



## Olağandışı Olaylar Hakkındaki Tweet'lerin Gerçek ve Gerçek Dışı Olarak Google BERT Modeli ile Sınıflandırılması

Onur SEVLİ<sup>1\*</sup>, Nazan KEMALOĞLU<sup>2</sup>

<sup>1</sup>Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği, Burdur

<sup>2</sup>Burdur Mehmet Akif Ersoy Üniversitesi, Bilgi Teknolojileri Uygulama ve Araştırma Merkezi, Burdur

### Özet

İnsanlar yanlarında taşıyabildikleri internet erişimi olan cihazlar ile gözlemledikleri her tür olağan ya da olağandışı durumu gerçek zamanlı olarak sosyal ağlarda paylaşabilmektedir. Twitter, bu konuda yaygın olarak kullanılan ve pek çok olağandışı durumun ilk duyulduğu sosyal ağlardandır. Bu anlamda acil müdahale ekipleri ve medya şirketleri için popüler bir haber kaynağıdır. Ancak yapılan paylaşımların her zaman gerçek bir olağan dışı durumu belirttiği açık değildir. Doğal dil işleme, insanların konuştukları dillerin makineler tarafından yorumlanabilmesine olanak tanır. Google BERT modeli, iki yönlü olarak kelimeler ve cümleler arasındaki bağlamsal ilişkileri yapay sinir ağları temelinde etkin bir şekilde ortaya koyan bir doğal dil işleme modelidir. Gerçekleştirilen çalışmada deprem, kaza, olumsuz hava olayları gibi felaket durumları hakkında atılan 7613 adet gerçek veya gerçek dışı olarak etiketlenmiş tweet içeren veri seti Bert modeli kullanılarak sınıflanmıştır. Gerçekleştirilen eğitim süreci sonunda %98.8 doğruluk elde edilmiştir.

**Anahtar Kelimeler:** Twitter Veri Analizi, Makine Öğrenmesi, Doğal Dil İşleme, Google BERT

## Classification of Tweets about Disasters as Real or Unreal by Google BERT Model Abstract

### Abstract

People can share any ordinary or unusual situation they observe on social networks in real-time with devices that have internet access. Twitter is one of the social networks that are widely used in this field and where many unusual situations take place for the first time. In this way, it is a popular news source for emergency teams and media companies. However, it is not clear that the shares always indicate a real disaster. Natural language processing allows the languages that people speak to be interpreted by machines. Google BERT is a natural language processing model that effectively demonstrates two-dimensional contextual relationships between words and sentences based on artificial neural networks. In this study, 7613 real or unreal tagged tweets about disaster situations such as earthquakes, accidents, adverse

<sup>1\*</sup> İletişim e-posta: onursevli@mehmetakif.edu.tr

<sup>\*\*</sup> Bu çalışmanın bir kısmı III. International Conference on Data Science and Applications 2020'de sözlü olarak sunulmuştur.

weather events were classified using the Bert model. 98.8% accuracy was obtained as a result of the training process.

**Keywords:** *Twitter Data Analysis, Machine Learning, Natural Language Processing, Google BERT*

## 1 Giriş

Akıllı telefon ve internet kullanımının yaygınlaşması ile birlikte insanlar günlerinin büyük bir kısmını internette geçirme olanağına kavuşmuştur. Kullanıcıların internette en çok vakit geçirdikleri mecralardan biri de sosyal ağlardır. Sosyal ağlar, tek taraflı bilgi paylaşımından eş zamanlı ve çok yönlü bilgi paylaşımına geçişi sağlayan, zaman ve mekân kısıtlaması olmadan paylaşım yapmaya imkân veren iletişim ortamlarıdır. İngiliz medya şirketi WeAreSocial ve Kanada merkezli sosyal medya yönetim şirketi Hootsuite'in hazırladığı 2020 yılı "Global Dijital Raporu"na göre dünyadaki internet erişimi olan kişi sayısı 2020 yılında 2019 yılına oranla %7 artarak 4.5 milyara yükselmiştir. Yine bu rapora göre 2019 yılında 3.4 milyar olan sosyal medya kullanıcı sayısı 2020'de 3.8 milyara ulaşmıştır. Bir kullanıcı gününün ortalama 7 saate yakını internette geçirmektedir [1].

Sosyal ağlar artan kullanıcı sayıları ve buna paralel artan paylaşımlarla her an büyük miktarda veri üretmektedir. Sosyal ağlar internet erişimi olan her kullanıcı için erişilebilirdir ve her kullanıcı özgür şekilde, bir sınırlama olmaksızın paylaşım yapabilmektedir. Sosyal ağ içerikleri bağımsız kullanıcılar tarafından üretildiği ve belli bir otorite tarafından denetlenmediği için bireysel fikirler ön plana çıkmaktadır. Bunun sonucu objektif gerçeklerden sübjektif fikirlere doğru bir geçiş olmaktadır. İnsanlar o an içinde buldukları durumu, kendi ruh halleri ve düşünceleri ile paylaşımlarına yansıtılmaktadır.

Yaygın kullanılan sosyal ağlardan biri olan Twitter 2006 yılında Jack Dorsey tarafından kurulan bir mikroblog sitesidir. Kullanıcılarına 280 karakterden oluşan "tweet" adı verilen paylaşımlar yapma imkânı sağlayan Twitter, bu özelliğinden dolayı internet dünyasının kısa mesaj servisi rolünü üstlenir. Kullanıcılar Twitter' a resmi web sayfası üzerinden erişebildiği gibi üçüncü parti uygulamalar, mobil yazılımlar ile de erişebilmektedir. 2019 yılı ikinci yarısı itibarıyla günlük 152 milyon aktif kullanıcısı olan Twitter' a,

kullanıcıların %80'i mobil uygulamalar ile erişmekte ve günlük 500 milyondan fazla paylaşım yapmaktadırlar [2].

Bilgi edinmek, bilgi yaymak, diğer kullanıcılar ile etkileşim kurmak gibi farklı amaçlarla kullanılan Twitter, kullanıcıların yanlarında taşıyabildikleri internet erişimi olan akıllı cihazlar sayesinde o an yaşadıkları deneyimleri, içinde buldukları durumları kendi gözlerinden ifade etme olanağı sağlamaktadır. Kullanıcılar o an deneyimledikleri olağan ya da olağan dışı durumları gerçek zamanlı olarak Twitter üzerinde paylaşabilmektedir. Bu anlamda Twitter olağandışı durumların, afetlerin, toplumsal hareketlerin duyulmasında geleneksel medyaya göre daha hızlıdır. Buna bir örnek olarak 2011 yılı Arap baharına ilişkin verilerin televizyon, radyo gibi geleneksel medya araçlarından daha önce Twitter' da duyulması örnek gösterilebilir [3].

Twitter, olağan dışı durumların paylaşımında sıklıkla kullanılan popüler platformlardan biridir. Twitter kullanıcıları kasırga, fırtına, deprem, kaza ve diğer acil durumların haberlerini, fotoğraflarını ve gözlemlerini gerçek zamanlı olarak paylaşmaktadır. Bu anlamda acil müdahale ekipleri, afetlerin nerede meydana geldiğini ve çevreye olan etkilerini bulmak için Twitter gibi sosyal ağlarda üretilen veri akışlarından yararlanmaktadır. Yine pek çok medya şirketi haber niteliği taşıyan olaylara ilişkin bilgilere hızla ulaşmak için sosyal ağları izlemektedir. Ancak çok kısa sürede yapılan milyonlarca paylaşımı manuel olarak takip edip işlemek son derece zahmetlidir. Bu nedenle acil yardım kuruluşları ve medya şirketleri sosyal ağ analizi için yazılımlara başvurmaktadır. Bu yazılımlar insan rolünü üstlenerek verileri filtreleme, analiz etme, sınıflama, anlamlandırma, çıkarım üretme gibi fonksiyonları yerine getirmektedir. Bu amaçla da yapay zekâ tekniklerinden sıklıkla yararlanmaktadır.

Yapay zekâ, insan düşünme sistemini taklit ederek, makinelerin belirli durumlar karşısında insana benzer çıkarımlar yapmalarını sağlamayı amaçlayan bir disiplindir. Yapay zekânın bir alt dalı olan makine öğrenmesi ve insanlara ait dillerin

makinelere tarafından yorumlanmasını sağlayan doğal dil işleme teknikleri belirli bir konu alanına ilişkin sosyal ağ verilerinin çıkarılması, işlenmesi ve sınıflandırılmasında büyük avantajlar sağlamaktadır.

Makine öğrenmesi eldeki mevcut veri setleri üzerinden eğitilerek, veriler üzerinde tespit edilen ilişkiler ile yeni karşılaşılan durumlar hakkında çıkarımlar yapabilen teknikler bütünüdür. Bu tekniklerden biri olan doğal dil işleme insanlar tarafından konuşulan dillerin makinelere tarafından anlamlandırılmasına yönelik çalışmaları kapsar. Doğal dil işleme süreci bir cümle içerisindeki kelimelerin ilişki ağını ortaya koyarak, kategorizasyon, kavram çıkarımı, özetleme, çeviri gibi dilsel işlemleri makinelere aracılığı ile gerçekleştirmeye çalışır.

Twitter gibi sosyal ağlar, doğal afetler konusunda müdahale hızını ve verimliliğini artırmaya yardımcı olabilecek değerli bilgiler içerir [4]. Makine öğrenmesi, veri madenciliği ve doğal dil işleme, çeşitli sınıflandırma kriterlerine göre tweet' lere öncelik vererek, verilerin filtrelenmesine yardımcı olur.

Cheong vd. 2010-2011 Avustralya sel baskınları sırasındaki önemli olayları kümelemek için sosyal medya metriklerinden yararlanmışlardır [5]. Mandel vd., Irene kasırgası esnasında atılan tweet' leri makine öğrenmesi teknikleri ile sınıflandırarak, Twitter mesaj sayılarının kasırganın şiddetlendiği dönemler ile korele olduğunu ve mesajlardaki kaygı düzeyinin coğrafik konuma bağlı olarak değiştiğini ortaya koymuşlardır [6]. Caragea vd., Sandy kasırgası sırasında Twitter' da kullanıcı mesajlarının duygu sınıflandırmasını gerçekleştirerek, duyguları kasırga merkezli bir coğrafik haritada görselleştirmişlerdir [7].

Guevara vd., daha önce meydana gelen felaketlerden yola çıkarak oluşturdukları veriler ile alan uyarlaması yoluyla yeni bir afet konusunda atılan tweet' leri sınıflamaya yönelik bir çalışma önermişlerdir [8]. Imran vd. makine öğrenmesi teknikleri kullanarak afetler hakkında atılan tweet' leri dikkat, tavsiye, hasar, yardım gibi kategorilere sınıflandırmışlardır [9].

Ashktorab vd., Twitter'ın kurulduğu 2006 yılından itibaren 2014 yılına kadar Kuzey Amerika'da gerçekleşen 12 farklı doğal felaket ile ilgili tweet' leri analiz etmişlerdir. Müdahale ekiplerinin çalışmalarına yardımcı olacak çıkarımlar yapmak için sınıflandırma ve kümeleme yöntemlerinin bir

kombinasyonunu kullanmışlardır [10]. Kireyev vd. konu tabanlı kümeleme ve görselleştirme, kavram seçimi, ağırlıklandırma ve dinamik korpus arıtımı ismini verdikleri yeni bir teknik kullanarak sosyal medyada paylaşılan felaket haberleri üzerinde sınıflama yapmışlardır [11].

Vieweg vd., Twitter kullanımındaki artış ve platformdan bağımsız şekilde hızlı iletişim olanağı sunmasının afet mağdurları ile yardım ekipleri arasındaki etkileşimi kolaylaştırdığını bildirmişlerdir [12]. Kumar vd. afetler sırasında acil müdahaleye yardımcı olmak için tweet' ler üzerinden konum ve belirli anahtar kelimelerin sınıflandırılmasını gerçekleştirmişlerdir [13].

Tweet'lerin makine öğrenmesi ve doğal dil işleme yöntemleri ile analiz edilerek; kullanıcıların deneyimledikleri olaylar, olağan dışı ve acil durumlar hakkında çıkarım yapılması mümkündür. Bu bağlamda literatürdeki çalışmalar incelendiğinde sosyal ağlar ve özellikle Twitter'ın, olağandışı durumlarında bilginin hızlı yayılmasına ve acil müdahale ekiplerinin işlerinin kolaylaşmasına katkı sağladığı görülmektedir. Ancak bu noktada kullanıcılar tarafından yapılan paylaşımların güvenilirliği ve gerçekten kayda değer bir durumu ifade edip etmediğinin ortaya konması önemlidir.

Kimi zaman dilsel ifadelerden kaynaklı durumlar, kimi zaman da doğal afetlerin karmaşık bir doğasının olması ve ifade edilmesindeki zorluklardan dolayı tweet içerisinde bahsedilen konunun doğru anlaşılması zorlaşmaktadır. Doğal dil içerisinde kullanılan benzetmeler, dil sanatları, ironik yapılar cümlenin gerçek anlamından farklı çıkarımlar yapılmasına neden olmaktadır. Bu durumda sadece belirli kelime ya da kalıplara bakarak çıkarım yapmaya çalışmak sağlıklı sonuçların üretilmesine engel olacaktır. Bunun için, belirli bir konu alanında yapılacak çalışmalar için makineye doğru ve yanlış kalıpların daha önceden öğretilmesi sağlıklı sonuçlara ulaşması açısından önem arz etmektedir.

Gerçekleştirilen çalışmada, içerisinde deprem, sel, kaza, olumsuz hava olayları gibi felaket durumları hakkında paylaşılan 7613 adet tweet ile sınıflandırma çalışması gerçekleştirilmiştir. Veri seti içerisinde yer alan tweet'lerin bazıları gerçek bir felaket durumunu ifade ederken bazıları bağımsız kelimeler açısından bir felaket olarak nitelenebilecekken bütün itibarıyla felaket olmayan bir durumu ifade etmektedir. Felaketler konusunda

gerçek ve gerçek dışı olarak işaretlenmiş bu veri kümesi Google tarafından geliştirilen doğal dil işleme modeli BERT ile sınıflandırılmıştır.

## 2 Materyal ve Metod

### 2.1 Doğal Dil İşleme (Natural Language Processing - NLP)

Doğal diller, düşünceleri ifade etmek, iletişim kurmak için insan toplulukları tarafından kullanılan sözcükler ve gramer kurallarını içinde barındırır. İnsanlar kavramlarla düşünür, kavramlar üzerinden iletişim kurar. Oysa bilgisayarlar matematiksel kurullarla çalışan makinelerdir. Kısa zamanda çok sayıda hesaplama yapabilseler de insanların kolaylıkla anlayabildiği karmaşık dilsel yorumlamalardan yoksundurlar. Ancak bilgisayarlar doğal dilleri insanlar gibi yorumlayamasalar da sınıflandırma ve çeviri işlemlerini başarı ile gerçekleştirebilirler.

Makine öğrenimi dünyasındaki en etkileyici gelişmelerden biri, bir makineye insan iletişimini nasıl anlayacağını öğrenme becerisi katmaktır. Makine öğrenmesinin bu alanına “Doğal Dil İşleme” denir. Doğal dil işleme bilgisayarların doğal dil metinlerini veya konuşmayı anlamak için nasıl kullanılabileceğini araştıran bir disiplindir. Doğal dil işleme araştırmacıları, insanların doğal dili nasıl anladığı ve kullandıkları hakkında edindikleri bilgilerle, bilgisayar sistemlerinin doğal dilleri anlaması ve düzenlemesini sağlamak amacıyla uygun araçlar ve teknikler geliştirmektedir [14].

Bilgisayarların doğal dili anlamlandırabilmesi için, dilin modellenen matematiksel bir çerçeveye dönüştürülmesi gerekir. Bu amaçla kullanılan tekniklerden belli başlıları şunlardır:

**Dizelere ayırma (Tokenization):** Bir metni kelimelere bölme işlemidir. Herhangi bir araç kullanarak bölme yapılabileceği gibi genelde boşluk karakterine göre bölme yapılır. Bütün halindeki metin bölme işlemi ardından çok elemanlı bir sözcük dizisine dönüşür.

**Durak ifadelerin (stop words) kaldırılması:** Metin içerisindeki bağlaçların, niteleyicilerin, tek başına anlamsal katkısı olmayan sözcüklerin temizlenmesi işlemidir. Bu işlem esnasında kullanılmayan rakamlar, noktalama işaretleri, yeni satır (\n), tab (\t), başa dönme (\r) gibi özel karakterlerin temizliği de gerçekleştirilir.

**N-Gram:** N sayısına bağlı olarak sıralı sözcükleri öbeklemek için kullanılır. Örneğin “Doğal dil işleme teknikleri” cümlesini ele alırsak;

1-gram veya unigramlar bir kelimeli gruplardır: “Doğal, dil, işleme, teknikleri”.

2-gram veya bigramlar ise iki kelimeli gruplardır: “Doğal dil, dil işleme, işleme teknikleri”.

Benzer şekilde 3-gram (trigram) ve n sayısına bağlı olarak n-gramlar oluşturulur.

**Kelime vektörü, ağırlıklandırma ve skorlama:** Metin içerisinde n-gram yöntemleri ile oluşturulan vektörlerin kodlanması için belirli skorlama ve ağırlıklandırma teknikleri kullanılır:

- One-hot encoding: Kelimenin varlığı veya yokluğuna göre 1, 0 şeklinde yapılan ikili ağırlıklandırma işlemidir. Kelime sözlüğünün tümü bir bütün olarak yerleştirilip, bağımsız her bir kelime bir satır olacak şekilde yazılır. Her bir kelimenin sözlük içinde gözlemlendiği sütunlara 1, diğer kısımlara 0 yazılarak elde edilir.
- Terim sıklığı (term frequency -TF): Bir doküman içerisinde belirli terimlerin ne kadar sık yer aldığını hesaplamak için kullanılan yöntemlerdir. Çeşitli frekans ve normalizasyon formülleri kullanılarak hesaplama yapılır.

### 2.2 Google BERT (bidirectional encoder representations from transformers) modeli

BERT, Google yapay zekâ grubu araştırmacıları tarafından geliştirilen, açık kaynak kodlu, önceden eğitilmiş bir doğal dil işleme modelidir [15]. 2015 yılında Rankbrain [16] algoritmasını makine öğrenmesi ile destekleyerek arama sonuçlarında insan mantığına en yakın ve doğru cevapları filtrelemeyi sağlayan Google, 2019 yılında BERT güncellemesini sunarak sorgu kelimelerini ayrı ayrı işlemek yerine tümünü mantıksal bir bütün olarak değerlendirip daha doğru sonuçlara ulaşmayı sağlamıştır. Yapay sinir ağlarını kullanan BERT her bir kelimenin, iki yönlü olarak, diğer kelimelerle olan ilişkilerini ortaya koyar. Diğer dil işleme modellerinden farklı olarak BERT, tüm katmanlarda hem sol hem de sağ bağlamda birlikte koşullandırılarak etiketlenmemiş metinden derin çift yönlü gösterimleri çıkarmak için tasarlanmıştır. BERT bir transfer öğrenme modelidir. Transfer öğrenme daha önceden eğitilmiş olan bir ağın bilgilerini benzer problemleri çözmek için bir başka ağa aktararak kullanmaktır. Eğitim sürecini hızlandırarak yüksek performans elde etmeyi sağlayan transfer öğrenme bilgisayarlı görüş

alanında yaygın olarak kullanılmakta olup BERT modeli ile doğal dil işleme alanında da başarılı sonuçlar verebileceği ortaya konmuştur. Önceden eğitilmiş BERT modeline ihtiyaca uygun bir çıkış katmanı eklenerek dil işleme konusunda klasik doğal dil işleme yöntemlerine göre çok daha performanslı sonuçlar ortaya konulabilmektedir. BERT kavramsal olarak basit, uygulamada ise son derece güçlüdür.

BERT bağlamsal sınırlamaların üstesinden gelmek ve çift yönlü birlikteliği ortaya koymak için temel iki öğrenme stratejisi kullanır:

### 2.2.1 Maskeli dil modelleme (masked language modelling - MLM)

Kelime dizileri BERT modeline aktarılmadan önce, %15'lik kısmı [MASK] belirteci ile değiştirilir. Daha sonra model, dizideki diğer maskelenmemiş kelimelerin oluşturduğu bağlama dayanarak maskelenen kelimelerin orijinal değerini tahmin etmeye çalışır.

### 2.2.2 Sıradaki cümle tahmini (next sentence prediction - NSP)

BERT eğitim sürecinde, modele cümle çiftlerini girdi olarak alır. Çiftteki ikinci cümle belgenin içerisinde sonraki cümle olup olmadığını tahmin etmeyi öğrenir. Modelin eğitimi sırasında girdilerin %50'lik kısmında ikinci cümle orijinal belge içerisinde takip eden cümle olduğu çiftler alınırken, diğer %50'lik kısımda ise ikinci cümle rastgele seçilir. Burada modelin rastgele seçilen cümlelerin ilk cümleyle bağlı olmadığını tespit etmesi beklenir.

## 3 Deneysel çalışma ve Bulgular

Gerçekleştirilen çalışmada kullanılan veri seti Twitter üzerinden derlenen deprem, sel, yangın gibi olağandışı felaket durumlarını ifade eden İngilizce tweet'lerden oluşmaktadır. Veri seti Amerikan yapay zekâ şirketi "Figure Eight" tarafından oluşturularak kendi veri seti paylaşım platformları üzerinden kullanıma sunulmuştur. Paylaşılan tweet'ler metinsel olarak olağandışı durumları ifade eden sözcükler barındırmakla birlikte doğal dil içerisinde kullanılan benzetmeler, dil sanatları, ironik yapılar ya da olağandışı olayların karmaşık yapısından dolayı oluşan ifade güçlükleri nedeni ile bazı tweet'ler gerçek bir felaketi tanımlamamaktadır. Bu nedenle veri seti içerisinde tweet'ler, gerçek bir olağan dışı durumu ifade edip etmemesine göre, uzman bir ekip tarafından gerçek veya gerçek dışı olarak etiketlenmiştir.

Veri seti iki özellik barındırmaktadır:

- Text: Paylaşılan tweet metni
- Target: Tweet gerçek bir olağandışı durumu belirtiyor ise 1, değilse 0 değerini içerir.

Analiz edilen veri seti içerisinde toplam 7613 adet tweet yer almaktadır. Veri seti %80 eğitim, %20 test seti olacak şekilde ayrılmış, eğitim seti içerisinde 6090, test seti içerisinde 1523 adet tweet yer almaktadır.

Veri seti Google BERT modeli kullanılarak analiz edilmiştir. Analiz işlemi öncesinde veri seti model ile işlenmeye hazır olacak şekilde ön işleme sürecinden geçirilmiştir:

- Her bir metin dizgelere ayrılmıştır (tokenization).
- Metin içerisinde yer alan URL, sembol, konum bilgisi gibi analize konu olmayan ifadeler temizlenmiştir.

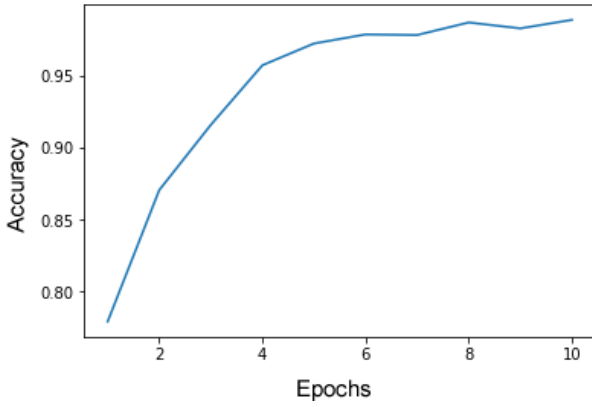
Google BERT modeli bir transfer öğrenme modelidir. Daha önce benzer dil işleme problemleri üzerinden eğitilerek, elde edilen yüksek başarılı ağ parametreleri kaydedilip, daha sonra oluşturulacak modeller için kullanıma sunulmuştur. Google BERT modelinin ağırlık değerleri Tensorflow'un daha önceden eğitilmiş makine öğrenimi model parametrelerini açık olarak kullanıma sunduğu deposu "tfhub" üzerinden elde edilerek çalışmanın modeli oluşturulmuştur.

Oluşturulan model toplam 10 epoch çalıştırılmıştır. Her bir epochtaki doğruluk değerleri kaydedilmiştir. BERT modelinin eğitim süreci diğer doğal dil işleme modellerine nazaran daha uzun sürmektedir. Çalışma bulut ortamında NVIDIA Tesla P100 GPU hızlandırması ile 12 GB RAM, Intel Xeon işlemci üzerinde çift çekirdekli gerçekleştirilmiştir. Her bir epochun çalışması ortalama 186 saniye sürmüştür, eğitim sürecinin tamamı yaklaşık 31.3 dakikada tamamlanmıştır.

Bir modelin değerlendirilmesi için kullanılan çeşitli metrikler vardır. Bunlardan en yaygın olan doğruluk (accuracy), doğru sınıflandırılmış örnek sayısının toplam örnek sayısına oranıdır ve Denklem (1) ile gösterilmiştir.

$$\text{doğruluk} = \frac{\text{doğru sınıflandırılmış örnek}}{\text{toplam örnek sayısı}} \quad (1)$$

İlk epochta %77.93 olan doğruluk değeri, 10 epoch sonunda %98.88'e ulaşmıştır. Modelin eğitimi sürecindeki doğruluk değerlerinin değişimini gösterir grafik Şekil 1'de yer almaktadır.

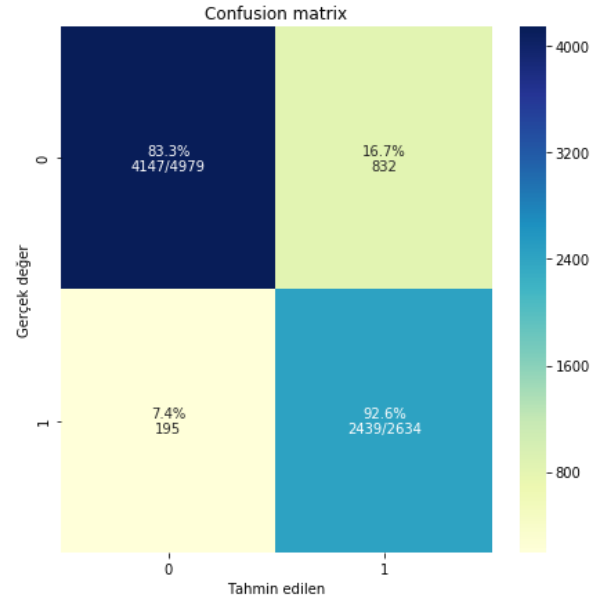


Şekil 1: Modelin doğruluk değişim grafiği

Modelin doğruluğu, veri kümesi her sınıftan eşit sayıda örnek içeriyorsa yani dengeli ise, performansı karakterize etmek için etkili bir parametredir. Ancak dengesiz bir veri kümesi ile çalışırken sistemin daha fazla performans ölçütü ile değerlendirilmesi gerekir. Bu amaçla karmaşıklık/konfüzyon (confusion) matrislerinden yararlanılır. Bir konfüzyon matrisi doğru ve yanlış sınıflandırmaları tablo halinde verir. Veri sınıflandırmanın ardından dört muhtemel sonuç ortaya çıkar [17]:

- Aslı pozitif olan veri pozitif olarak doğru tahminlendiğinde doğru pozitif (true positive - TP),
- Aslı pozitif olan veri negatif olarak yanlış tahminlendiğinde yanlış negatif (false negative - FN),
- Aslı negatif olan veri negatif olarak doğru tahminlendiğinde doğru negatif (true negative - TN),
- Aslı negatif olan veri pozitif olarak yanlış tahminlendiğinde yanlış pozitif (false positive - FP) olarak tanımlanır.

Google BERT modeli ile gerçekleştirilen çalışmada elde edilen karmaşıklık matrisi Şekil 2'de yer almaktadır.



Şekil 2: Karmaşıklık matrisi

Konfüzyon matrisinden elde edilen bu değerlerle sınıflandırıcının performansını ifade etmek için farklı metrikler türetilir. Bunlardan biri olan kesinlik (precision) modelin yanlış pozitifleri eleme kabiliyetini gösterir.

Kesinlik hesabı Denklem (2) ile gösterilen formül kullanılarak yapılır.

$$kesinlik = \frac{TP}{TP + FP} \quad (2)$$

Diğer bir metrik olan duyarlılık (recall) ise sınıflandırmanın doğru pozitifleri tespit etme kabiliyetini gösterir. Duyarlılık değeri hesabında Denklem (3) ile gösterilen formül kullanılır.

$$duyarlılık = \frac{TP}{TP + FN} \quad (3)$$

Gerçekleştirilen çalışmada sözü geçen metrikler için elde edilen değerler şunlardır:

- Kesinlik: %87.943
- Duyarlılık: %85.036

#### 4 Sonuç

Günümüzde pek çok insan günün büyük bölümünü internet ve özellikle sosyal ağlarda geçirmektedir. Kullanıcılarına 280 karakterlik mesajlar paylaşma olanağı sunan Twitter da yaygın kullanılan sosyal ağlardandır. Kullanıcılar yanlarında taşıyabildikleri internet erişimine sahip cihazlarla diledikleri zaman içinde buldukları durumu kendi görüşleriyle Twitter üzerinde paylaşabilmektedir.

Günlük hayat içinde meydana gelen olağandışı pek çok durum da ilk olarak Twitter’da duyulup hızla yayılmaktadır. Bu nedenle Twitter verileri acil müdahale ekiplerine yardımcı olabilmektedir. Bir dakika içerisinde yapılan milyonlarca paylaşımın manuel takibi son derece zordur. Bu işi yerine getirmek için özel yazılımlar kullanılmaktadır. Bu yazılımların temelinde ise makine öğrenmesinin özel bir alanı olan doğal dil işleme teknikleri yer almaktadır. Doğal dil işleme insanların konuştuıkları dillerin makineler tarafından anlamlandırılmasına yardımcı olan tekniklerdir. Doğal diller doğaları gereği karmaşık bir yapıya sahiptir ve net kuralları yoktur. Bu nedenle bağımsız kelimeler açısından farklı bir anlama gelen ifade cümlelerin bütününe bakıldığında farklı bir anlama gelebilmektedir. Bu çalışmada olağandışı durumlar hakkında Twitter’da yapılan paylaşımlardan oluşan bir veri seti analiz edilmiştir. Veri seti içerisinde yer alan paylaşımlar gerçek bir felaket durumunu ifade edip etmemesine göre gerçek veya gerçek dışı olarak etiketlenmiştir. Bu veriler Google yapay zekâ ekibi tarafından geliştirilen, sinir ağı temelli bir model olan BERT ile sınıflanmıştır. %80 eğitim, %20 test seti olarak ayrılan veri kümesi üzerinde 10 epoch olarak gerçekleştirilen eğitim işlemi sonucunda %98.88 elde edilmiştir. Kesinlik değeri %87.94, duyarlılık değeri ise %85.03 olarak elde edilmiştir. Daha sonra gerçekleştirilecek çalışmalarda veri setinin genişletilmesi ve dengelenmesi, eğitim için hibrit modellerin kullanılması ile başarıyı arttıracak çalışmalar gerçekleştirilebilir.

### Kaynaklar

- [1] “Digital 2020: Global Digital Overview,” DataReportal – Global Digital Insights. <https://datareportal.com/reports/digital-2020-global-digital-overview> (accessed May 10, 2020).
- [2] “Twitter by the Numbers (2020): Stats, Demographics & Fun Facts,” Jan. 05, 2020. <https://www.omnicoreagency.com/twitter-statistics/> (accessed May 13, 2020).
- [3] A. Bruns, T. Highfield, and J. Burgess, “The Arab Spring and social media audiences: English and Arabic Twitter users and their networks,” *American behavioral scientist*, vol. 57, no. 7, pp. 871–898, 2013.
- [4] T. Terpstra, A. De Vries, R. Stronkman, and G. L. Paradies, *Towards a realtime Twitter analysis during crises for operational crisis management*. Simon Fraser University Burnaby, 2012.
- [5] F. Cheong and C. Cheong, “Social media data mining: A social network analysis of tweets during the Australian 2010-2011 floods,” in *15th Pacific Asia Conference on Information Systems (PACIS)*, 2011, pp. 1–16.
- [6] B. Mandel, A. Culotta, J. Boulahanis, D. Stark, B. Lewis, and J. Rodrigue, “A demographic analysis of online sentiment during hurricane irene,” in *Proceedings of the second workshop on language in social media*, 2012, pp. 27–36.
- [7] C. Caragea, A. Squicciarini, S. Stehle, K. Neppalli, and A. Tapia, “Mapping moods: Geo-mapped sentiment analysis during hurricane sandy,” pp. 642–651, Jan. 2014.
- [8] H. Li et al., “Twitter mining for disaster response: A domain adaptation approach,” Jan. 2015.
- [9] M. Imran, S. Elbassuoni, C. Castillo, F. Diaz, and P. Meier, *Extracting Information Nuggets from Disaster-Related Messages in Social Media*. 2013.
- [10] Z. Ashktorab, C. Brown, M. Nandi, and A. Culotta, “Tweedr: Mining twitter to inform disaster response.,” in *ISCRAM*, 2014.
- [11] K. Kireyev, L. Palen, and K. Anderson, “Applications of topics models to analysis of disaster-related twitter data,” in *NIPS workshop on applications for topic models: text and beyond*, 2009, vol. 1.
- [12] S. Vieweg, A. L. Hughes, K. Starbird, and L. Palen, “Microblogging during two natural hazards events: what twitter may contribute to situational awareness,” in *Proceedings of the SIGCHI conference on human factors in computing systems*, 2010, pp. 1079–1088.
- [13] S. Kumar, G. Barbier, M. A. Abbasi, and H. Liu, “Tweetracker: An analysis tool for humanitarian and disaster relief,” in *Fifth international AAAI conference on weblogs and social media*, 2011.
- [14] G. G. Chowdhury, “Natural language processing,” *Annual review of information science and technology*, vol. 37, no. 1, pp. 51–89, 2003.
- [15] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, “Bert: Pre-training of deep bidirectional transformers for language understanding,” *arXiv preprint arXiv:1810.04805*, 2018.
- [16] K. Schachinger, “A Complete Guide to the Google RankBrain Algorithm,” *Search Engine Journal*, 2017.
- [17] F. BULUT, “ÇOK KATMANLI ALGILAYICILAR İLE DOĞRU MESLEK TERCİHİ,” *Anadolu Üniversitesi Bilim Ve Teknoloji Dergisi A-Uygulamalı Bilimler ve Mühendislik*, vol. 17, no. 1, pp. 97–109, 2016.