktadır. Bu başarı, BiGRU modelinin tweetleri sırasıyla ileri ve geri yönde okuması sayesinde tweetlerdeki kelimelerin daha etkili bağlamsal özelliklerini, anlamsal özelliklerini ve gramer özelliklerini çıkarabilmesinden kaynaklanmaktadır.

Bu çalışma, 16 Haziran 2021 ve 18 Eylül 2021 arasında Twitter'dan toplanan COVID-19 aşılılarıyla ilgili Türkçe tweet'lerin kapsamlı bir analizini yaptı. Bu çalışma için toplam 176345 Covid-19 aşılılarıyla ilgili paylaşılan tweet kullanıldı. Duygu analizi sonuçları, genel duygu polaritesinin pozitif olduğunu ve pozitif tweetlerin sayısının, negatif tweetlerin sayısının yaklaşık iki katı olduğunu gösterdi. Bu çalışmanın deneysel sonuçları, aşılama ile ilgili paylaşılan uygunsuz, eksik ve hatalı bilgilerin tespiti kolaylaştıracaktır. Bu sayede, aşı kararsızlığı yaşayan bireylerinin aşı karşıtlığına eğilim göstermesinin önüne geçilebilecektir. Çalışmadan elde edilen sonuçlar, toplumun uygulanan aşılarla bakış açısını genişletecek ve aşıyla ilgili paylaşılan olumsuz içerikli tweetlerin tespitini kolaylaştıracaktır. Bu sayede, hükümet ve sağlık kurumlarının salgınla mücadelenin kilidi olan aşılama çalışmalarını daha verimli uygulayabilecektir. Covid-19'la mücadelenin kilidi olan aşı sayesinde, pandeminin bir an önce kontrol altına alınacağını ve normal hayata dönebileceğini umuyoruz. Gelecekte, mevcut çalışmaya dayalı olarak sahte hesapları ve yanlış bilgileri tespit edip sosyal medyaya müdahale etmek için derin öğrenme tabanlı optimal bir sistem geliştirilmesi planlanmaktadır.

## ÇIKAR ÇATIŞMASI BEYANI

Yazar bu makale ile ilgili herhangi bir çıkar çatışması bildirmemektedir.

## ARAŞTIRMA VE YAYIN ETİĞİ BEYANI

Yazar bu çalışmanın araştırma ve yayın etiğine uygun olduğunu beyan eder.

## KAYNAKLAR

- Agarwal, A., Xie, B., Vovsha, I., Rambow, O. ve Passonneau, R. J. (2011, June). Sentiment analysis of twitter data. In Proceedings of the workshop on language in social media (LSM 2011) (pp. 30-38).
- Alicılar, H. E. ve Meltem, Ç. Ö. L. (2021). Yeni Koronavirüs Hastalığına Karşı Aşılama Tutumu. Yeni Koronavirüs Pandemisi Sürecinde Türkiye'de Covid-19 Aşılması Ve Bağışıklama Hizmetlerinin Durumu, 61.
- Ashraf, I., Hur, S. ve Park, Y. (2018). BLocate: A building identification scheme in GPS denied environments using smartphone sensors. *Sensors*, 18(11), 3862.
- Aygün, İ., Kaya, B. ve Kaya, M. (2021). Aspect Based Twitter Sentiment Analysis on Vaccination and Vaccine Types in COVID-19 Pandemic with Deep Learning. *IEEE Journal of Biomedical and Health Informatics*.
- Baccianella, S., Esuli, A. ve Sebastiani, F. (2010, May). Sentiwordnet 3.0: An enhanced lexical resource for sentiment analysis and opinion mining. In Proceedings of the Seventh International Conference on Language Resources and Evaluation (LREC'10).
- Badgujar, K. C., Badgujar, V. C. ve Badgujar, S. B. (2020). Vaccine development against coronavirus (2003 to present): An overview, recent advances, current scenario, opportunities and challenges. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*.
- Barkur, G. ve Vibha, G. B. K. (2020). Sentiment analysis of nationwide lockdown due to COVID 19 outbreak: Evidence from India. *Asian journal of psychiatry*, 51, 102089.
- Bradley, M. M. ve Lang, P. J. (1999). Affective norms for English words (ANEW): Instruction manual and affective ratings (Vol. 30, No. 1, pp. 25-36). Technical report C-1, the center for research in psychophysiology, University of Florida.
- Cabanillas, B. ve Novak, N. (2021). Allergy to COVID-19 vaccines: a current update. *Allergology International*, 70(3), 313-318.

Research article/Araştırma makalesi  
 DOI:10.29132/ijpas.1087486

- Cambria, E., Havasi, C. ve Hussain, A. (2012, May). Senticnet 2: A semantic and affective resource for opinion mining and sentiment analysis. In Twenty-Fifth international FLAIRS conference.
- Chakraborty, K., Bhatia, S., Bhattacharyya, S., Platos, J., Bag, R. ve Hassanien, A. E. (2020). Sentiment Analysis of COVID-19 tweets by Deep Learning Classifiers—A study to show how popularity is affecting accuracy in social media. *Applied Soft Computing*.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. ve Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.
- Cortes Corinna, Vapnik Vladimir. Support-vector networks. *Machine learning*. 1995; 20(3):273–297.
- Depoux, A., Martin, S. ve Karafillakis, E. (2020). Raman Preet, Annelies Wilder-Smith, and Heidi Larson. The pandemic of social media panic travels faster than the covid-19 outbreak.
- Demir, F. (2021). L1-Norm DVM ve Ki-Kare Tabanlı Öznitelik Seçme Algoritmaları ile Parkinson Hastalığının Konuşma Sinyalleri Üzerinden Saptanması. *International Journal of Pure and Applied Sciences*, 7(1), 32-40.
- Duncan, B. ve Zhang, Y. (2015, July). Neural networks for sentiment analysis on Twitter. In 2015 IEEE 14th International Conference on Cognitive Informatics & Cognitive Computing (ICCI\* CC) (pp. 275-278). IEEE.
- Feng, Y. ve Zhou, W. (2020). Is working from home the new norm? an observational study based on a large geo-tagged covid-19 twitter dataset. arXiv preprint arXiv:2006.08581.
- Go, A., Bhayani, R. ve Huang, L. (2009). Twitter sentiment classification using distant supervision. CS224N project report, Stanford, 1(12), 2009.
- Han, J., Pei, J. ve Kamber, M. (2011). *Data mining: concepts and techniques*. Elsevier.
- Hilbe, J. M. (2009). *Logistic regression models*. Chapman and hall/CRC.
- Hornung, O., Dittes, S. ve Smolnik, S. (2018). When emotions go social—understanding the role of emotional intelligence in social network use. <https://covid19.saglik.gov.tr/> (accessed 12 march, 2022).
- Hu, M. ve Liu, B. (2004, August). Mining and summarizing customer reviews. In Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 168-177).
- Hu, M. ve Liu, B. (2004, August). Mining and summarizing customer reviews. In Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 168-177).
- Investor fact sheet. Twitter. 2021. [29-04-2021] [https://s22.q4cdn.com/826641620/files/doc\\_financials/2021/q1/Q1'21-Shareholder-Letter.pdf](https://s22.q4cdn.com/826641620/files/doc_financials/2021/q1/Q1'21-Shareholder-Letter.pdf).
- Jelodar, H., Wang, Y., Orji, R. ve Huang, S. (2020). Deep sentiment classification and topic discovery on novel coronavirus or COVID-19 online discussions: NLP using LSTM recurrent neural network approach. *IEEE Journal of Biomedical and Health Informatics*.
- Joshi, R. ve Tekchandani, R. (2016, August). Comparative analysis of Twitter data using supervised classifiers. In 2016 International conference on inventive computation technologies (ICICT) (Vol. 3, pp. 1-6). IEEE.
- Kamyab, M., Liu, G. ve Adjeisah, M. (2021). Attention-Based CNN and Bi-LSTM Model Based on TF-IDF and GloVe Word Embedding for Sentiment Analysis. *Applied Sciences*, 11(23), 11255.
- Kwok, S. W. H., Vadde, S. K. ve Wang, G. (2021). Twitter Speaks: An Analysis of Australian Twitter Users' Topics and Sentiments About COVID-19 Vaccination Using Machine Learning. *Journal of Medical Internet Research*.
- Li S, Wang Y, Xue J, Zhao N ve Zhu, T. The impact of COVID-19 epidemic declaration on psychological.
- Loria, S. (2018). textblob Documentation. Release 0.15, 2, 269.
- Lu, X. ve Zhang, H. (2021). Sentiment analysis method of network text based on improved at-bigru model. *Scientific Programming*, 2021.
- Madasu, A. (2019). A Study of Feature Extraction techniques for Sentiment Analysis. arXiv preprint arXiv:1906.01573.
- Ortiz-Sánchez, E., Velando-Soriano, A., Pradas-Hernández, L., Vargas-Román, K., Gómez-Urquiza, J. L., Cañadas-De la Fuente, G. A. ve Albendín-García, L. (2020). Analysis of the anti-vaccine movement in social networks: a systematic review. *International journal of environmental research and public health*, 17(15), 5394.
- Pang, B. ve Lee, L. (2004). A sentimental education: Sentiment analysis using subjectivity summarization based on minimum cuts. arXiv preprint cs/0409058.
- Pano, T. ve Kashef, R. (2020). A complete VADER-based sentiment analysis of bitcoin (BTC) tweets during the era of COVID-19. *Big Data and Cognitive Computing*, 4(4), 33.

Research article/Araştırma makalesi  
DOI:10.29132/ijpas.1087486

- Parikh, R. ve Movassate, M. (2009). Sentiment analysis of user-generated twitter updates using various classification techniques. CS224N Final Report, 118.
- Pennebaker, J. W., Boyd, R. L., Jordan, K. ve Blackburn, K. (2015). The development and psychometric properties of LIWC2015.
- Pennington, J., Socher, R. ve Manning, C. D. (2014, October). Glove: Global vectors for word representation. In Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP) (pp. 1532-1543).
- Rehman, M., Tauseef, I., Aalia, B., Shah, S. H., Junaid, M. ve Haleem, K. S. (2020). Therapeutic and vaccine strategies against SARS-CoV-2: past, present and future. *Future Virology*, 15(7), 471-482.
- Sohangir, S., Petty, N. ve Wang, D. (2018, January). Financial sentiment lexicon analysis. In 2018 IEEE 12th international conference on semantic computing (ICSC) (pp. 286-289). IEEE.
- Süral, I., Griffiths, M. D., Kircaburun, K. ve Emirtekin, E. (2019). Trait emotional intelligence and problematic social media use among adults: The mediating role of social media use motives. *International Journal of Mental Health and Addiction*, 17(2), 3.
- Şengür, D. (2019). KOVID-19 Salgını Sırasında Öğrencilerin Öğrenme Alışkanlıklarının Schur Ayrıştırma Tabanlı Dalgacık Aşırı Öğrenme Makineleri ile Tahmini. *International Journal of Pure and Applied Sciences*, 7(1), 13-18.
- Trapani, D. ve Curigliano, G. (2021). COVID-19 vaccines in patients with cancer. *The Lancet Oncology*, 22(6), 738-739.
- We used MAXQDA 2020 (VERBI Software, 2019) for data analysis.
- World Health Organization. Mental Health and Psychosocial Considerations during the COVID-19 Outbreak. Available online: 1 November 2020.
- Worldometer. Available online: [https://www.worldometers.info/coronavirus/?utm\\_campaign=homeAdvegas1?](https://www.worldometers.info/coronavirus/?utm_campaign=homeAdvegas1?) (accessed on 14 March 2022).
- Xue, J., Chen, J., Hu, R., Chen, C., Zheng, C., Su, Y. ve Zhu, T. (2020). Twitter discussions and emotions about the COVID-19 pandemic: Machine learning approach. *Journal of medical Internet research*, 22(11), e20550.
- Yan, L. C., Yoshua, B. ve Geoffrey, H. (2015). Deep learning. *nature*, 521(7553), 436-444.