

SURİYELİ MÜLTECİLERE UYGULANAN AYRIMCI-DIŞLAYICI TWİTLERİN BERT MODELİ İLE SINIFLANDIRILMASI

Dr. Engin Karaman

İstanbul Esenyurt Üniversitesi

enginkaraman1013@gmail.com

Orcid: 0000 0002 2336 6289

DOI: 10.31834/ortadoguvegoc.1148440

Makale Türü / Article Types: Araştırma Makalesi / Research Article

Geliş Tarihi / Received: 25 Temmuz/ 25 July 2022

Kabul Tarihi / Accepted: 28 Aralık / 28 December 2022

Yayın Tarihi / Published: 30 Aralık / 30 December 2022

Yayın Sezonu / Pub Season: Aralık / December

Atıf / Cite: Karaman, A. (2022). Suriyeli Mültecilere Uygulanan
Ayrımcı-Dışlayıcı Twitlerin Bert Modeli ile Sınıflandırılması.

Ortadođu ve Göç, 12(2). ss. 428-456.

İntihal / Plagiarism: Bu makale, en az iki hakem tarafından incelendi
ve intihal içermediği teyit edildi. / This article has been reviewed by
at least two referees and checked via a plagiarism detector.

Öz

Bu çalışmanın amacı, mülteciler özelinde ‘Suriyeliler’ temasının Türk halkında uyandırdığı imajı ayrımcılık-ötekileştirme bağlamında sınıflamaktır. Analiz için gerekli olan veri, Twitter platformunda toplanmış gerekli ön işlemlerden geçirilmiş, ardından ayrımcı-dışlayıcı ifadeler içeren ve içermeyenler olarak ikili (binary) sınıflandırılmıştır. Model oluşturma safhasında dönüştürücü (transformer) mimarisini kullanan BERT modeli önerilmiştir. Arkasında çok kapsamlı bir matematik ve derin ağ bulunan BERT modeli; dilden dile çeviri, özet çıkarma ve sınıflama gibi birçok alanda başarılı performans göstermektedir. Oluşturulan modelin doğruluk oranı 0.8562 bulunmuştur. Çalışmanın uygulama aşamasında, geliştirilen model kullanılarak Türkiye’de yaşanan mültecilerle ilgili adli iki vaka üzerine atılan twitler incelenmiştir. Sonuç olarak iki olay üzerinden yapılan değerlendirmede ülkemizde mültecilere yönelik olumsuz duygu ve tutumların endişe verici bir düzeyde olduğu ortaya çıkmıştır.

Anahtar Sözcükler: Suriyeliler, Ayrımcılık, Dönüştürücü, Bert, Pytorch.

CLASSIFICATION OF DISCRIMINATORY-EXCLUSIONARY TWEETS APPLIED TO SYRIAN REFUGEES BY THE BERT MODEL

Abstract

The aim of this study is to classify the image that the theme of "Syrians" evokes in the Turkish people in the context of discrimination and marginalization in the context of refugees. The data required for the analysis were collected on the

Twitter platform and then classified as binary with or without discriminatory-exclusionary expressions. In the model creation phase, the BERT model is proposed. It shows successful performance in many areas such as translation from language to language, summarizing and classification. The accuracy rate of the created model was found to be 0.8562. In the application phase of the study, tweets on two legal cases related to refugees in Turkey were examined by using the developed model. As a result, in the evaluation made on two events, it has been revealed that the negative feelings and attitudes towards refugees in our country are at an alarming level.

Keywords: Syrians, Discrimination, Transformer, Bert, Pytorch.

Giriş

Her şey, 17 Aralık 2010 tarihinde Tunuslu bir işportacı gencin (Muhammed Buazizi) kendisine uygulanan baskı ve şiddeti protesto etmek için vücudunu ateşe vermesi ve ardından Mısır, Libya, Suriye, Bahreyn, Ürdün ve Yemen gibi ülkelerin yönetimlerini derinden etkileyen bir mecraya dönüşesiyle başladı. Arap Baharı olarak da adlandırılan bu olaylar bazı ülkelerde iktidarları değiştiren, bazı ülkelerde de reform ve anayasal düzenlemelerle demokratik değişimlere neden oldu. Bu ülkeler arasında devinimini tamamlayamayan hatta giderek kronikleşen ve sadece kendisini değil tüm Ortadoğu'yu derinden etkileyen Suriye oldu. 2011'de başlayan olaylar hala önemini korumakta, küresel bir vaka olarak tüm uluslararası aktörlerin (ABD, Rusya, İsrail, Fransa, Türkiye vd.) üzerinde söz hakkı almaya çalıştığı çok boyutlu bir hegemonya savaşına dönüştü. Tamamen demokratik istem ve taleplerle başlayan

barışçıl eylemlere karşı, iktidarın sert ve uzlaşmasız bir tutum göstermesi, süreci geri dönülmez bir hale getirdi. Zaten demografik yapısı heterojen olan ülkenin çatışma potansiyeline yakıt taşıyan dış müdahaleler büyük bir yangın başlattı. Artık çatışmalar ‘Vekalet Savaşı’ olarak boyut değiştirdi. Sonuç olarak bugün Türkiye’yi de derinden etkileyen savaş, her gün yeni acı ve dram öyküleriyle kendini günlük hayatın rutini olarak var ediyor. O halde milyonlarca insanı derinden etkileyen ve kitlesel göç hareketlerine neden olan olaylar zinciri ülkemize nasıl bir etkiye bulundu? Misafirperverliği düstur edinmiş bir ülkenin insanları, zulme uğramış komşu ülkenin halkına hangi duygularla karşılık verdi? İçerisinde birçok karmaşa ve boyut bulunan bu soruların cevabını aramak bu araştırma temelini oluşturuyor. Göç sürecinin başladığı andan günümüze kadar konu üzerine birçok kurum ve akademisyen farklı alanlarda meseleyi derinlemesine irdeledi. Konu birçok bakımdan hâlâ incelenmeye muhtaçtır. Gerek mültecilik statüsünün devamlılığı gerekse de vatandaşlık edinimi açısından Türkiye’nin demografik yapısı ve gelecek tahayyülü bakımından öngöründe bulunup, politika yapıcılarına bakış açısı sunmak zorunludur. Bu çalışmada temel amaç ‘Suriyeliler’ temasının insanlarda uyandırdığı imajı ayrımcılık-dışlayıcılık bağlamında sınıflamaktır. Analiz için gerekli olan veri, Twitter platformunda toplanıp gerekli ön işlemlerden geçirilip ardından ayrımcı-dışlayıcı ifadeler içeren ve içermeyenler olarak ikili (binary) sınıflandırma yapılacaktır. Model oluşturma safhasında son zamanlarda uluslararası literatürde en geçerli sınıflandırma algoritması olarak kullanılan, 2018 yılında Google tarafından geliştirilmiş ve dönüştürücü (transformer) mimarisini kullanan BERT (Bidirectional Encoder Representations for Transformers) modeli kullanılacaktır.

Arkasında çok kapsamlı bir matematik ve derin ađ bulunan BERT modeli; dilden dile çeviri, özet çıkarma ve sınıflama gibi birçok alanda başarılı performans göstermiş kendinden önceki birçok derin öğrenme algoritmaların (CNN, RNN, LSTM vb...) üstesinden gelemediđi problemleri aşmıştır. Son günlerde Doğal Dil İşlemede devrim olarak nitelenen ve basında geniş yer bulan, insanların yazdıđı metinlere benzer içerik üretmek için üretilen derin öğrenmeli öz bađlanımlı dil modeli (Milliyet, 2021) GPT-3 (Generative Pre-trained Transformer- Üretken Ön İşlemeli Dönüştürücü) modelinin temelini de oluşturur. Sonuç olarak geliştirilen model aracılıđıyla bir tweet ya da metnin ayrımcı-dışlayıcı anlam içerip içermediđi tespiti amaçlanacaktır.

Teorik metod

Çalışmanın bu kısmı iki bölümden oluşuyor. İlk bölümde Mültecilik kavramı ele alınıp, teorik ve sayısal bilgiler sunulacaktır. İkinci bölümde ise model ve model kullanılan algoritmalar üzerinde durulacaktır.

Tüm cihandaki en kitlesel halk: Mülteciler

Birleşmiş Milletler Mülteciler Yüksek Komiserliđinin tanımına göre mülteci; ırkı, tabiiyeti, dini, toplumsal gruba mensubiyeti veya politik fikirleri yüzünden baskıya uğrayan ve ülkesinin dışında bulunan, geri dönemeyen veya korku nedeniyle dönmek istemeyen şahıslar olarak tanımlanır (UNHCR, 2021). Birleşmiş Milletler Mülteciler Yüksek Komiserliđinin 2020 yılının başında yayınladıđı rapora göre, tüm Dünya'da kayıt altına alınabilen 80 milyon mülteci bulunuyor. Aynı raporda mültecilere ev sahipliđi yapan ülkeler arasında birinci sırada Türkiye yer alırken, en çok mülteci oluşturan ülke sıralamasında Suriye birinci sırada yer alıyor. Bu anlamda


mültecilere karşı geliştirilen ötekileştirici ve dışlayıcı tutumların belirlenmesinde ülkemiz verilerinin uluslararası bir geçerlilik ve güvenilirlik taşıdığı söylenebilir.

Bu çalışmada “Suriyeli Mülteciler” terimi terminolojik olarak, ülkemize zorunlu göç hareketinde bulunarak yerleşen ama mülteci statüsü bulunmayan ancak hukuki statü olarak geçici koruma altındaki Suriye kökenli bireyleri tarif etmektedir. Çalışmada odaklanılan belirleyici faktör, iç kamuoyunun her türlü dış nüfuz hareketini (Suriye, Afganistan, Pakistan ve Afrika ülkeleri) mülteci olarak kabullenerek tutumlarını ona göre oluşturmasıdır. İncilenen twittlerde hepsi tek bir kavram üzerinde sınıflandırıldığı tespit edilmiştir: Mülteciler. Bu nedenle çalışmanın ilerleyen aşamalarında genel konsept olarak Suriyeli Mülteciler tanımı üzerinden hareket edilecektir.

Suriye iç savaşı ve mülteci hareketliliği

Ülkelerindeki hukuki baskıya, gösteri haklarının olmamasına, işkence ve uzun yargılama süreçlerine ve ekonomik sorunlara karşı örgütlenen Suriye halkı, 2010 yılı Ocak ayında taleplerini duyurmak için eylemlilik süreçlerine başlamıştır. Tamamen barışçıl bir şekilde vücut bulan gösteriler gerek Esad rejimin sert müdahaleleriyle gerekse de dış faktörlerin kışkırtıcı yönlendirmeleriyle çok büyük yıkımlara neden oldu. Sonsuz bir iç savaş sarmalına giren ülkede binlerce can kaybı, milyonlarca yaralanma ve nüfus hareketlikleri yaşandı. Bu göç hareketliliğinin ilk hedef noktasının Türkiye olması kaçınılmazdı. Gerek geniş sınır hattı ortaklığı ve inanç paydaşlığı gerekse de Avrupa varış noktasının güzergahında olması nedeniyle ülkemiz mültecilerin ilk tercihiydi. 2011’de başlayan Suriyeli mülteci hareketinin ilki 29 Nisan 2011’de 252 Suriyelinin Hatay Cilvegözü sınır kapısından geçmesiyle

başladı. İlk gelen Suriyeli mülteciler için Türk Kızılay'ı ve AFAD vasıtasıyla Hatay'da "barınma merkezleri" denilen kamplar kurulmaya başlandı. Bu kamplar yeterli gelmeyince Gaziantep ve Kilis'te çadır ve konteyner kentler inşa edildi (Erdoğan, 2014). Ancak mülteci girişi, sürekliliği ve sayısı tahminlerin çok üzerinde oldu. İlk sene verilerine göre mülteci nüfusu 133 bin iken; üç buçuk yıl içinde bu sayı ise 1 milyon 650 bine ulaştı. Türkiye'de yıllara göre tespit edilen düzensiz göçmen sayısı 2015 yılından önce her yıl ortalama 50.000'leri bulurken Suriye'de yaşanan iç savaşın etkisiyle 2015 yılından itibaren ise her yıl 150.000'lere yükseldi (T.C. İçişleri Bakanlığı Göç İdaresi Başkanlığı, 2022). En güncel (gib.gov.tr, 19.12.2022) verilere göre Türkiye'de bulunan mülteci sayısı Şekil 1'de sunulmuştur.



Şekil 1. Yıllara Göre Geçici Koruma Kapsamındaki Suriyeliler

Bu veriler ışığında Süreyi iç savaşı çıkana kadarki süreçte kayıtlı geçici korumaya alınan Suriyeli sayısı 2011 yılı için sıfır, 2012 yılı için ise 14.237 olarak kayıtlanmıştır. Ancak ilerleyen yıllarda üstel bir artış meydana gelmiş ve 2016 yılı itibarıyla 3 milyondan fazla Suriyeliye geçici koruma hakkı verilmiştir. Türkiye'nin,

kuruluşunun ilk yıllarında deneyimlediği göç olgusuyla gelen insanlara kucak açan kimliği, ilerleyen yıllarda hem ekonomik-sosyal nedenler hem de göçmenlerin tutum ve davranışları nedeniyle yerini öfke ve nefrete bıraktı. Mültecilere yönelik geliştirilen devlet politikalarıyla bu durum düzeltilmeye çalışılsa da halk bazında yansımaları çoğunlukla olumsuz oldu (Karataş,2020:22). İstanbul Politik Araştırmalar Enstitüsü tarafından yapılan araştırmada (IstanPol,2021), Suriyelilere karşı hissedilen duygular sıralamasında birinci sırada endişe yer alırken, sonuculuğu nefret hissi almıştır. Ancak yıldan yıla şiddetli öfke hissedenler ve yoğun nefret hissedenler oranı giderek artmış ayrıca yoğun endişe hislerinin yoğun acıma duygusunun önünde olduğu tespit edilmiştir. Yapılan birçok çalışma, Suriyeli mültecilere yönelik olumlu hislerin giderek nasıl olumsuz seyre döndüğü, buna zemin hazırlayan ekonomik, siyasi ve kültürel faktörleri ve kitle iletişim araçlarında üretilen ayrımcı ve dışlayıcı tutumları incelemiştir (Akbulut, 2020). “Suriyeli Sığınmacıların Türkiye’ye Etkileri” başlıklı bir çalışmada (Orhan ve Gündoğar, 2015) ekonomik, toplumsal ve siyasi-güvenlik gibi açılardan, göçün yarattığı etkiler sosyal medya verileri aracılığıyla analiz edilmiştir. Çalışmada “mültecilerle yerli halk arasında kültür, dil ve yaşam tarzı farklılıklarının uyumu güçleştirdiği, demografik yapının değiştiği, çocuk işçiliğinin yaygınlaştığı, çarpık yapılaşmanın arttığı, Suriyelilerin yaşam koşulları ve eğitimsizliği nedeniyle suç oranlarındaki artış başta olmak üzere bazı sosyal sorunları beraberinde getirdiği, Suriyeli gelinlerden kaynaklanan boşanmaların arttığı ve ucuz işçiliğin arttığı” gibi görüşlerin ortaya çıktığı tespit edilmiştir. Erdoğan (2014) tarafından yapılan araştırmada katılımcıların %72,5’i Suriyeli çocukların eğitimi konusuna olumlu baktığı, %70,8’inin Suriyeliler kaynaklı ekonominin zarar gördüğü, %62,3’nün Suriyelilerin güvenlik

riski oluşturduğu, %47,4'ü sürekli çalışma iznine karşı çıktığı, %84,5'i vatandaşlık verilmesini onaylamadığı, yarısının Suriyelilerin ülkelerine dönmesi gerektiği ve de %66,9'luk bir kesimin de Suriyelilerin Türk toplumuna uyum sağlayamayacağı görüşünü belirtmiştir. Ayrıca Suriyeliler yüzünden işsiz kalma kaygısının yüksek olduğu ve bu nedenlerden dolayı Suriyelileri ötekileştiren bir bakış açısının yaygın olduğu tespiti yapılmıştır (T.C. İçişleri Bakanlığı Göç İdaresi Başkanlığı, 2021).

Suriyelilerin ülkelerine geri dönme ihtimalinin belirsizliği de “biz” ve “öteki” sınıflandırmasını meşrulaştırmaktadır. Öte yandan bakıldığında, göç koşulları, yeni yerleşim yerine oryantasyon ve yaşam şartları mültecilerin güvenliğini tehlikeye atıyor (Bozdağ, 2021). Ülkelerinde yaşadıkları mezalimden kaçarak başka topraklarda umut arayan ve neredeyse yeni bir yaşam serüvenine atılan bu kişiler ikinci kez çetin bir mücadeleyle karşı karşıya geliyor: Ötekileştirme ve Ayrımcılık. Karar ve yetki mekanizmasında hiçbir söz hakkı olmayan halklar, savaşların da en büyük kurbanı oluyor. On yılı aşan mültecilik durumu artık kendini kalıcı bir forma dönüştürmüş durumda. 2019 yılı itibariyle Türkiye Cumhuriyeti vatandaşlığına hak kazanan 79 bin 820 kişi bulunuyor (Sözcü, 2021). Ayrıca birçok Suriyeli işletmeci ülkemizde küçük ölçeklide olsa üretimde yer alıp ve istihdam sağlıyor. Dört milyona yakın bu kitlenin çoğunluğunun kalıcı olacağı göz önüne alındığında, sorunun çözümüne dair politika geliştirmek ve çok boyutlu analiz yapmak ülkemiz için ertelenemez bir görev olarak önümüzde duruyor. Bunun için geç kalındığı eleştirisini yapmak doğru olacaktır. Mülteci dalgasının başladığı günlerde bu projeksiyonla politikalar oluşturulsaydı, yukarıda belirtilen toplumsal öfke ve şiddet sarmalı durdurulur

ya da süreç daha yumuşak geçişlerle idare edilebilirdi. Bu çalışma da bu amaçla gerçekleştirilmiş olup, mültecilere yönelik ayrımcı-ötekileştirici duyguları saptama hedefi amaçlandı. Geniş bir veri setiyle eğitilecek olan derin ağ, ayrımcı ve ötekileştirici ifadeler içeren metinleri algılayacak, tutumların zamansal değişimlerini ve uygulanacak politikaların yansımaları değerlendirme açısından önemli dönüşler sağlayacaktır.

Metin İşlemede BERT Model ile sınıflandırma

Metin (text) sınıflandırması, Doğal Dil İşleme (NLP)'de kullanılan en popüler yöntemlerden biridir (Munika vd.,2019). Buradaki temel amaç, belirli bir metin dizisine önceden tanımlanmış kategoriler atamaktır (Sun vd.,2019). Son yıllarda bu alan daha hızlı gelişti ve iki ana tekniğin birleşimi sayesinde giderek daha başarılı hale geldi. Bunlar; kelime gömme (word embedding) ve derin öğrenme tabanlı modellerdir (Pota vd.,2021).


Derin Sinir Ağları, giriş ve çıkış arasında çoklu gizli katmanlar sunan ve nöronların topolojisine ve bağlantılarına bağlı olarak çok sayıda farklı mimaride bulunan Yapay Sinir Ağlarıdır (Yadav/ Vishwakarma,2020 NLP'deki metin sınıflandırma, dil modelleme, makine çevirisi gibi görevlerin çoğu, dizi modelleme (sequence modeling) görevlerinden oluşur. Geleneksel makine öğrenimi modelleri ve sinir ağları, kelime merkezli işlem yaptığı için metinde bulunan sıralı bilgileri yakalayamaz. Bu nedenle, araştırmacılar tekrarlayan sinir ağlarını (RNN ve LSTM) geliştirdi. Bu mimariler metinde bulunan sıralı bilgileri modeller. Bununla birlikte, bu yapıların da sorunları vardır. Önemli bir sorun, RNN'lerin paralelleştirilememeleridir, çünkü her seferinde bir girdi

almaktadırlar. 2018'de Google OPEN AI ekibi tarafından yayınlanan “Attention is All You Need” makalesi yeni bir devrimin işaret fişegi olan Dönüştürücüler (Transformers) modelini tanıtarak NLP'de çığır açtı (Vaswani vd.,2017).

Dönüştürücüler (Transformatörler)

Transformatörler, her katmanında birden fazla dikkat ögesi içeren ve çoklu katmanlardan oluşan yapılardır (Clark vd.,2019). NLP'de Transformatörler, uzun menzilli bağımlılıkları kolaylıkla ele alabilmelerinin yanında diziden diziye görevleri çözmeyi amaçlayan bir mimariye de sahiptir. Transformatörün arkasındaki fikir, giriş ve çıkış arasındaki bağımlılıkları dikkatle (attention) ve yineleme (recurrence) ile tamamen ele almaktır. Transformatör tabanlı modelleri kullanmanın birçok avantajı vardır, ancak en önemlileri şu şekilde sıralanabilir. İlk fayda, bu modeller, bir giriş dizisini belirteç olarak işlemezler, bunun yerine tüm diziyi tek seferde girdi olarak alırlar. Geleneksel sıralı veya tekrarlayan modellerin aksine, dikkat mimarisi tüm girdi dizisini bir kerede işler. Bu, RNN tabanlı modellere göre büyük bir gelişmedir. Başka bir fayda ise; bu modelleri önceden eğitmek için etiketlenmiş verilere ihtiyaç bulunmamasıdır. Bu, transformatör tabanlı bir modeli eğitmek için çok büyük miktarda etiketlenmemiş metin verisi sağlanması gerektiği anlamına gelir. Bu eğitilmiş modeller, metin sınıflandırması, adlandırılmış varlık tanıma, metin oluşturma gibi NLP görevleri için kullanılır. BERT ve GPT-3 en popüler transformatör tabanlı modellerdir. Bidirectional Encoder Representations for Transformers (Transformatörlerden Çift Yönlü Kodlayıcı Temsilleri) ifadesinin kısaltması olan BERT; çift yönlü, hem sol hem de sağ bağlamda ortak koşullandırma yoluyla

etiketlenmemiş metinden derin çift yönlü temsilleri önceden eğitmek için tasarlanmıştır.



Şekil 2. Dönüştürücü Model Mimarisi

Şekil 2’de görüldüğü gibi, BERT’in ilk katmanı, girdi olarak dizge (token), pozisyon (positional) ve segment gömme (embedding) vektörlerinin bir kombinasyonundan oluşur (Rogers vd., 2021). Bunlardan ilki; girdi cümlesinin sayısal temsilini, ikincisi dizgelerin cümlede bulunduğu konumu ve sonuncusu ise dizgenin hangi cümlede olduğunu belirtir. İlk süreç bu üç vektörün toplanarak kodlayıcılara gönderilmesiyle başlar. Böyle kapsamlı bir gömme şeması, model için birçok yararlı bilgi içerir. Bu ön işleme adımları kombinasyonları, BERT’i çok yönlü hale getirir. Böylece, modelin mimarisinde büyük bir değişiklik yapılmadan eğitmek kolaylaşır (Kaggle,2021). Her Transformer bütünleşik bir ikili yapıya sahip olan Otokodlayıcılardan (Encoder- Decoder) oluşur. Bunlar denetimsiz bir şekilde eğitilen, verinin kodlanmış gösterimini öğrenip daha sonra bu kodlanmış gösterimden girdi verisini mümkün olan en yakın şekilde üreten yapay sinir ağlarıdır. Encoder ve Decoder blokları aslında birbirinin üzerine yığılmış birden çok özdeş kodlayıcı ve kod çözücüdür. Hem kodlayıcı yığını hem de kod çözücü yığını aynı sayıda birime sahiptir. Her bir kodlayıcı (Encoder) bloğunda bir tane Çoklu Dikkat Ağı (Multi-Head Attention) ardından da İleri Beslemeli (Feed

Forward) Sinir Ağı katmanı bulunur. Kod çözücüde (Decoder) ise buna ek olarak ekstra bir Maskelenmiş Çoklu Dikkat Yapısı (Masked Multi-Head Attention) bulunur (Hua,2019:137). Çoklu dikkat yapısı, modelin farklı konumlardaki farklı temsili alt uzaylarından gelen bilgileri ortaklaştırarak ağa katılımını sağlar (Vaswani vd.,2017). Bu katmanlar “Ekleme&Normalize” (Add & Norm) ile gösterilen kutularla birbirine bağlanırlar. “Add” kısmı artık (Residual) bir bağlantı olduğunu gösterir ve bu da gradyanın yok olmasını engeller. Norm kısmı ise katmanın normalizasyonunu belirtir. Kodlayıcı ve kod çözücü birimlerinin sayısı bir hiper parametredir. Bu çalışmada 6 adet Encoder, Decoder yapısı kullanılacaktır. Uygulamaya geçmeden önce Dikkat (Attention) yapısının önemi üzerine durmakta fayda olacaktır.

Dikkat Yapısı nedir?

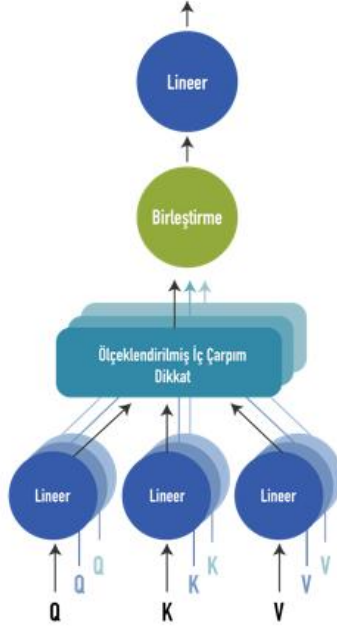
Dikkat, bir sorguyu (Query), bir dizi anahtar-değer (Keys-Values) çiftini ve çıktının tümünü belirli ağırlıklar doğrultusunda vektörel bir sonuca dönüştürme işlemi olarak tanımlanabilir. Dikkat ağırlıkları (Attention weights), mevcut dizge için bir sonraki temsili üretirken diğer tüm dizgelerin ne kadar "önemli" olduğunu belirleyen bir yönelim olarak görülebilir. Tahmin edilecek ve bağlam hakkında fikir veren kelimelere sorgu (Q), önceki tahminler için kullanılan şu anki kelime ile ilgili bilgi taşıyan etiketler anahtar (K) ve kelimelerin içeriklerini temsil eden yapılar ise değer (V) olarak adlandırılır. Dikkat fonksiyonunu bir matris halinde paketlenmiş bir dizi sorgu üzerinde aynı anda hesaplanır ve eş zamanlı olarak anahtar ve değer yapılarıyla bütünleştirilir. Sonuç matrisi şu şekilde hesaplanır;

$$Dikkat(Q, V, K) = Softmax\left(\frac{QK^T}{\sqrt{d^k}}\right)V \quad (1)$$

İç çarpımda ölçeklendirme yapmak için notasyonda $\frac{1}{\sqrt{d^k}}$ düzeltilmesi kullanılır. d^k ; anahtar vektörünün boyutunu ifade eder. Öz dikkat yapısı her boyut için ayrı hesaplamalar yapar. Bununla birlikte, Çoklu Dikkat yapısı kullanılarak, modelin farklı konumlardaki farklı temsil alt uzaylarından gelen bilgiler iç çarpım (dot product) aracılığıyla final değeri oluşturulur. Tek bir dikkat başlığı ile ortalama alma bunu verimli bir şekilde sağlayamaz. Böylece modelin farklı pozisyonlara odaklanma yeteneği genişler.

$$başlık_i = dikkat(QW_i^Q, KW_i^K, VW_i^V) \text{ iken} \quad (2)$$

$$\text{Çoklu Dikkat}(Q, V, K) = \text{İç Çarpım}(başlık_1, \dots, başlık_d)W^0 \quad (3)$$



Şekil 3. Çoklu Dikkat Yapısı

Önceden eğitilmiş modeller ve transfer öğrenme

Modern NLP sistemlerinin önemli bir bileşeni olarak önceden eğitilmiş (pre-trained) kelime gömme tekniği, sıfırdan öğrenilen yerleştirmelere göre önemli iyileştirmeler sunar. Cümle gömmeleri veya paragraf gömmeleri gibi sözcük gömmelerinin genelleştirilmesi de alt modellerde özellik olarak kullanılır. Transfer öğrenimi, büyük bir veri kümesi üzerinde eğitilmiş bir derin öğrenme modelinin başka bir veri kümesinde benzer görevleri gerçekleştirmek için kullanıldığı bir tekniktir. Böyle bir derin öğrenme modeline önceden eğitilmiş bir model denir (AnalyticsVidhya,2021). Son zamanlarda, büyük miktarda etiketlenmemiş veri içeren büyük bir ağ üzerinde dil modellerini önceden eğitme ve alt görevlerinde (downstream)

ince ayar(fine-tuning) yapma yöntemi, birçok doğal dil anlama görevinde bir atılım yaptı (Sun vd.,2019). Bir metin dizisi durumunda, bir RNN veya LSTM, girdi olarak her seferinde bir dizge (token) alır. Böyle bir modeli büyük bir veri kümesi üzerinde eğitmek çok zaman gerektirir. Bu nedenle, NLP'de transfer öğrenmeye duyulan ihtiyaç tüm zamanların en yüksek seviyesindedir. Sonuç olarak, önceden eğitilmiş BERT modeline, çok çeşitli NLP görevleri için son teknoloji modeller oluşturmak üzere yalnızca bir ek çıktı katmanıyla ince ayar yapılabilir (Wang vd.,2020).

Ön eğitim ve ince ayar iş akışı, BERT'in çok önemli bir parçasıdır. İlkinden görevden bağımsız bilgi sağlaması, ikincisinden ise modele eldeki görev için faydalı temsiller oluşturması beklenir (Rogers vd.,2021) BERT modeli ilerleyen aşamalarda kullanım amaçlarına göre birçok çalışmada revize edildi ya da geliştirildi. Bunlara örnek olarak; mBERT (Nozza vd.,2021), RoBERTa (Delobelle vd.,2021), FlauBERT (Le vd.,2021), ALBERT (Lan vd.,2020), vb... verilebilir. BERT modelinin sözcüklerin kullanıldıkları bağlamı temsil etmekte daha başarılı olduğu söylenebilir (Öztürk vd.,2020). Bu çalışmada, Transformers kütüphanesi yardımıyla metin sınıflandırması yapmak için bir BERT modeline ince ayar (fine-tuning) işlemi yapılacaktır. Bunun için Python programlama dili uygulaması olan PyTorch kullanılacaktır.

Uygulama

BERT, Wikipedia'nın tamamı (250 milyon kelime) ve Kitap Derleme (800 milyon kelime) dahil olmak üzere geniş bir etiketlenmemiş metin topluluğu üzerinde önceden eğitilmiştir. Bu işleyiş, BERT'in başarısının ardındaki sihrin yarısıdır. Bunun

nedeni, model büyük bir metin yığını üzerinde eğitilirken, dilin nasıl çalıştığına dair daha derin ve yapısal ilişkileri kavramasıdır. Bu bilgi, hemen hemen her NLP görevi için yararlı olan İsviçre çakısı gibidir (Devlin vd.,2019), Literatürde BERT model üzerinden Twitter verileri kullanan birçok çalışma mevcuttur. Olağandışı olaylar üzerine atılan tweetlerin gerçek ve gerçek dışı olarak sınıflandırılmasında BERT modeli kullanılmıştır (Sevli/Kemaloğlu,2021), Bir başka çalışmada BERT'in çok dilli modeliyle, Türkçeden İngilizceye çevrilmiş metinlerin BERT'in ana modeli performansları karşılaştırılmıştır (Acikalın vd.,2020), Online reklam platformlarından elde edilen reklam metinlerinin sektör bazlı olarak sınıflandırılması yapılmıştır(Özdil vd.,2021), Bir başka çalışmada, anlamlı bir diyalog akışı üretebilecek bir chatbot uygulaması geliştirmek için etiketleme aşamasında birçok algoritma denenmiş, sonuç olarak BERT modelinin en yüksek skoru oluşturduğu saptanmıştır (Ozan/Taşar,2021). Google Play uygulaması üzerinde Türkçe yapılan yaklaşık iki milyon yorum 1-5 arası puanlandırılarak model geliştirilmiştir (Sığırcı vd.,2020). Türkçe metinlerde ironi tespiti için yapılan ve birçok sinirsel yöntemlerin incelendiği çalışmada BERT modeli en başarılısı olarak belirlenmiştir (Cemek vd.,2020).

BERT'in iki farklı parametreye sahip modelleri vardır. İlki 12 katman, 768 gizli boyut ve 12 dikkat noktasına sahip ve 110 milyon parametreden oluşan orta ölçekli model, diğeri ise 24 katman, 1024 gizli boyut ve 16 dikkat noktasından oluşan ve 340 milyon parametreye sahip olan büyük ölçekli modeldir. Tahmin edileceği gibi böyle büyük boyutlardaki modellerin eğitilmesi çok zor olacağı ve bol vakit alacağı için, modellerin doğrudan eğitimi yerine, önceden eğitilmiş modellere ekstra

katman eklenerek bu katmanı, amaçlanan görev için etiketli veriyle eğitilmesi sağlanır.

Analiz

Bu çalışmada yaklaşık 35GB'lık oldukça büyük bir Türkçe dokümanla önceden eğitilmiş olan BERT-BASE-TURKISH-UNCASED modeli (Schweter,2020) kullanıldı. Model Türkçe dilinde NLP alanında yapılan çalışmalarda başarı ile kullanılmıştır. Analiz için gerekli olan veri, Twitter platformundan toplanıp gerekli ön işlemlerden geçirilip ardından ayrımcı-dışlayıcı ifadeler içeren ve içermeyenler olarak ikili (binary) sınıflandırıldı. Sonuç olarak 2264 tweetin %85'i eğitim, %15'i de test setinde kullanıldı. Eğitim setiyle yapılan ince ayar işleminden sonra model teste tabii tutularak tahmin gücü hesaplandı.

Modelde epoch sayısı 12 olarak atandı. Diğer doğal dil işleme modelleriyle karşılaştırıldığında BERT modelinin eğitim süreci daha uzun sürmektedir. Bunun için çalışma bulut ortamında Google Colaboratory (Colab) üzerinden yapıldı. Colab ile ücretsiz Tesla K80 GPU üzerinden Keras, Tensorflow ve PyTorch kullanarak derin öğrenme uygulamaları gerçekleştirilmektedir. Modelin çalışma süresi 123 dakika sürdü. Eğitim setinin son epochtaki kayıp oranı 0,5682 ve doğruluk oranı 0,8562 olarak hesaplandı. Modelin test seti üzerindeki doğruluk oranı ise 0,81 bulundu.

Örnek Olay İncelemesi

Bu aşamada Türkiye gündemindeki mülteciler konulu haberler üzerinden atılan tweetler modelimiz tarafından incelenecek ve değerlendirmelerde bulunulacaktır. Bunun için biri olumlu

diğeri olumsuz iki haber seçilecek ve bu olayların olduğu gün ve öncesi yapılan yorumları karşılaştırılacaktır.

Olay 1: 30 Ekim 2021 tarihinde gerçekleşen olayda Suriyeli bir çocuk gasp edilerek öldürüldü. Ayrıntılar Şekil 4'te sunulmuştur.



Fotoğraf: AA/Arşiv

Ankara'nın Altındağ ilçesinde, iki gün önce kaybolan Suriyeli Muhammed Hattabi (11), boş bir gecekondunun içinde öldürülmüş halde bulundu.

Gecekonduda bir oğlan çocuğunun hareketsiz yattığını gören yurtaşlar, polise haber verdi. Yapılan incelemelerde çocuğun başının taşla ezildiği tespit edildi.

Çocuğun üzerinden cüzdan ve kimlik çıkmaması üzerine polis ekipleri, daha önce kayıp bildiriminde bulunan Suriyeli aileyi olay yerine getirdi.

Cesedin başına gelen karı- koca, çocuğun, kaybolan oğulları Muhammed Hattabi olduğunu teşhis etti. Hattabi'nin bedeni olay yerindeki incelemenin ardından otopsi yapılmak üzere Adli Tıp Kurumu Morgu'na kaldırıldı.

Olay 2: Olay 1 ile aynı lokasyonda 11 Ağustos 2021 tarihinde gerçekleşen olayda ise 18 yaşındaki bir Türk genci Suriyeliler tarafından öldürüldü. Ayrıntılar Şekil 5'te sunulmuştur.



Ankara'nın Altındağ ilçesinde dün Suriyeliler ile yaşanan gerginlik sonucu bıçaklanan 18 yaşındaki Emirhan Yalçın'ın hayatını kaybetmesiyle başlayan olaylar büyüdü. Polis ekipleri sokağa dökülen öfkeli kalabalığı evlerine dönmeleri konusunda ikna etmeye çalışırken bir grup ise Suriyelilerin dükkanlarına saldırdı.

Ankara'nın Altındağ ilçesinde 18 yaşındaki Emirhan Yalçın'ın yabancı uyruklu grup ile çıkan kavgada bıçaklanmasının ardından mahalle sakinleri sokağa dökülmüş ve gergin anlar yaşanmıştı. Polisin vatandaşları zorlukla sakinleştirdiği olaylar bugün de devam ediyor. Ağır yaralanan Emirhan Yalçın'ın tedavi gördüğü hastanede hayatını kaybetmesinin haberini alan vatandaşlar, tekrar sokağa döküldü.

MAHALLE SAKİNLERİ SOKAĞA DÖKÜLDÜ

Polis ekipleri Altındağ'da vatandaşları evlerine dönmeleri konusunda ikna etmeye uğraşırken bir yandan da mahalle sakinleri sokaklarda devrile atmaya devam ediyor.

Şekil5. Haber 2 (<https://www.nrdhaber.com/haber-son-dakika...suriyeliler-turk-gencini-bicaklayarak-oldurdu-ankara-karisti-9835.html>)

Türkiye de geniş yankı uyandıran bu iki olaya dair sosyal medyada birçok yorum yapılmış ve tepki oluşmuştur. Bu yorumlar üzerinden modelimiz ayrımcı-ötekileştirici metinleri sınıflamıştır. Olaylara verilen tepkilerin duyarlılığını ölçmek için bir önceki günün analizleri de hesaba katılarak değerlendirme yapıldı. Model tarafından yapılan sınıflandırma ve sonuçları Tablo1'de sunulmuştur.

Tablo 1: Analiz Sonuçları

	Olay 1				Olay 2			
	Haber Öncesi		Haber Sonrası		Haber Öncesi		Haber Sonrası	
	Ötekileştirme-Dışlayıcılık							
	Var	Yok	Var	Yok	Var	Yok	Var	Yok
Twit Sayısı	86	12	180	78	92	14	375	22
Yüzde	88%	12%	70%	30%	87%	13%	94%	6%
Toplam	98		258		106		397	

Analizde kullanılan tweetler gerekli ön işleme ve ayıklama işlemleri yapıldıktan sonra modele sokuldu. Olay 1 öncesi gün yapılan analizde 98 tweet yayınlanmış bunların %88'i mülteciler üzerine olumsuz görüş belirtirken % 12'si olumlu ya da tarafsız görüş beyan etmiştir. Suriyeli çocuğun ölümü haberi sonrası atılan tweet sayısı bir önceki güne oranla yaklaşık iki kat kadar artmış ve olumsuz görüş oranı azalmış (%70), olumlu ve tarafsız görüş oranı (%30) artmıştır. Olay 2 için ise tam tersi bir yönelim oluşmuş, gerek atılan tweet oranı gerekse de mülteciler üzerine beyan edilen ötekileştirici-dışlayıcı dil kullanımı yüzdesi (% 94) artmıştır. Buna ek olarak, metinlerde en sık kullanılan kelimelerin frekans temsilini görselleyen Kelime Bulutu (Word Cloud) uygulaması gerçekleştirildi. Ancak öne çıkan kelimelerin

çođu argo ve galiz ifadeler içerdiğinden çalışmada yer alması uygun görülmedi.

SONUÇ

Bulunduđu cođrafi konum nedeniyle tarihin her döneminde geçiş noktası olarak kullanılan Türkiye son yıllarda Avrupa'ya giriş kapısı olarak mülteciler için uğrak bir yer oldu. Dođu ve Batı arasında köprü vazifesi gören ülke, savaş ve kaosla özdeşleşen Ortadođu ve Ön Asya ülke vatandaşlarının kaçış rotasının ilk tercihi olarak tercih edilmektedir. Özellikle yönetsel ve ideolojik deđişim taleplerinin halklar nezdinde vücut bulduđu Arap Baharı isyanı ve de son zamanlarda kitlesel göç hareketlerine neden olan Taliban'ın Afganistan'da iktidarı yeniden ele alması milyonları aşan göçmen nüfusunun ülkemize akmasına neden oldu. Sayıları milyonları aşan ve geçici olmaktan çok kalıcı bir yaşam eğilimi gösteren insanlar, olumlu ya da olumsuz bir şekilde Türk halkıyla etkileşim içerisine girmiş, kimi zaman ülke gündeminde önemli bir yer işgal etmiştir. Sürecin başında gerek inançsal ortaklık gerekse de tarihsel geçmişin verdiği kader birliği Türk halkında göçmenlere karşı misafirperver bir tutum sergilenmesine neden olmuştur. Ancak artan mülteci nüfusu, adli vaka sayısı, iş gücü rekabeti ve birçok neden toplumsal gerilmelere yol açmıştır. Bu gerilmelere karşı tepki geliştiren mülteciler ise kendilerine yeni yaşam alanları ve örgütlenme modelleri oluşturarak savunma mekanizması geliştirmiştir. Bu durum iki kamp arasında kronikleşen problemlere yol açmıştır. Özellikle yaşanan bazı yerel olaylar sosyal medya vasıtasıyla ülke sathında toplumsal linç vakalarına dönüşmüştür. Yapılan birçok çalışma ve analiz durumun giderek toplumsal fay

hattında yeni kırımlara yol açacağına işaret etmektedir (Akdeniz,2018).

Bu çalışmada mülteciler özelinde ‘Suriyeliler’ temasının insanlarda uyandırdığı imajı ayrımcılık-ötekileştirme bağlamında sınıflandırılması amaçlandı. Analiz için gerekli olan veri, Twitter platformunda toplanıp gerekli önışlemlerden geçirilip ardından ayrımcı-dışlayıcı ifadeler içeren ve içermeyenler olarak ikili (binary) sınıflandırıldı. Model oluşturma safhasında dönüştürücü (transformer) mimarisini kullanan BERT modeli kullanıldı. Modele Transfer Öğrenme yöntemi uygulanarak ince ayar işlemleri yapıldı. Bu yöntem modelin eğitimi sürecinde büyük zaman tasarrufuna ve örneklem hacmi kazancına neden oldu. Sonuç olarak oluşturduğumuz modelin sınıflama tahmin başarısı %81 olarak test edildi.

Analizin ikinci aşamasında modelin iki farklı örnek olay üzerinden işlenmesi sağlandı. Olay 1 ve Olay 2 olarak isimlendirdiğimiz örneklerin ülke gündeminde nasıl bir tepki uyandırdığı Twitter verileri üzerinden analiz edildi. Bu örnekler seçilirken iki zıt durumun karşılaştırılması hedeflendi. İlk olay Suriyeli bir çocuğun faili meçhul bir şekilde öldürülmesi üzerine oluşan tepkileri ölçerken, ikinci olay ise bir Türk gencinin Suriyeliler tarafından öldürülmesi üzerine gelişen tepkileri ölçtü. Bu iki olayın ülke kamuoyunda oluşturduğu duygu-tepki oluşumunu analiz ederken tutum değişimini belirlemek adına bir önceki gün atılan aynı gündemli twitlerde baz alındı. İki olay üzerinden yapılan analiz üzerinden şu sonuçlara ulaşıldı;

- Sürecin olağan olduğu dönemlerde bile atılan tweetlerde ötekileştirici-dışlayıcı ifade oranları çok yüksek (%80’ler civarı) olarak belirlendi. Bu durum bile

toplumda oluşan mülteci karşıtlığının ne kadar tehlikeli bir düzeye ulaştığını gösteriyor.

- Olay1, gerek bir çocuk mağduriyeti gerekse de vahşice işlenen bir cinayet vakası olması nedeniyle insani değerlere sahip kişiler için kabul edilemez bir durum ihtiva eder. Olay1'deki önceki gün yapılan analizde %12 olan olumlu dil haber sonrası %30'a kadar yükselmiştir. Bununla birlikte olumsuz görüş belirtme oranının %70 olarak ortaya çıkması ön yargılarda esnek olmayan bir yapının olduğunu işaret ediyor.
- Olay2 ise ilk örneğin tersine Suriyeliler tarafından gerçekleştirilen bir mağduriyeti temel aldı. Tahmin edileceği gibi olumsuz enerjiye güç sağlayacak bu vaka anında sosyal medya da bir infial etkisi yarattı. Haber öncesi %87 olan olumsuz twitler 7 puan artmış, olumlu görüş oranı ise %6 olarak belirlendi. Ek olarak önceki günle karşılaştırıldığında atılan tweet oranı 4 kat olmuştur. Bu oran mültecilere bakış konusunda Türk kamuoyunun ne kadar hassas ve duyarlı olduğunu işaret ediyor.
- Her iki olay birlikte değerlendirildiğinde, ülke halkının mülteciler üzerinde büyük oranda ayrımcı-ötekileştirici tutum geliştirdiği saptandı. Öyle ki bu refleksif tutum temel bir insan mağduriyeti (Olay1) üzerinde bile kendini baskın bir şekilde ortaya koydu. Hatta bazı tweetlerde mağdur çocuğu savunan kişilere karşı hakarete varan tepkiler olduğu gözlemlendi. Diğer dikkate değer veri ise Olay2 üzerinden verilen tepkilerin

artış oranıdır. Olay2 esnasında atılan tweetlerin yoğunluğu önceki güne oranla dikkate değer bir şekilde artmıştır. Ayrıca Olay2'ye karşı geliştirilen olumlu görüşler daha çok sakinleştirici ve ılımlı tutumlar olarak belirlendi. Ancak bu görüşlerin bile şiddetli karşı tepkilere maruz kaldığı gözlemlendi.

Tüm değerlendirmeler ışığında ülkemizde mültecilere karşı oluşan tutum ve davranışların insani değerler açısından kaygı verici düzeyde olduğu ortaya çıkmıştır. Maalesef bu olumsuz tutumların zaman geçtikçe hem nitel hem de nicel olarak arttığı da ortaya çıkmıştır. Komşu ve Ortadođu ülkelerinin durumları tahlil edildiğinde savaş koşullarının yerini barış ve istikrara bırakmasının çok yakın olmadığı gerçeğiyle karşı karşıyayız. Bunun diğer anlamı gerek ülkemizdeki mültecilerin gerekse de üzerine eklenecek yenilerinin uzun süre ülkemizde konaklamaları kaçınılmaz olacaktır. Politika yapıcılarının durumun giderek kronikleşmesinin önüne geçmesi ve de oluşan kamplaşmayı ortadan kaldırması acil önem arz ediyor. Dolayısıyla insanlarda oluşan 'Suriyeli mültecileri geri gönderme' algısının, 'mültecilerle bir arada yaşamak' sürecine doğru evrilmesi en doğru yol olacaktır. Oluşturduğumuz model buna hizmet etmek açısından bir ilk olma özelliği taşıyabilir. Daha kesin ve hassas bir model için örneklem sayısı, konu ve kapsam genişliği arttırmak yerinde olacaktır.

Kaynaklar

Acikalın, U.U., Bardak, B., Kutlu, M. (2021). BERT Modeli ile Türkçe Duygu Analizi. <http://earsiv.etu.edu.tr:80/xmlui/handle/20.500.11851/4264>.

- Akbulut, E. (2020). Misafirlikten Ötekiliğe Suriyeli Mülteciler ve İnsan Hakları: Sultanbeyli Örneği, Doktora Tezi, Maltepe Üniversitesi, Eğitim Enstitüsü, İstanbul.
- Akdeniz, E. Suriyeliler Geri Döner Mi? Evrensel Gazetesi *erişim tarihi: 18.06.2021*
- Bozdağ, F. (2021). Covid-19'un Suriyeli Mülteciler Üzerindeki Etkileri. *Eff Covid-19 Syr Refug*, 1, 701-722.
- Cemek, Y., Cidecio, C., Öztürk, AU., Çekinel, RF., Karagöz, P. (2020). Investigating The Neural Models For Irony Detection On Turkish Informal Texts . 28th Signal Processing and Communications Applications Conference (SIU), 1-4.
- Clark, K., Khandelwal, U., Levy, O., Manning, C.D. (2019). What does Bert Look at? an Analysis of BERT's attention . *ArXiv190604341 Cs. 1. http://arxiv.org/abs/1906.04341*.
- Delobelle, P., Winters, T., Berendt, B. (2021). RoBERT: a Dutch RoBERTa-based Language Model *http://arxiv.org/abs/2001.06286* .
- Devlin, J., Chang, MW., Lee, K., Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *http://arxiv.org/abs/1810.04805* .
- Erdoğan, M. M. (2014). Türkiye'deki Suriyeliler: Toplumsal Kabul ve Uyum Araştırması, İstanbul Bilgi Üniv.Yayınları.
- Hua, Y. (2019). Understanding BERT Performance in Propaganda Analysis Proc Second Workshop Nat Lang Process Internet Freedom Censorsh Disinformation Propag, 135-138, *Published online 2019, doi:10.18653/v1, D19-5019*.
- Karataş, İ. (2020). Türkiye'nin Vatandaşlık Politikalarının Öteki Algısındaki Rolünü Suriyeli Mülteciler Üzerinden Düşünmek, Süleyman Demirel Üniversitesi Fen-Edebiyat Fakültesi Sos Bilim Dergisi, 50, 17-42.

- Lan, Z., Chen, M., Goodman, S., Gimpel, K., Sharma, P., Soricut, R. (2020). ALBERT: A Lite BERT for Self-Supervised Learning Of Language Representations. <http://arxiv.org/abs/1909>.
- Le, H., Vial, L., Frej, J (2020). FlauBERT: Unsupervised Language Model Pre-Training for French <http://arxiv.org/abs/1912.05372>.
- Munikař, M., Shakya, S., Shrestha, A (2019). Fine-grained Sentiment Classification Using BERT. Artificial Intelligence for Transforming Business and Society (AITB), 1, 1-5.
- Nozza, D., Bianchi, F., Hovy D. (2020). What the [MASK]? Making Sense of Language-Specific BERT Models. <http://arxiv.org/abs/2001.06286>.
- Orhan, O. ve Gündođar, S.S. (2015). Suriyeli Sıđınmacıların Türkiye'ye Etkileri, Ortadođu Stratejik Arařtırmalar Merkezi, Türkiye Ekonomik ve Sosyal Etüdlr Vakfı, İstanbul.
- Ozan, ř. ve Tařar, D.E. (2021). Auto-tagging of Short Conversational Sentences Using Natural Language Processing Methods. <http://arxiv.org/abs/2106.04959>.
- Özdil, U., Arslan, B., Tařar, D.E., Polat, G., Ozan, ř. (2021). Ad Text Classification with Transformer-based Natural Language Processing Methods. <http://arxiv.org/abs/>.
- Öztürk, H., Deđirmenci, A., Güngör, O., Uskudarlı, S. (2020). The Role of Contextual Word Embeddings in Correcting The 'De., Da' Clitic Errors in Turkish . In: 2020 28th Signal Processing And Communications Applications Conference (SIU). Gaziantep-Türkiye, 1-4.
- Pota, M., Ventura, M., Catelli, R., Esposito, M. (2021). An effective BERT-Based Pipeline For Twitter Sentiment Analysis: A Case Study in Italian. *Sensors*, 21(1), 1-21.

- Rogers, A., Kovaleva, O., Rumshisky A. (2021). A primer in BERTology: What We Know About How BERT Works Trans Assoc Comput Linguist, 8, 842-866.
- Sevli, O., Kemalöglu, N (2021). Olağandışı Olaylar Hakkındaki Tweet'lerin Gerçek ve Gerçek Dışı Olarak Google BERT Modeli ile Sınıflandırılması, Veri Bilimi, 4(1), 31-37.
- Schweter, S. (2020). BERTurk - BERT Models for Turkish. Zenodo, doi:10.5281., zenodo.3770924
- Sığırcı, İO., Özgür, H., Oluk, A., et al. (2020). Sentiment Analysis of Turkish Reviews On Google Play Store, 5th International Conference on Computer Science and Engineering (UBMK), 314-315.
- Sun, C., Qiu, X., XuYi, Huang X. (2019). How to Fine-tune BERT for Text Classification? In: Sun M, Huang X, Ji H, Liu Z, Liu Y, eds. Chinese Computational Linguistics. Lecture Notes in Computer Science. Springer International Publishing; 2019:194-206. doi:10.1007., 978-3-030-32381-3_16.
- Vaswani, A., Shazeer, N., Parmar N. (2017). Attention is All You Need . Published Online December 5, <http://arxiv.org/abs/1706.03762>.
- Wang, T., Lu, K., Chow, KP., Zhu, Q. (2020). COVID-19 Sensing: Negative Sentiment Analysis on Social Media in China Via BERT Model. IEEE Access, 8, 138162-138169.
- Yadav, A., Vishwakarma, D.K. (2020). Sentiment Analysis Using Deep Learning Architectures: a Review, Artif Intell Rev. 53(6), 4335-4385.
- <https://www.milliyet.com.tr/gpt-3-nedir-gpt-3-neler-yapabiliyor> 16712 erişim tarihi: 21.05.2021.
- <https://www.unhcr.org/tr/wp-content/uploads/sites/14/2020/01/Multecilerin-Hukuki-Durumuna-Iliskin-Sozlesme> erişim tarihi: 11.04.2021.

<https://www.goc.gov.tr/ gecici-koruma563>, erişim tarihi:
19.12.2022.

<https://www.sozcu.com.tr/ 2020/ gundem/ turkiyede-kac-suriyeli-var-kaci-tc-vatandasi-oldu-3274793> erişim tarihi:
11.09.2021.

<https://www.istanpol.org/ post/ istanbul-da-suriyeli> erişim tarihi:
01.09.2021.

<https://www.analyticsvidhya.com/ blog/ 2019/ 06/ understanding-transformers-nlp-state-of-the-art-models> .
erişim tarihi:11.04.2021

<https://kaggle.com/ abhinando5/ bert-for-humans> erişim
tarihi:11.04.2021.

<https://www.analyticsvidhya.com/ blog/ 2020/ 07/ transfer-learning-for-nlp-fine-tuning-bert-for-text-classificatio>
erişim tarihi:21.04.2021.

