

T.C.
TRAKYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME İLE TÜRKÇE HABER METİNLERİNE BAŞLIK ÜRETME

ABDULKADİR KARACA

YÜKSEK LİSANS TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Tez Danışmanı: Dr. Öğr. Üyesi ÖZLEM AYDIN

EDİRNE-2021

ABDULKADİR KARACA'nın hazırladığı “**DERİN ÖĞRENME İLE TÜRKÇE HABER METİNLERİNE BAŞLIK ÜRETME**” başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından **Bilgisayar Mühendisliği** Anabilim Dalında bir **Yüksek lisans tezi** olarak kabul edilmiştir.

Jüri Üyeleri (Ünvan, Ad, Soyad):

İmza

Dr. Öğr. Üyesi Özlem AYDIN

.....

Dr. Öğr. Üyesi Mehmet Ali Aksoy TÜYSÜZ

.....

Dr. Öğr. Üyesi Aydın CARUS

.....

Tez Savunma Tarihi: 18/02/2021

Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Dr. Öğr. Üyesi Özlem AYDIN
Tez Danışmanı

.....

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

.....
Doç. Dr. Hüseyin Rıza Ferhat KARABULUT
Fen Bilimleri Enstitüsü Müdürü

T.Ü. FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS PROGRAMI
DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

18 / 02 / 2021

Abdulkadir KARACA

İmza

Yüksek Lisans Tezi
Derin Öğrenme ile Türkçe Haber Metinlerine Başlık Üretme
T.Ü. Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

ÖZET

İnternet kavramı geçmişten günümüze büyük bir değişim göstermiştir. Özellikle günümüzde birçok insanın çok kolay ulaşabildiği ve insanların kolaylıkla bağımsız içerik oluşturabildiği bir ortam haline gelmiştir. Ancak sağladığı bu kolaylıkların yanı sıra üretilen ham veriden bilgi elde etmek daha zor hale gelmiş ve üretilen içeriklere verilen başlıklar daha yanıltıcı olmaya başlamıştır. İnternete servis edilen bilginin çok fazla miktarda olması ve yanıltıcı bilgi içermesi, kısıtlı zamanında aradığı bilgiye kısa zamanda ulaşmak isteyen insan için olumsuz bir durum oluşturmaktadır. İnsanların istediği bilgiye hızlı bir şekilde ulaşmasına yardımcı olacak en belirgin özelliklerden biri içeriklere ait başlıklardır. Çünkü insan, bu başlıklardan yola çıkarak içeriğe ait bir ön bilgiye sahip olabilecektir. Ancak yanıltıcı başlıklar söz konusu olduğunda bu bir dezavantaja dönüşüp, istenilen bilgiye ulaşmayı engelleyebilmektedir. Bu tür yanıltıcı başlıkların üretildiği içeriklerin en başında haber metinleri yer almaktadır. Bu çalışmada derin öğrenme yöntemi ile Türkçe haber metinlerine otomatik olarak başlık üreten bir uygulama geliştirilmiştir. Veri seti olarak SuDer haber derleminden özetleme görevi için uygun olabilecek haber metinleri ayıklanarak, bu ayıklanan haberler bir dizi ön işlemlerden geçirilerek kullanılmıştır. Eğitim öncesi sözel verilerin sayısallaştırılmasında ve kelime gömmelerinin oluşturulmasında, derin öğrenme kütüphanelerinden Keras kütüphanesi kullanılmıştır. Modelin eğitimi için ise günümüzde doğal dil çalışmalarında sıklıkla tercih edilen transformatör mimarisi ile soyut özetleme yöntemi kullanılarak, haber başlıklarının üretiminde daha insansı sonuçlar elde etmek istenmiştir. Modelin 20 ve 25 dönem eğitimden sonra sırasıyla yaklaşık %75 ve %85 oranında doğruluğa ulaşarak, haber metinlerindeki bağlamı ifade etmekte yetenekli başlıklar üretebildiği gözlemlenmiştir.

Yıl : 2021

Sayfa Sayısı : 54

Anahtar Kelimeler : Otomatik Başlık Üretme, Soyut Metin Özetleme, Derin Öğrenme,
Transformatörler

Master Thesis
Generating Turkish News Headlines with Deep Learning
Trakya University Institute of Natural Sciences
Department of Computer Engineering

ABSTRACT

The concept of internet has changed greatly from past to present. Especially today, it has become an environment where many people can easily access and people can easily create independent content. However, in addition to these facilities, it has become more difficult to obtain information from the raw data produced and the titles given to the content produced have become more misleading. The excessive amount of information presented on the internet and the fact that it contains misleading information creates a negative situation for people who want to reach the information they seek in a limited time they have in a short time. One of the most obvious things that will help people quickly find the information they want is the content titles. Because, based on these titles, people will be able to have a preliminary knowledge of the content. However, when it comes to misleading titles, this can turn into a disadvantage and prevent access to the desired information. News texts are at the top of the content in which such misleading headlines are produced. In this study, an application that automatically generates headlines for Turkish news texts with deep learning method was developed. As a data set, news texts that might be suitable for the summarizing task were extracted from the SuDer news collection, and these extracted news were used after a series of pre-processes. Keras library, one of the deep learning libraries, was used to digitize verbal data before education and to create word embedding. For the training of the model, it was aimed to obtain more humanoid results in the production of news headlines by using the transformer architecture, which is frequently preferred in natural language studies today and the abstract summarization method. The model achieved approximately 75% and

85% accuracy after 20 and 25 periods of training, respectively. The model succeeded in generating headlines that could express the context in news texts.

Year : 2021

Number of Pages : 54

Keywords : Automatic Headline Generation, Deep Learning, Abstract Text Summarization, Transformers

TEŐEKKÜR

Bu alıőmanın araőtırma aőamasında ve hazırlanması sűrecinde her konuda bana yardımcı olan ve beni yűnlendiren kıymetli hocam Dr. Őđr. Ŭyesi Őzlem AYDIN'a ok teőekkűr ederim.

Uygulamanın kodlanması esnasında karőılaőtıđım problemler karőısında verdiđi her tűrlű yardım ve destekten dolayı Arő. Gűr. Dr. Emir ŐZTŪRK hocam iin teőekkűrű bor bilirim.

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xiv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	3
DOĞAL DİL İŞLEME	3
2.1. Doğal Dil'in Bilgisayar Bilimindeki Yeri.....	3
2.2. Bazı Doğal Dil İşleme Uygulamaları.....	5
BÖLÜM 3	7
OTOMATİK HABER BAŞLIĞI ÜRETME	7
3.1. Başlık Üretme Nedir?.....	7
3.2. Başlık Üretme Yöntemleri.....	8
BÖLÜM 4	11
DERİN ÖĞRENME	11
4.1. Derin Öğrenmenin Gelişimi.....	11

4.1.1. Yapay Zeka	12
4.1.2. Makine Öğrenmesi	12
4.2. Derin Öğrenme.....	13
4.3. Derin Öğrenme Yöntemleri.....	14
4.3.1. Evrişimli Sinir Ağları.....	15
4.3.2. Çekişmeli Üretici Ağlar	15
4.3.3. Yinelemeli Sinir Ağları	16
4.3.4. Uzun Ömürlü Kısa Dönem Belleği	18
4.3.5. Geçitli Yineleme Birimi	20
4.3.6. Transformatör Mimarisi	20
4.3.6.1. Konumsal Kodlama.....	22
4.3.6.2. Çok Başlı Dikkat Mekanizması	23
4.3.6.3. Noktasal İleri Besleme Ağ Katmanı	24
BÖLÜM 5.....	24
GELİŞTİRİLEN UYGULAMA.....	25
5.1. Veri Kümesi	25
5.2. Ön İşlemler.....	26
5.3. Eğitim Modeli	28
BÖLÜM 6.....	31
SONUÇLAR	31
6.1. Değerlendirme.....	31
6.2. Analiz	33
6.3. Yorumlar	34
KAYNAKLAR	35
EKLER.....	37
ÖZGEÇMİŞ.....	40

SİMGELER VE KISALTMALAR DİZİNİ

BERT	Bidirectional Encoder Representation from Transformer (Çift Yönlü Transformatör Kodlayıcı Temsilleri)
BLEU	Bilingual Evaluation Understudy (İki Dilli Değerlendirme Anlayışı)
CNN	Convolutional Neural Network (Evrışimli Sinir Ağları)
DARPA	Defense Advanced Research Projects Agency (İleri Savunma Araştırma Projeleri Ajansı)
DDA	Doğal Dil Anlayışı
DDİ	Doğal Dil İşleme
DDÜ	Doğal Dil Üretimi
DEFT	Deep Exploration and Filtering of Text (Derin Keşif ve Metin Filtreleme)
GAN	Generative Adversarial Networks (Çekişmeli Üretici Ağlar)
GRU	Gated Recurrent Unit (Geçitli Yineleme Birimi)
HBS	Heuristic Beam Search (Sezgisel Işın Araması)
LSTM	Long Short-Term Memory (Uzun Ömürlü Kısa Dönem Belleği)
RegEx	Regular Expression (Düzenli İfadeler)
RNN	Recurrent Neural Network (Yinelemeli Sinir Ağları)
ROUGE	Recall-Oriented Understudy for Gisting Evaluation (Geri Çağırma Yönelimli Özetleme Değerlendirme Anlayışı)
Seq2Seq	Sequence-2-Sequence (Uçtan Uca)
TF-IDF	Term Frequency - Inverse Document Frequency (Terim Sıklığı – Ters Belge Sıklığı)

VAE Variational Autoencoder (Değişimsel Otokodlayıcılar)

ŞEKİLLER DİZİNİ

Şekil 4.1. Yapay zeka, makine öğrenmesi ve derin öğrenmenin kronolojisi.....	11
Şekil 4.2. Makine öğrenmesi ile derin öğrenmenin karşılaştırılması.....	14
Şekil 4.3. Derin öğrenme algoritmalarının çok katmanlı öğrenme mimarisi.....	14
Şekil 4.4. Derin öğrenmenin en bilinen türlerinden CNN mimarisi.....	15
Şekil 4.5. Çekişmeli üretici ağ mimarisi.....	16
Şekil 4.6. Basit RNN modeli.....	17
Şekil 4.7. RNN'nin farklı uygulama modelleri.....	18
Şekil 4.8. LSTM'in anatomisi.....	19
Şekil 4.9. Seq2Seq model mimarisi.....	21
Şekil 4.10. Temel transformatör model mimarisi.....	21
Şekil 4.11. Öz dikkat mekanizması.....	23
Şekil 5.1. Modelin süreç adımlarını gösteren blok diyagram.....	29
Şekil 5.2. Modelin eğitim doğruluk oranı.....	29

ÇİZELGELER DİZİNİ

Çizelge 5.1. Cumhuriyet Gazetesi'nin derlem istatistikleri.....	25
Çizelge 5.2. Sabah Gazetesi'nin derlem istatistikleri.....	26
Çizelge 5.3. Ön işlenmiş haber ve başlık örneği - 1.....	27
Çizelge 5.4. Ön işlenmiş haber ve başlık örneği - 2.....	27
Çizelge 5.5. Ön işlenmiş haber ve başlık örneği - 3.....	28
Çizelge 6.1. Sistem tarafından üretilen başlık - 1.....	32
Çizelge 6.2. Sistem tarafından üretilen başlık - 2.....	32
Çizelge 6.3. Sistem tarafından üretilen başlık - 3.....	33
Çizelge 6.4. Genel deney sonuçları.....	33

BÖLÜM 1

GİRİŞ

Günümüzde çevrimiçi içeriklerin üssel olarak artması, beraberinde servis edilen bilgilerin de aynı oranda yanıltıcı bir şekilde karşımıza çıkmasına neden olmaktadır. Bu durum hem gereksiz bilgiye maruz kalma ihtimaline hem de gün içinde kısıtlı olan zamanı etkili kullanamama problemlerine sebep olmaktadır. Oluşan bu zaman kaybına ve yanlış bilgilendirme problemlerine nispeten engel olabilmek için, metinlerin içindeki ham veriden bağlamı doğru ifade edebilecek yeteneğe sahip başlıkları üretebilecek sistemlere ihtiyaç duyulmaktadır. Otomatik başlık üreten bu sistemler ile herhangi bir araştırmayla alakalı hangi kaynakların kullanılıp kullanılmayacağına karar verme sorununun çözümü kolaylaşacaktır. Bu çalışmanın da konusu olan haber metinleri için başlık üretme probleminin çözümü, içerikten bağımsız spekülatif olarak insan tarafından verilen yanıltıcı olabilecek başlıklara alternatif, içeriğe bağımlı başlıklar üreterek yanlış bilgilendirme sorununa bir çözüm sunmayı amaçlamaktadır.

Başlık üretmenin bir nevi metin özetleme görevi olduğu düşünülebilir. Bu şekilde özetleme mantığı üzerinden giderek, haber metinlerinde çıkarıma dayalı yöntemler kullanılabileceği gibi, metin bağlamını ifade edebilecek ve metnin içinde birebir bulunmayıp, aynı zamanda insan diline daha yakın sonuçlar elde etmemizi sağlayacak soyut temelli yöntemler de başlık üretmek için kullanılabilir. Bu iki yöntemin yapay zekanın çalışma alanları içinde bulunan makine öğrenmesi ve derin öğrenme yöntemleriyle bütünleşmiş bir şekilde kullanımıyla metin özetleme alanında daha başarılı çözümler elde edildiği görülmüştür. Varolan çözümlerin yanı sıra her geçen gün daha yeni ve daha özgün farklı yöntemler de önerilmektedir.

Bu alıřmada ilk olarak, dili anlamada en nemli role sahip olan Doęal Dil İřlemenin (DDİ) tanımı yapılmıřtır ve DDİ kullanılarak yapılan bazı uygulama rnekleri anlatılmıřtır (Blm 2). Daha sonra bu alıřmanın konusu olan bařlık retmenin tanımı ve neden ihtiya duyulduęundan bahsedilmiřtir. Bu konuyla alakalı gemiřten gnmze sunulan bazı zm yntemleri kısaca aıklanmıřtır (Blm 3). Ardından DDİ'nin matematiksel hesaplama tarafında yer alan ve DDİ'yi iřleyebilecek kabiliyete sahip olan derin ęrenme kavramının tanımı ve geliřiminden sonra farklı alıřma alanlarında da kullanılabilen derin ęrenme yntemleri bařlıklar halinde incelenmiřtir (Blm 4). Sonrasında ise temelinde DDİ, bařlık retme ve derin ęrenme gibi kavramları barındıran, bu alıřma iin geliřtirilen uygulama tanıtılmıřtır (Blm 5). Bundan sonra ise uygulama ile retilen sonular deęerlendirilip, analizleri yapıldıktan sonra daha etkili sonuların nasıl retilbileceęine dair yorum kısmı ile alıřma sonlandırılmıřtır (Blm 6).

BÖLÜM 2

DOĞAL DİL İŞLEME

2.1. Doğal Dil'in Bilgisayar Bilimindeki Yeri

DDİ, insanın en önemli iletişim aracı olan dili kullanarak, bilgisayarla iletişime geçme çabası olarak tanımlanabilir. Yeryüzünde kullanılan doğal dillerin var olan kurallı yapısının çözümlenerek anlaşılması, makinelerin anlayabileceği iki durumlu forma ve matematiksel normlara indirgenerek yeniden makine tarafından üretilmesinin amaçlandığı bir çalışma alanıdır. Başka bir tanımla da makine ile yazı ve ses gibi dil öğelerinin analiz edilerek veriden bilgiye dönüştürülmesi şeklinde de açıklanabilir. Daha birçok farklı şekilde yaklaşık olarak aynı anlamları içeren tanımlar yapılabilir. Fakat temelde bütün tanımlar aynı şeyi ifade etmektedir. İnsanlar arasında daha birbirlerini gördükleri andan itibaren başlayan anlamlı iletişimin, makinelerle de bu seviyede hatta daha üstün iletişim seviyelerine ulaşılmasını amaçlayan disiplinler arası alt bir çalışma alanıdır. Yapay zeka alanında çalışmalar yapan Cerebro Tech. firması bir blog yazısında, belki de DDİ alanındaki en iyi araştırmacıların yazdığı geniş kapsamlı ders kitaplarından birinde, konuya hem klasik dilbilim hem de modern istatistiksel yöntemlerin tartışılmasına izin veren “Dilbilim Bilimi” şeklinde bir ifade ile karşılaştığını belirtmiştir (Cerebro Tech., 2018, parag.16). “Deep Learning for Natural Language Processing” isimli kitabın (2017) yazarı olan Jason Brownlee'nin, DDİ ile alakalı birçok kaynaktan faydalanarak yazmış olduğu bir blog yazısında “Dilbilim, dil bilgisi, anlam bilim ve fonetik dahil olmak üzere bilimsel bir çalışma alanıdır.” tanımıyla ifade edilmiştir (Brownlee, 2019). Aynı zamanda dilbilim, dilin kurallarının geliştirilmesini ve daha etkili bir şekilde ifade edilmesini amaçlamaktadır (Brownlee, 2019).

Dilin kurallı yapısı büyük ölçüde deterministik olarak matematiksel formüller olarak açıklanabilse de insan beyninin deterministik bir yapıya sahip olmamasından dolayı genelgeçer bir formüle sahip değildir. Aynı zamanda dilin yaşayan canlı organizma gibi gelişen bir yapıda olması, kalıcı formül ve çözümler elde etmeyi neredeyse imkansız hale getirmektedir. Dilbilim, yaşanan teknolojik gelişmelerin de neticesi olarak, klasik dilbilimin haricinde hesaplamalı dilbilim adı altında çalışma alanına da sahip olmuştur. Hesaplamalı dilbilim, bilgisayar bilimi araçlarını kullanarak modern dilbilimsel çalışmaları yürüten bir alt alandır. Bu alan genel olarak doğal dil üzerindeki insanın ihtiyaç duymadığı ve göz ardı ettiği istatistiksel yapıları kullanarak yeni ve daha etkili istatistiksel yapılar elde etmeyi amaçlamaktadır. İstatistiksel yapıların matematiksel çözümleri dışında mühendislik tabanlı çözümleri de yansıtabilmesi için DDİ adıyla bilinmektedir (Brownlee, 2019).

DDİ kullanılırken iki aşama olduğu söylenebilir. İlk olarak DDA olarak kısaltabileceğimiz doğal dil anlayışıdır. DDA'da girdi olarak gelen sesli veya yazılı olan doğal dilin makineler tarafından sözdizimsel ve anlamsal olarak insan seviyesinde anlaşılması amaçlanmaktadır. Örnek olarak "Aldığın kalemi geri koy." cümlesi ile "Günün bu saati koy yüzmek için sakindir." cümlesi arasındaki farkı anlamak için, beynimiz her ne kadar arka planda karmaşık işlemler yapsa da, insanın farkında olarak ekstra bir çaba sarf etmesi gerekmez. İlk cümlede geçen "koy" için fiil, ikinci cümlede geçen "koy" için ise rahat bir şekilde isim diyebilir. Doğal dili anlama açısından makineye doğru bir şekilde ifade etme çabasından sonra, bu çabanın karşılığı olarak anlamlı bir şekilde doğal dili üreterek iletişimin devamlılığının sağlanması gerekmektedir. Bu da DDİ'nin ikinci aşaması olan, DDÜ olarak kısaltabileceğimiz doğal dil üretimi aşamasıdır. Bu aşamadaki amaç ise makine tarafından üretilen çıktının sözdizimsel ve bağlamsal olarak insanın anlayabileceği seviyede olmasıdır. Buradaki temel problemler ise ilk olarak makinenin ürettiği çıktıda sözcükleri doğru seçmesi ve doğru yerde kullanmasıdır. İkinci olarak metin akışının yani bağlamın uygun olmasıdır. Son olarak ise dilbilgisi ve morfolojik kurallara uygun olmasıdır. Yani DDİ'yi oluşturan iki kavramdan biri olan DDA'da amaç okuduğunu anlamaya odaklanırken, ikincisi olan DDÜ'de bilgisayarın doğal dile uygun yazmasına odaklanılır (Kavlakoğlu, 2020).

DDİ için çok geniş çalışma alanı vardır. Bu çalışma alanlarıyla alakalı problemleri tek bir şekilde çözmeyi başarabilecek yöntem veya algoritma henüz mevcut değildir. Yani

asıl amaç yapay zeka ve DDİ çalışmalarının tamamına tek bir algoritma veya yöntem ile sonuç üretilmesidir. Böyle bir başarı seviyesine henüz ulaşamamıştır. Yapay zeka ve DDİ alanlarında farklı uzman sistemler için özelleşmiş çalışmalarda yüksek başarılar elde edilmiş olsa da aynı çözüm başka bir DDİ uzman sisteminde doğru sonuç vermeyebilir. Örneğin; DDİ, soru cevaplama, bilgi çıkarımı, duygu analizi, makine çevirisi, nesne tanıma gibi ayrı ayrı problemler üzerinde başarılı çözümler üretse de genel DDİ problemlerini tek elde çözebilecek bir çözüm yöntemi henüz bulunmamaktadır.

2.2. Bazı Doğal Dil İşleme Uygulamaları

Doğal dil, insanların en önemli iletişim aracı olmasından, insan ve bilgisayar etkileşiminde nispeten bir arayüz aracı olarak tercih edilmesinden dolayı, bunun neticesi olarak çok önemli ve geniş bir çalışma alanına sahiptir. Bu çalışma alanlarının ortaya çıkardığı uygulamalara ilk olarak kelime kökü bulma, varlık ismi tanıma gibi doğal dilin çözümlenmesi problemlerini örnek olarak vererek başlayabiliriz. Bu çalışmalar, kullanıldığı dilin anlaşılmasında metnin anlamını bozmadan, gereksiz sözcüklerin azaltılmasını sağlar. Dilin morfolojik yapısının anlaşılması ve dili matematiksel olarak daha iyi ifade edebilme açısından önemlidir.

DDİ uygulamalarına örnek olarak; özel bir şirketin kendi servisleri içinde kullandığı, yazılı veya sözlü veriden DDİ özellikleri ile bilgi keşfi ve etiketlenmesi için bir çözüm mimarisi hizmeti vardır. Burada amaç verilerin doğruluğunun ya da kullanılabilirliğinin artırılmasıdır. Sosyal platformlar, forumlar ve diğer metinlerde ağırlıklı olarak soru-cevap hizmetlerinde dizin oluşturma ve kullanıcıya seçme veya arama kolaylığı sağlayan etiketler yoğun olarak kullanılmaktadır. Doğru etiketleme çözümüne sahip olmayan web platformlarının, kullanıcıya geri dönüşlerdeki etki düzeyi diğerlerine oranla çok daha düşüktür. Bu uygulama ile bu sorunun ortadan kaldırılması amaçlanmaktadır (Microsoft, 2021).

Başka bir uygulama da askeri ve milli güvenlik alanlarındaki tehditlerin önceden keşfedilerek güvenliğinin sağlanmasının hedeflendiği DARPA (Defense Advanced Research Projects Agency, İleri Savunma Araştırma Projeleri Ajansı) tarafından geliştirilen DEFT (Deep Exploration and Filtering of Text, Derin Keşif ve Metin Filtreleme) uygulamasıdır. Bu sistem metinlerdeki sözcüklerin veya konuşmaların ifade ettikleri farklı anlamları insan hassasiyetinde yakalayabilmektedir. Bağlam ilişkisini fark

edebilmekte ve farklı anlamlar üreterek, bunların analizini yapabilmektedir. (Harris, 2014).

DDİ ile yapılan çalışmalardan biri de konuşma tanımadır. Derin öğrenme alanında yüksek başarılı çalışmalara imza atan ve Çin'in en büyük arama motorunun baş uzmanı olan Andrew NG tarafından, gürültülü ortamlarda dahi sesli komutları anlayıp bu komutları yerine getirebilen bir uygulama geliştirilmiştir. Bu uygulama geliştirilirken GPU ile 100.000 saatlik konuşma verisi kullanılarak eğitilmiştir (Kurt, 2015, parag.2). Baidu firmasının geliştirmiş olduğu bu çözümün Derin Konuşma 2.0 adını verdiği versiyonunda, eğitilen yarım saatlik bir ses verisinden dahi yüzlerce aksanı öğrenip, gerçek insan seslerini taklit edebilir seviyeye geldiği görülmüştür (Popper, 2017, parag.2).

Chatbotlar günümüzde özellikle belli bir hizmet pazarlayan firmalar için hızlı çözümler üretilebilmesi, ilgili hizmete hızlı bir şekilde erişilebilmesi amacıyla oluşturulmuş geniş çalışma alanına sahip DDİ çözümleridir. Konuşma temsilcileri veya konuşma sistemleri olarak da isimlendirilebilen chatbotlar birçok büyük firma tarafından geliştirilmekte ve kullanılmaktadır. Bu çözümler sunulurken ise DDİ ile derin öğrenme yöntemlerinden faydalanılmaktadır (Britz, 2016, parag.1, 2).

Bir başka uygulama ise derin görsel-anlamsal hizalama modeli ile görüntü için tanımlanan açıklama metninin uygun şekilde parçalanması sağlanarak, görüntü alanları ve metin parçacıklarını birleştiren yani görüntülerdeki nesnelere tanıyıp işaretleyen bir uygulamadır. Geliştirilen model her görüntü için tanımlanan farklı cümleler içinden, en uyumlu cümleyi almakta ve bu cümle parçalarını geometrik şekillerle sınırlandırarak ilgili görüntü üzerinde işaretlemektedir (Karpathy & Fei-Fei, 2015).

BÖLÜM 3

OTOMATİK HABER BAŞLIĞI ÜRETME

3.1. Başlık Üretme Nedir?

Başlık üretme, belirli bir dilde yazılmış olan nispeten uzun metinleri, metnin bağlamına uygun olan en saf ve kısa şekilde kısaltarak açıklamak ve bu sayede metni okumadan önce, metni okuduktan sonra elde edilebilecek kazanımları daha net bir şekilde önceden kestirebilmeyi amaçlayan bir çalışma alanıdır. Bu problemin çözümü için ise bağlama uygun doğal dil üretmenin morfolojik sorunlarına karşın genel olarak metin özetleme yöntemleri kullanılır.

Metin özetleme kendi içinde oldukça geniş ve farklı başlıklar barındıran bir çalışma alanıdır. Özetleme görevleri için girdinin türüne göre, bağlama göre ve çıktının türüne göre farklı özetleme yöntemleri mevcuttur. İlk olarak girdinin türüne göre tekli veya çoklu belgeden özet üretilebilmektedir. Tekli belge özetleme herhangi başka bir belge referans alınmadan yapılan özetleme yöntemidir, yani burada özeti üretmek için tek bir kaynak kullanılır. Bu çalışmada da ilgili bağlam özetlenirken tek bir belgeden elde edilen metinler kullanılmaktadır. Çoklu belge özetleme ise bir metin bağlamına ait farklı belgelerin de referans alınarak özeti üretilmesidir. Yani özet oluşturulurken birden fazla kaynak kullanılarak, ana bağlamı ifade edecek kadar güçlü ve bağlamı farklı bakış açılarından değerlendirebilecek kadar özgün özetlerin üretilmesi sağlanmaktadır. Başka bir özetleme yöntemi olarak ise bağlama göre özetleme, yani alana özgü, sorgu tabanlı ve genel özetleme yöntemleri bulunmaktadır. Alana özgü yöntemde bağlam belli bir konu üzerinedir. Örnek olarak, klasik fizik veya kuantum fiziği gibi tek bir konu ile alakalı metinlerin özetlenmesi sağlanır. Sorgu tabanlı özetleme ise daha çok web tarayıcılarında

sorgu metnini yazıp, arama yaptıktan sonra karşımıza çıkan sonuçların alt kısımlarında yer alan, açıklama olarak gösterilen özetlerdir. Bağlama yönelik son yöntem ise aynı zamanda bu çalışmadaki yöntem olan belirli bir alana ve sorguya bağlı kalmadan her türlü konuda içeriği bulunabilen genel metinlerin özetlenmesidir. Metin özetleme yöntemlerinin sonuncu başlığında ise çıktının türüne göre yani çıkarıma dayalı ve soyut özetleme yöntemleri bulunmaktadır. Çıkarıma dayalı özetleme, metindeki cümlelerin kendi arasında puanlanarak bağlamı en iyi ifade edebilecek, en yüksek puanlara sahip belli oranda bir cümlenin seçilip değiştirilmeden özetin oluşturulmasıdır. Bu yöntem daha çok kitap gibi bağlamın korunması zor olan uzun metinlerde tercih edilir. Soyut özetleme ise derlem içindeki sözcüklerin anlamlandırılıp, metin bağlamı yorumlanarak, bağlamı ifade edebilecek kadar güçlü ve kısa metinlerin üretilmesidir (Nekic, 2019).

3.2. Başlık Üretme Yöntemleri

Geçmişten günümüze metinlere başlık üretmek için çok farklı yöntemler önerilmiştir. Bu yöntemlerin neticesinde elde edilen sonucun metin bağlamına bağlı, kapsamlı ve morfolojik açıdan okunabilir olması gerekmektedir. Üretilen başlık, belirginlik, uzunluk, tutarlılık ve gramerin yanı sıra gereksiz sözcüklerin de olmaması gibi kriterler göz önünde bulundurularak değerlendirilir. Bu türlü çalışmaların ilk zamanlarında Baxendale (Baxendale'dan aktaran Nekic, 2019) 1958 yılında konumsal yöntem adını verdiği, 200 paragraf üzerinde yaptığı çalışmasında, paragrafin ilk ve son cümlelerinin sırasıyla %85 ve %7 oranında başlık cümlelerini ifade ettiğini öne sürmüştür. Aynı yıl Luhn (Luhn'dan aktaran Nekic, 2019) sözcük frekanslarını kullanarak cümleleri puanlandırma yoluyla bir yöntem geliştirmiştir. 1968 yılında ise Edmunson (Edmunson'dan aktaran Nekic, 2019) cümlenin pozisyonu, sözcük frekansı, önemli cümleleri işaretleme ve belgenin gramer yapısının özelliklerini kullanarak geliştirmiş olduğu bir fonksiyonla çözüm önermiştir. 2004 yılında ise sözcüksel merkezli ve grafiksel tabanlı LexRank yöntemi önerilmiştir. Bu yöntemde cümleleri oluşturan sözcükler baz alınarak ters belge sıklığına göre (TF/IDF) cümlelerin önemleri hesaplanır. Aynı konu hakkındaki farklı belgelerden, farklı cümleler düğüm olarak gösterilir. Cümleler arasındaki ilişkiler ise belirli eşik değer aralıklarına göre kenar olarak gösterilir. Kenar ilişkilerinin ağırlıkları, kosinüs benzerlik matrisi şeklinde hesaplanarak en yüksek ağırlığa sahip düğümün yani cümlenin ve bu düğümle ilişkili olan diğer düğümlerin

bağlamı en iyi ifade edebilecek cümleler olduğuna karar verilir (Erkan & Radev, 2004). Buraya kadar olan yöntemler çıkarıma dayalı yöntemlerdir (Nekic, 2019).

Günümüzde ise bilgisayar sistemlerinin karmaşık hesaplamaları yapabilecek kaynaklara sahip olmasıyla, her ne kadar ortaya çıkışı 1980'li yıllara uzansa da, makine öğrenmesi ve derin öğrenme alanları çok da eski denilemeyecek bir zamanda DDİ problemleri için çözüm sunulmasına olanak sağlamıştır. Bu sayede de DDİ ile ilgili problemlerin çözümünde de aktif olarak Yinelemeli Sinir Ağları (Recurrent Neural Network, RNN), Uzun Ömürlü Kısa Dönem Belleği (Long Short-Term Memory, LSTM), Geçitli Yineleme Birimi (Gated Recurrent Unit, GRU) gibi kodlayıcı-kod çözücü tabanlı uçtan uca (Seq2Seq) mimariler kullanılmaya başlanmıştır. DDİ ile ilgili bu mimarileri kullanan birçok çalışma mevcuttur. Güncel olarak ise DDİ problemlerinin çözümünde son teknoloji olarak yüksek başarı oranlarıyla karşımıza çıkan, temel ve çeşitli transformatör mimarileri kullanılmaktadır. Bu mimariler hem çıkarıma dayalı hem de soyut özetleme görevlerinde sıkça tercih edilmektedir.

Literatürde bu konu üzerine daha farklı çalışmalar ve çözüm yöntemleri de bulunmaktadır. Güncel olarak, 2020 yılının Nisan ayında yayınlanan akademik bir çalışma bu konu için güzel bir örnek olarak verilebilir. Bu çalışmada çözüm olarak sunulan mantık, genel olarak başlık üretme problemlerinin çözümü olarak sunulan özetleme çözümü olarak ele alınmamıştır. Yani bu çalışmanın çözüm mantığı, haber metinlerindeki çoğu bilgiyi en az fazlalıkla yakalayıp sonuç üretmek değildir. Bunun yerine haberin hikayesi ile alakalı farklı kaynaklardan elde edilen diğer haber metinleriyle de ortak olan bilgileri kısa uzunlukta yakalamaktır. Yani sonuç üretirken her bir makalenin kendine özgü bilgisini hariç tutarak, doğru kısma odaklanmayı hedeflemişlerdir. Bu farklı yaklaşımı sunarken ilk olarak eğitim verisinin az olduğu durumlarda kullanılan, herhangi bir insan açıklamasına ihtiyaç duymayan büyük ölçekli uzaktan denetim yaklaşımını (Distant Supervision Approach) geliştirmişlerdir. Bu yaklaşım teknik iki bileşene odaklanmaktadır. İlk odağı farklı seviyelerde kalite-miktar dengesindeki farklılık ve etiketlenmemiş çok büyük bir derlem içeren çok seviyeli ön eğitilmiş framework (çatı) yapısıdır. İkinci olarak ise sonuç üretme aşamasında haber metniyle alakalı, birden çok haber metni tarafından paylaşılan ve ortak olan önemli noktaları algılayabilen yeni bir öz oylama tabanlı makale dikkat mekanizması kullanımını

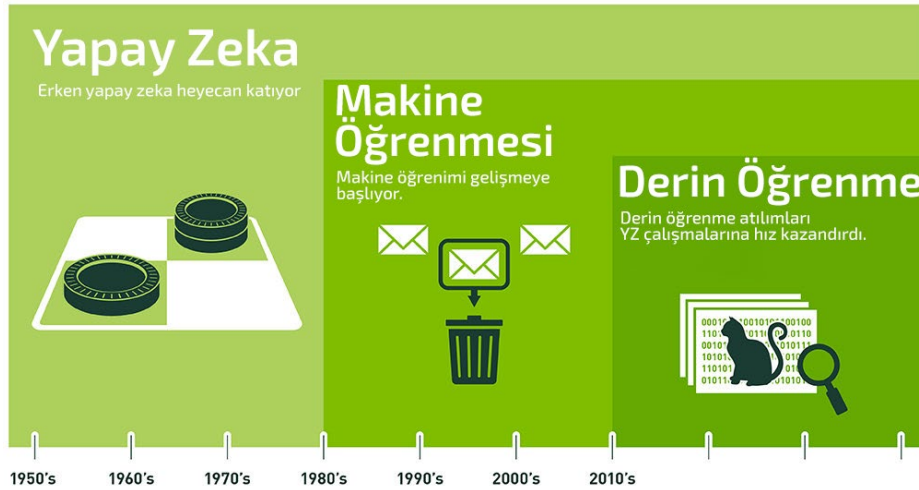
önermişlerdir. Modelin eğitimini ise NHNET adını verdikleri ve temel transformatör mimarisini kullanan kodlayıcı-kod çözücü bir model ile yapmışlardır (Gu vd., 2020).

BÖLÜM 4

DERİN ÖĞRENME

4.1. Derin Öğrenmenin Gelişimi

Derin öğrenmenin tanımından önce yapay zekanın ve makine öğrenmesinin tanımları yapılmalıdır. Çünkü bu üç terim arasında sıkı bir ilişki bulunmaktadır. Şekil 4.1’de ise bu terimler arasındaki sıkı ilişkinin zaman içindeki gelişimi görülebilmektedir.



Şekil 4.1. Yapay zeka, makine öğrenmesi ve derin öğrenmenin kronolojisi (Kaynak: <https://developer.nvidia.com/deep-learning>).

4.1.1. Yapay Zeka

Yapay zeka kavramı, 1950'li yıllarda bilgisayar biliminin babası olarak kabul edilen Alan Turing'in doktora tezinde, tarihe Turing Testi olarak geçen, makinelerin de düşünebileceği fikrini ortaya atmasıyla çıkmıştır. Bu testte sorgulayıcı, karşısındakinin insan mı yoksa makine mi olduğunu bilmeden, birbirlerinden izole olan insan ve makine sistemiyle etkileşime girer. İnsan karşısındakinin makine olup olmadığını ayırt edemez, insan olduğunu düşünürse Turing testi başarılı olarak geçilmiş olur ve bu da zeki, düşünebilen bir makine ile karşı karşıya olduğumuz anlamına gelmektedir. Günümüzde bu testi geçebildiği iddia edilen çalışmalar olsa da henüz Turing testini geçebilecek kadar başarılı bilinen bir makine de bulunmamaktadır. Yapay zekanın asıl isim babası ise 1956 yılında konuyla alakalı akademik bir konferansta konuşma yapan John McCarthy'dir. Konferansın sonunda katılımcıların vardıkları ortak görüş yapay zeka ile ilgili çalışmaların ileri bir seviyeye çıkarılması gerektiği yönünde olmuştur (Şener, 2017, parag.2). DDİ konusu da yapay zekanın öncelikli çalışma alanlarından biridir.


4.1.2. Makine Öğrenmesi

Makine öğrenmesi, yapay zekanın alt çalışma alanlarından biridir ve bu konuyla alakalı çalışmalar kronolojik olarak 1980'li yıllarda başlamıştır (Şekil 4.1). Makineye verilen eğitim veri kümelerinin belli bir problem karşısında nasıl davranıp, bu davranış karşısında veriden sonuç olarak elde edinilmesi istenilen bilgilerin etiketlenerek veya tanımlanarak makineye bu davranışın öğretilmesi olarak açıklanabilir. Makine öğreniminin en öne çıkan çalışmalarından biri ise görüntü tanımadır. Makine, verilen binlerce resimden benzer piksel, desen gibi kendine göre bazı özellikleri tanımaya başlar ve birbirlerinin ortak yönlerini tespit ederek öğrenir. Böylece görüntülerin birbiri arasındaki farkları ayırt edebilecek yeteneğe sahip olabilir. Yine bu benzer yöntemleri kullanarak dijital yayın platformları bizlerin alışkanlıklarını öğrenerek hangi filmleri, dizileri beğendiğimizi; aynı şekilde dijital satış platformlarının sundukları ürünlere göre nelerden hoşlandığımızı tahmin etmesi, makine öğrenmesinin bir ürünüdür. Makine öğrenmesi, kullanıcıların hareketlerini analiz ederek bu sonuçları üretmektedir. Bu hareketlerin analizinde Semantik Web olarak bilinen Web 3.0 teknolojisiyle entegre olarak Google gibi arama motorlarında yapılan sorgulamalar, Twitter gibi sosyal platformlardaki aktiviteler, takip edilen hesaplar gibi çapraz web platformlarında

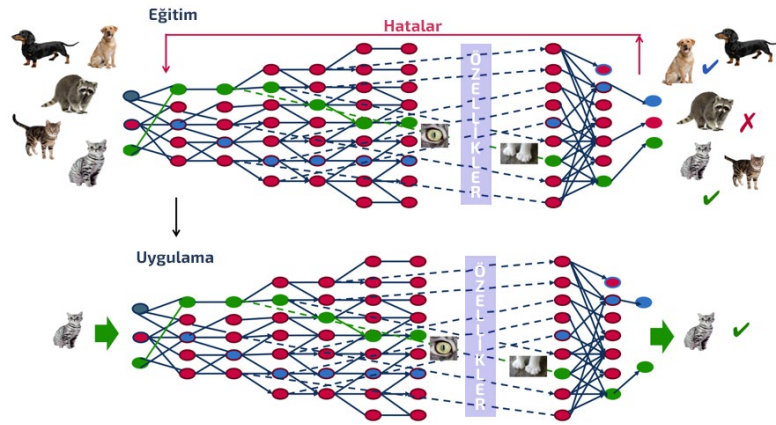
birbirleriyle ilişkilendirilmiş olan verilerin makine öğrenmesi yöntemleriyle kullanılması sayesinde daha başarılı sonuçlar elde edilebilmektedir.

4.2. Derin Öğrenme

Derin öğrenme için tek katmanlı olarak çalışan makine öğrenmesinin çok katmanlı bir yapıda çalışan hali olduğu söylenebilir. Yani makine öğrenmesi algoritmalarıyla, çözümü için üzerinde çalışılan algorithmada sadece bir durum elde edilirken; derin öğrenme ile birden çok durumu ayrı ayrı öğrenen makine öğrenmesi algoritmaları, birbirleriyle çok katmanlı bir yapıda çalışarak sonuç üretir. Bahsedilen yapıda bir makine öğrenmesi algoritmasının sonucu başka bir makine öğrenmesi algoritmasının giriş verisidir. Örneğin, bir muz resmi ile portakal resminin makine öğrenmesi ile ayrılması gerektiğinde, insanın bugüne kadar edinmiş olduğu tecrübeler parametreler vasıtasıyla makineye tanıtılmaya çalışılır. Örneğin; “Turuncu ise muhtemelen portakaldır.”, “Sarı ise muzdur.” veya “Yuvarlak ise muhtemelen portakaldır.”, “Yay şeklindeyse muhtemelen muzdur.” vb. birçok parametrenin tanımlanması gerekebilir. Fakat derin öğrenme görüntüler arasındaki bu farklı özellikleri kendi başına öğrenebilmektedir (Şekil 4.2). Örnek olarak Şekil 4.3’te gösterilen illüstrasyonda kedi, köpek vb. hayvan görüntüleri eğitim amacıyla derin öğrenme sistemine verilerek, kedinin tanınabilmesi için göz, pati vb. özelliklerin ana ayırıcı özellikler olduğunu otomatik olarak fark edebilmektedir. Böylece temel insan yetilerine ihtiyaç duymadan, kendi ayrıştırıcı özelliklerini oluşturarak eğitimini gerçekleştirebilir. Hataları optimize ederek, hatalarından ders alarak eğitimini tamamlamaktadır. Eğitimden sonra sisteme verilen görüntüler için de sonuç çıktısı üretilmektedir. Neticede açıklananlardan yola çıkarak, Şener’in bir blog yazısındaki “Büyük veri denizi ile tek bir katmanda değil, birçok katmanda makine öğreniminde kullanılan hesapları tek bir seferde yapan, makine öğreniminde tanımlamanız gereken parametreleri bile kendisi keşfeden, belki de daha iyi parametreler ile değerlendirmelerde bulunabilen bir sistemdir.” tanımı da daha açıklayıcı olmaktadır (Şener, 2017, parag.23).



Şekil 4.2. Makine öğrenmesi ile derin öğrenmenin karşılaştırılması.



Şekil 4.3. Derin öğrenme algoritmalarının çok katmanlı öğrenme mimarisi.


4.3. Derin Öğrenme Yöntemleri

Yapay zeka kavramında genel bir zekadan bahsedilemediği ve tek bir uzman algoritma diyebileceğimiz genel bir çözüm yöntemi olmadığı için, farklı görevleri icra etmekte göreve bağlı olarak çözüm yöntemleri de farklılaşmaktadır. Bu farklar temel olarak görsel ve doğal dili ilgilendiren işitsel ve metinsel görevlerdir. Hatta görsel olarak mevcut olan resim, fotoğraf ve video gibi verileri işlerken kullanılan yöntem Evrişimli Sinir Ağları (Convolutional Neural Network, CNN) iken, bunları üretmeye yönelik olarak kullanılan yöntem ise Çekişmeli Üretici Ağlar (Generative Adversarial Networks, GAN) olarak farklılık göstermektedir. Hava durumu tahmini, borsa tahmini gibi sıralı veriler barındıran işlemler için genel olarak RNN ve türevleri kullanılmaktadır. Fakat doğal dil gibi sıralı veriler barındıran işlemlerde ise doğal dili anlamakta daha başarılı olan

transformatör tercih edilmektedir. Bahsi geçen yöntemler uyarlanıp farklı çözümler için kullanılabilir de genel kullanım amaçları bu yöndedir.

4.3.1. Evrişimli Sinir Ağları

CNN, derin öğrenme sinir ağlarının en bilinen türlerinden biridir. CNN, iki boyutlu evrişim katmanları kullanarak öğrenilen verileri girdi verileriyle birleştirir ve iki boyutlu verilere uyan bir mimari oluşturur (Şekil 4.4). Otomatik belirli matematiksel ve istatistiksel hesaplarla çıkarılan özellikler sayesinde öğrenme modelleri daha da hassas bir öğrenme ve sonuç performansı gösterir.



Şekil 4.4. Derin öğrenmenin en bilinen türlerinden CNN mimarisi.

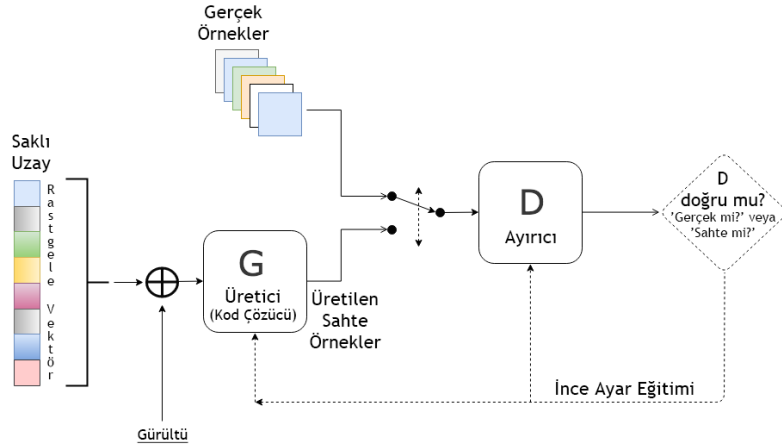
Ayırıcı özelliklerin, öğrenme algoritmasının eğitimi aşamasında farklı katmanlarda öğrenilmesinden dolayı, katman derinliği arttıkça özelliklerin karmaşıklığı artmaktadır. Dolayısıyla ilk katmanlarda sadece nesnelerin kenar gibi basit özellikleri tespit edilebilirken, son katmanda nesnenin görüntüsü öğrenilebilecek kadar özellik çıkarılmış olur. Yine bu mimarilerin kendi içlerinde de daha performanslı çözümler üretebilmek için farklılaşmış türleri bulunmaktadır.

4.3.2. Çekişmeli Üretici Ağlar

GAN mimarisi görüntü üretimi konusunda Değişimsel Otokodlayıcılar'a (Variational Autoencoder, VAE) alternatif olarak önerilen bir yöntemdir. GAN'ın temel mantığına örnek olarak, Picasso resimlerini taklit eden biri düşünülür ve taklitçi başta bu görevde kötüdür. Bu taklidini bir galericiye gösterir ve galerici de Picasso resimlerini

Picasso resmi yapan özgün özellikler hakkında bilgi verir. Bu sayede taklitçi daha iyi Picasso resmi yapmayı, galerici ise taklit eserleri anlama konusunda uzmanlaşır. Sonuç olarak ise mükemmel sahte Picasso resimleri ortaya çıkmaya başlar. Yani burada taklitçi ve uzman ağ ayrı ayrı en iyi olmak için eğitilir (Chollet, 2019, s.326).

GAN mimarisinde kullanılan iki temel ağdan biri olan üretici ağ, rastgele bir vektörü girdi olarak alır ve yeni bir resim olarak kod çözücüde üretir (Şekil 4.5). Ayırıcı ağ ise, girdi olarak gerçek veya üretilen sahte resimlerden bir örnek alır. Bu örneğin gerçek veri setinden mi yoksa ağın ürettiği resim mi olduğunu tahmin etmeye çalışarak kendisini eğitir. Sonuç olarak ise üretici ağa ince ayar bildirimlerini göndererek eğitimin doğru ve başarılı bir şekilde ilerlemesini sağlar (Chollet, 2019, s.326).



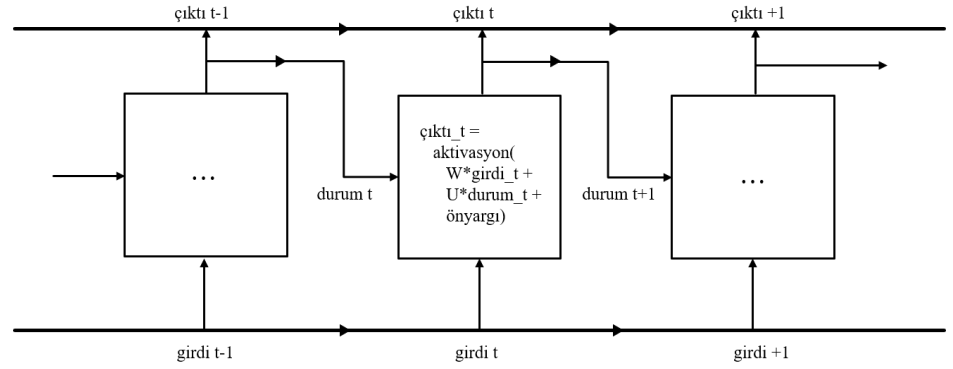
Şekil 4.5. Çekişmeli üretici ağ mimarisi.

4.3.3. Yinelemeli Sinir Ağları

RNN için Rumelhart vd. tarafından (Rumelhart vd.'den aktaran Goodfellow, Bengio, Courville, 2018, s. 373) sıralı verileri işlemek için özelleştirilmiş sinir ağları ailesi, şeklinde bir tanım yapılmıştır. CNN'ler görüntü benzeri uzamsal ilişkisi olan verileri işlemek için kullanılır. RNN'ler de $x^{(1)}, \dots, x^{(t)}$ gibi sıralı verileri işlemek için özelleştirilmiştir. CNN'ler büyük genişliğe ve yüksekliğe sahip görüntülere ölçeklenebilir ya da değişken boyutlardaki görüntüleri işleyebilir. Bunun gibi RNN'ler de sıra tabanlı


veriler için özelleşmiş olmayan ağların işleyebileceğinden daha büyük sıralı dizilere ölçeklenebilir ve bu dizileri işleyebilir (Goodfellow vd., 2018, s.373).

CNN'nin ana karakteristiği, hafızalarının olmaması ve her girdiyi birbirinden bağımsız olarak işlemesiyle bunlar arasında durum bilgisi tutmamasıdır. Fakat şu anda bu cümleleri okurken aralıklı göz hareketleriyle adım adım önceden okuduklarımızla beraber hafızamızda tutuyoruz. Biyolojik zeka, bilgiyi sırası geldikçe daha önceden öğrenmiş olduğu iç modeli korurken yeni bilgiyle güncelleyerek artırımı olarak işler. RNN'ler de Şekil 4.6'te görüldüğü üzere prensip olarak aynı yöntemi kullanır (Chollet, 2019, s.208).



Şekil 4.6. Basit RNN modeli.

RNN'lerde farklı uygulama modelleri bulunmaktadır. Şekil 4.7'de her dikdörtgen bir vektördür ve oklar fonksiyonları temsil etmektedir. Giriş vektörleri kırmızı renktedir, çıkış vektörleri mavi renktedir ve yeşil vektörler RNN'nin durumunu tutmaktadır.



Şekil 4.7. RNN'nin farklı uygulama modelleri.

Şekil 4.7'deki soldan sağa doğru ilk model, sabit büyüklükteki girdiden sabit büyüklükte çıktı vermektedir. Örneğin: Görüntü sınıflandırma problemleri. İkinci model, dizi çıkışı üretmektedir. Örneğin: Resim alt yazısı bir görüntü alır ve sözcüklerin bir cümlesini verir. Üçüncü model, dizi girişinden bir çıktı üretmektedir. Örneğin: Verilen bir cümlenin, olumlu ya da olumsuz duyguları ifade ettiğinin tespitidir yani duygu analizi görevidir. Dördüncü ve bu çalışmada kullanılan model, çoklu girişten eş zamanlı olmayan dizi çıkışı üretmektedir. Örneğin: Bu yapıda bir RNN, İngilizce bir cümleyi okur ve daha sonra Türkçe bir cümle oluşturur yani makine çevirisi yapar. Beşinci model ise, senkronize edilmiş dizi girişi ve çıkışının üretilmesidir. Örneğin: Videoların her bir karesini etiketlemek istediğimiz video sınıflandırması problemleridir (Karpathy, 2015, parag.3).

DDİ uygulamalarında basit RNN'ler çok uygun olmamakla beraber bunun dışında bir boyutlu CNN'ler kullanılabilir de daha performanslı çalışan ve göreve bağlı olarak özelleşmiş olan LSTM, GRU ve bu çalışmada kullanılan Transformatör gibi farklı mimariler mevcuttur.

4.3.4. Uzun Ömürlü Kısa Dönem Belleği

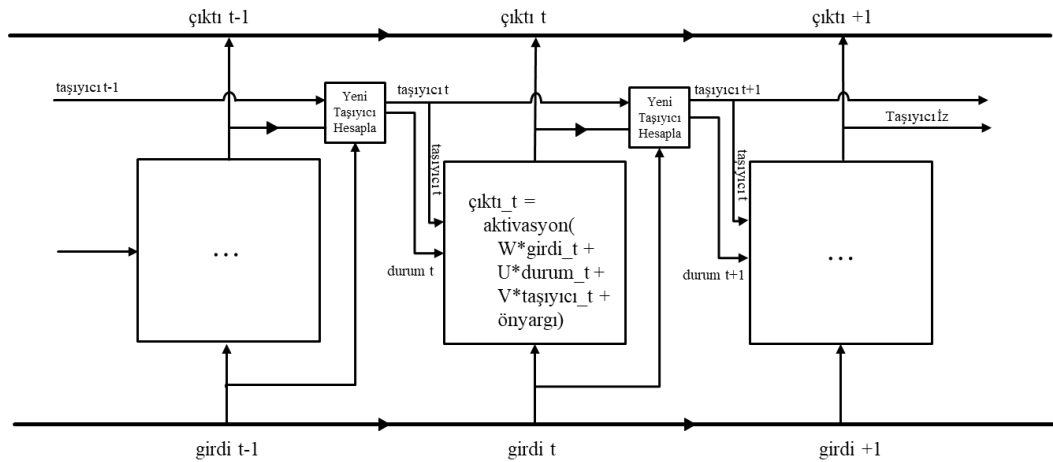
Basit RNN'ler teorik olarak her ne kadar bir t anında önceki bütün adımlardaki bilgiyi saklayabilseler de pratikte uzun dönemli gereksinimleri karşılamakta yetersiz kalmaktadır. Bu problemin kaynağı ise gradyan¹ yok olması durumu ve çok derin ileri

¹ Gradyan: Tensör işleminin türevidir. Türev kavramının fonksiyonlardan çok boyutlu girdilere genelleştirilmesidir.

yayımlı ağlarında görüldüğü gibi yeni katmanlar eklendikçe ağı eğitilemez olmasıdır. Bu sorun 1990'ların başında Hochreiter, Schmidhuber ve Bengio tarafından çalışılmış olup LSTM ve GRU katmanları çözüm olarak önerilmiş, 1997 yılında Hochreiter ve Schmidhuber tarafından geliştirilmiştir. (Chollet, 2019, s.215).

LSTM, basit RNN mimarisine ek olarak birçok zaman adımını taşıyabileceği bir yol ekler (Şekil 4.8). Bu yolu, asıl işlenen sıraya paralel olarak çalışan taşıyıcı bir yol olarak düşünebiliriz. Bu sayede herhangi bir zaman adımında ihtiyacımız olan başka bir zaman adımındaki bilgiyi kullanabilir, yani geçmiş bilgiyi geleceğe enjekte edebiliriz. Kısmen de olsa bağlamsal ve semantik ilişkiyi sağlayabiliriz. Bu LSTM'in temel prensibidir. Böylece bilgiyi sonra kullanmak üzere saklarken, aynı zamanda gerideki zaman sinyalinin gradyan yok olması probleminin de ortadan kalkmasını sağlar (Chollet, 2019, s.216).

Bu mimariler ayrıca dikkat mekanizması olarak bilinen ekstra bir hesaplama katmanı eklenerek kullanılabilirler. Dikkat mekanizması ağıımızın sayılar ve isimlerde dahil olmak üzere girdilerin belirli yönlerini daha iyi hatırlamasına yardımcı olarak, girdinin bağlama göre ne kadar önemli olduğunun değerlendirildiği bir mekanizmadır (Lopyrev, 2015). Sorgu ve anahtar-değer çiftinin bir çıktıya eşlenmesi olarak tanımlanabilir (Vaswani vd., 2017). LSTM ve GRU gibi ağlara ek bir hesaplama katmanı olarak eklenebildiği gibi transformatör mimarilerinde olduğu şekilde katmanın kendi içinde öz dikkat mekanizması olarak bulunabilir.



Şekil 4.8. LSTM'in anatomisi.

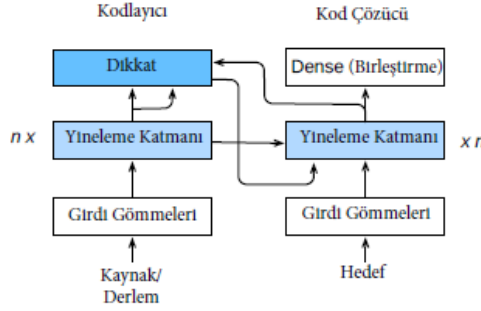
4.3.5. Geçitli Yineleme Birimi

GRU kavramı ađın içinde bařtan bařa kullanılan zaman adımı yolunun tařıdıđı her bilginin gerekli olmadığı, insanların da yařamları boyunca kendi zaman adımlarında elde ettikleri her bilgiyi saklamak yerine, aslında daha gerekli bilgiyi saklamak için gereksiz bilgileri unutmaları prensibi ile hareket etmektedir. Bilgiler zaman adımı yolunda eřik deđerine bađlı olarak ya unutulur ya da hatırlanarak ađda ileri dođru iletilir. GRU'nun LSTM mimarisinden farkı ise tek bir geřit biriminin aynı anda hem unutma faktörünü hem de durum birimini güncelleme kararını kontrol etmesidir.

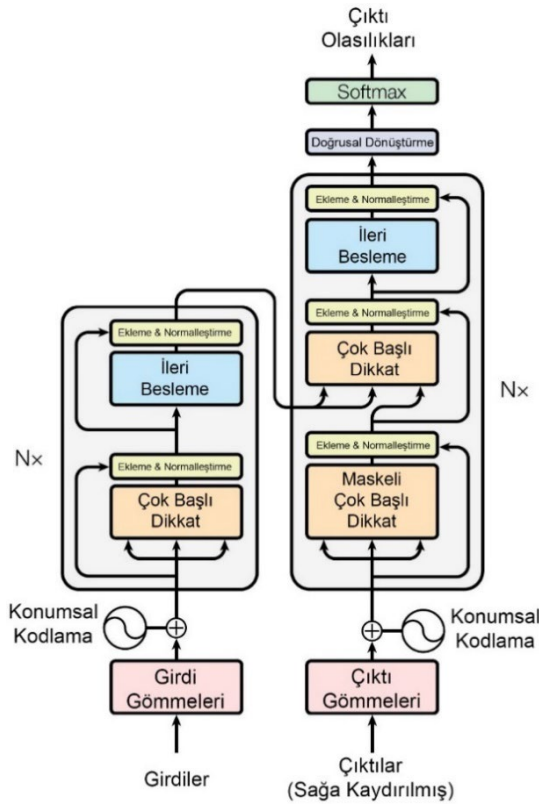
4.3.6. Transformatör Mimarisi

Transformatörler, derin öğrenmenin 2012'de ImageNET'te CNN mimarisini kullanarak göstermiş olduđu büyük atılımdan sonra, DDİ ile ilgili yayınlanmış olan "Attention is All You Need" (Vaswani vd., 2017) bařlıklı makaleyle birlikte en son teknoloji olarak söyleyebileceğimiz bir derin öğrenme mimarisidir. Makalenin bařlığından da anlaşılabilirce üzere böyle bir gelişmedeki en önemli pay transformatör mimarisinin blokları içinde kullanılan öz dikkat mekanizmasıdır. Transformatörler dikkat açısından sıralı veriler üzerinde daha başarılı sonuçlar elde edebildiđi için DDİ problemlerinde en çok tercih edilen mimari konumundadır. Transformatörler ve diđer RNN mimarileri arasındaki temel farklardan biri, RNN'ler t zamanındaki çıktıının deđerini, $t-1$ zamanındaki deđeri hesaplamadıkça elde edememesidir. Yani veriyi işlerken paralelleřtirme sađlayamamaktadır. Aynı zamanda DDİ problemlerinin çözümlerinde RNN mimarileri, kodlayıcı ve kod çözücü olmak üzere iki bileřenden oluřan bir model ile kullanılmaktadır. Bu yöntemde sekanslar, kodlayıcı adımları boyunca RNN ile eğitildikten sonra kod çözücü yine RNN ile çıktıyı tahmin etmeye çalıřır. Buradaki temel problem aslında öğrenilmeye çalıřılan girdinin tek bir bađlam özetine sıkıřtırılmaya çalıřılmasıdır. Bu durumda da tek seferde eğitim için modele giren sekansların uzunluđu arttıkça, kod çözücüye tahmin etmeye başlaması için girdi olarak verilen bađlam özeti de eğitim girdisini tam olarak ifade edemeyip, uygun çıktıların hesaplanamamasına neden olacaktır. Transformatördeki kodlayıcı ve kod çözücü mimarisinde ise her kodlayıcının çıktısı kod çözücüye besleyerek bađlamdan uzaklařılmamasını kolaylařtırmaktadır.

Transformatör mimarisi, RNN, LSTM ve GRU gibi Seq2Seq kodlayıcı ve kod çözücü (Şekil 4.9) mantığı üzerine modellenen mimarilerdeki yinelenen katmanlar yerine, eğitim hesaplamalarının içinde yapıldığı transformatör bloklarının kullanılması ve cümledeki her sözcüğün konum bilgisini de saklayan konumsal kodlama yöntemleriyle farklılık göstermektedir (Şekil 4.10).



Şekil 4.9. Genel Seq2Seq model mimarisi (Kaynak: Dive into Deep Learning).



Şekil 4.10. Temel transformatör model mimarisi.

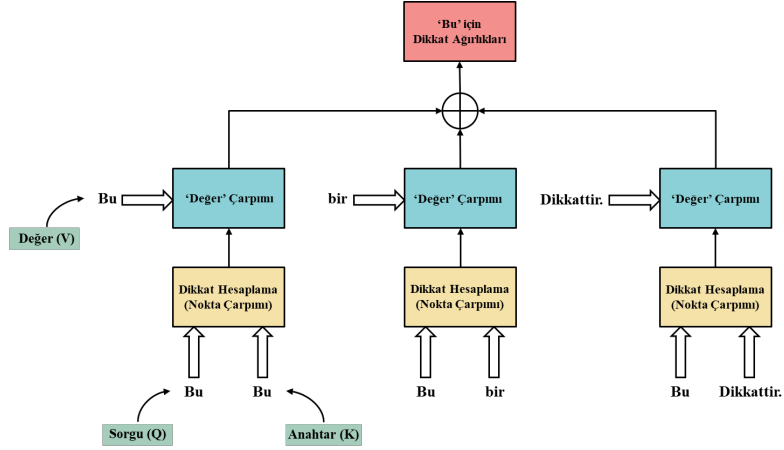
Seq2Seq modeldeki tekrarlayan bir katman, bir transformatör bloğu ile değiştirilir. Bu blok, çok başlı bir öz dikkat katmanı ve kodlayıcı için sinyalleri sonraki bloğa iletmek üzere ileri besleme (yayılm) ağ katmanı içerir. Kod çözücünde, kodlayıcı bloğundan farklı olarak kodlayıcıdan gelen durum sinyalleri için ekstra çok başlı öz dikkat katmanı kullanılır. Öz dikkat katmanı, bir sekanstaki öge sırasını ayırt etmediğinden, her bir sekans ögesine sıra bilgisini eklemek içinde konumsal kodlama katmanı kullanılır. Transformatör mimarisinin bir farkı daha artık toplama (resudial) yapıda olmasıdır. Yani her bir işlem adımından sonra, işlem adımının sonucu ile işleme giren kısma belirli bir toplama ve normalleştirme fonksiyonu uygulanarak iletimin sağlanmasıdır. Bu artık bağlantılar gradyanların doğrudan ağlar üzerinde akmasına izin vererek ağın eğitimine yardımcı olur. Aynı zamanda transformatör bloklarının alt katmanlarında kontrollü olarak t adımı geçilirken, $t-1$ dahil olmak üzere bu adıma kadar olan bilginin kaybolmadan aktarılmış olması sağlanır (Zhang, Lipton, Li & Smola, 2020).

4.3.6.1. Konumsal Kodlama

Doğal dilin matematiksel işlemlerde kullanılabilmesi, bilgisayarın doğal dili anlayabilmesi, günümüz yöntemleriyle cümle veya sözcüklerin, kullanılan derlemdeki sözlük uzayında yönü olan skaler değerlerle yani vektörlerle ifade edilmesiyle mümkündür. Özet olarak her sözcük gösterimi için farklı bir tam sayı değeri verilmelidir. Daha sonra bu vektörler kendilerine en yakın olan belirli sayıdaki diğer vektörler ile bir olasılık dağılımı ile kayan noktalı (float) değerler içeren bir matris oluşturur. Buna sözcük gömmeleri veya gömme matrisi (word embeddings) denilmektedir. Daha önce bahsedilen derin öğrenme mimarileri de verileri işlemeye başlamadan önce aynı yöntemi uygulamaktadır. Fakat transformatör mimarisi bu değerleri elde ettikten sonra diğer mimariler gibi doğrudan eğitim bloklarına göndermez. Doğal dilde sözcüklerin cümledeki pozisyonları bağlamdaki anlamlarını doğrudan etkilemektedir. Bu sebeple transformatör mimarisi girdileri, konumları ile toplayarak, her sözcüğün cümledeki konum bilgisini de içermektedir. Böylece dilin gramer yapısının da anlaşılması kolaylaşmaktadır.

4.3.6.2. Çok Başlı Dikkat Mekanizması

Şekil 4.11’de gösterildiği üzere öz dikkatin hesaplanabilmesi için her girdi üç ayrı vektör olarak transformatör bloğuna gönderilir. Bunlar bir girdi içindeki her elemanın sırasıyla sorgu (q), değer (v) ve anahtar (k) ağırlık değerleridir.



Şekil 4.11. Öz dikkat mekanizması.

Çok başlı dikkat mekanizması, prensip olarak dikkat mekanizmasındaki dikkat ağırlıklarının hesaplanmasını sağlayan nokta çarpımı işlemini bütün bir girdiye uygulamak yerine, ağırlık girdilerini dikkat başı kadar parçalara bölerek bağlamı daha iyi anlamayı amaçlamaktadır. Bu yöntemi CNN’deki gibi modelin başta hiçbir şey bilmediği durumda, görselin tamamını anlamak yerine ilk önce küçük kısımları anlamlandırıp daha sonra daha derin şekilleri anlamlandırmasına benzetebiliriz (Şekil 4.4). Buradan hareketle metinsel girdideki farklı anlamları da çıkarabilecek farklı açılara da dikkat sağlayabilmek amacıyla q , v ve k vektör matrisleri n başlık olacak şekilde $q_1, \dots, q_n, v_1, \dots, v_n, k_1, \dots, k_n$ olarak bölünür. Bu değerler arasında Denklem 4.1’deki hesaplamalar yapıp daha sonra bölünen başlıkların toplanmasıyla girdi vektör matrisinin öz dikkat ağırlıkları hesaplanmış olur. Bu hesaplamalardan sonra model ileri besleme ağ katmanı ile bir sonraki transformatör bloğuna iletilerek aynı döngü sağlanır.

Kod çözücü bloğunda farklı olarak Şekil 4.10’daki gibi ek bir maskeli çok başlı dikkat işlemi ile hedef girdilerinin vektör matrislerinin ağırlıkları hesaplanarak, diğer hesaplamalar ile birlikte ileri besleme ağ ile kod çözücü blokları boyunca yayılır.

Modeldeki son kodlayıcı bloğundan gelen ağırlık matrislerinin, kod çözücü tarafındaki her bloğa ayrı ayrı dahil edilmesiyle gerekli işlemler hesaplanır. Aynı zamanda kaynak ile hedef arasındaki dikkat ağırlıkları da hesaplanmış olur. Son kod çözücü bloğundan çıkan vektör doğrusal dönüşüm katmanında hedef sözlük boyutuna sahip bir vektöre genişletilir. Genişletilen bu vektör softmax katmanından geçerek en yüksek orana sahip değer seçilerek tahmin gerçekleşir.

$$Dikkat(Q, K, V) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4.1)$$

4.3.6.3. Noktasal İleri Besleme Ağ Katmanı

Transformatördeki önemli diğer bir bileşen noktasal ileri besleme ağıdır. Bu katman farklı aktivasyon fonksiyonlarına sahip iki ayrı yoğun katmandan (dense layer) oluşur. Noktasal olarak isimlendirilmesinin sebebi ise normalde matrisler üzerinde tek adımda yapılan işlemlerin aksine, matrisleri oluşturan her bir vektör ayrı ayrı işlenerek ileri yayılım gerçekleşir. Bu katman, dikkat katmanlarında eğitilen ağırlıkların potansiyel olarak daha zengin temsil gücüne sahip olmasını sağlamakla birlikte, iletilecek vektörlerin bir sonraki bloğun girişine uygun olarak yani sonraki transformatör bloğunun dikkat katmanlarına iletilmesini sağlar (Şekil 4.10).

BÖLÜM 5

GELİŞTİRİLEN UYGULAMA

5.1. Veri Kümesi

Bu çalışmada veri seti olarak derin öğrenme için yeterli sayıda haber ve başlık içeren, Türkçe metinlerde belge sınıflandırması görevi için hazırlanan ve 2010 ile 2017 arasındaki iki ayrı gazeteden elde edilen SuDer Türkçe haber derlemi tercih edilmiştir. Derlemde yaklaşık olarak 700.000 haber metni, haber başlığı, haber tarihi ve kategori bilgilerini içeren veri bulunmaktadır. Başlık üretme için sadece haber metinleri ve başlıkları derlemden alınarak kullanılmıştır. Bu gazetelerin derlem istatistikleri ayrı ayrı Çizelge 5.1 ve Çizelge 5.2’de gösterilmiştir (Şen & Yanıkoğlu, 2018).

Çizelge 5.1. Cumhuriyet Gazetesi’nin derlem istatistikleri.

Kategori	Toplam Doküman Sayıları	Sözcük Sayıları	
		Toplam	Ortalama
Türkiye	84,741	22,829,220	269.39
Yazarlar	33,835	16,663,717	492.49
Video	33,409	2,007,691	60.09
Spor	31,396	7,240,974	230.63
Dünya	21,005	4,416,708	210.26
Siyaset	15,969	6,409,811	401.39
Foto	14,302	248,871	17.04
Ekonomi	8,187	2,520,473	307.86
Teknoloji	7,913	1,734,268	219.16
Kültür-Sanat	6,506	2,664,020	409.47
Yaşam	4,833	918,754	190.1
Sağlık	2,573	863,208	335.48
Eğitim	2,38	744,396	312.77
Çevre	1,735	477,811	275.39
Toplam	268,784	69,739,922	259.46

Çizelge 5.2. Sabah Gazetesi'nin derlem istatistikleri.

Kategori	Toplam Doküman Sayıları	Sözcük Sayıları	
		Toplam	Ortalama
Gündem	143,842	35,749,880	248.54
Yaşam	123,086	22,878,732	180.86
Ekonomi	85,485	22,261,600	247.38
Yazarlar	68,1	16,335,364	239.87
Toplam	420,513	95,494,110	227.09

Haber metinleri içinde bir olayı anlatan metinlerden farklı olarak siyasi seçim sonuçları gibi farklı istatistiksel bilgileri içeren metinlerin gürültü yapabileceği düşünülmüştür. Bu nedenle haber metinlerinin istatistiksel bilgilerini kullanarak deneme yanılma yolu ile 256 sözcükten küçük haber metinleri eğitime dahil edilmeyecek şekilde atılmıştır. Böylece yaklaşık olarak 290.000 haber metni elde edilmiştir. Bu veri kümesi içinde de tek veya 2, 3 sözcük içeren başlıklar eğitim için uygun olmaması ve eğitimi sıkıştırması sebebiyle ortalama haber başlığı uzunluğu olan 6 sözcükten kısa başlığı olan metinler eğitim veri kümesinden atılmıştır. Sonuç olarak 50.000'nin üzerinde haber ve başlık metni içeren veri elde edilmiştir.

5.2. Ön İşlemler

Bilgisayar algoritmalarının genel olarak “ne girerse o çıkar” prensibinden hareketle, derin öğrenme algoritmalarının ana unsuru olan verilerin en saf halde olması başarılı sonuçlar elde edebilmek için önemli bir durumdur. Buradan hareketle, haber metinleri ve başlıklarının normalizasyonunun yapılması gerekmektedir. Bu çalışmada bunun için yapılan işlemler şunlardır:

- 1- Düzenli ifadeler (RegEx) kullanılarak noktalama işaretlerinin, arka arkaya olabilecek fazla boşluk veya iki sözcük arasında kalan tek karakterlerin filtrelenmesi
- 2- Ara başlıkların silinmesi
- 3- Haber metinlerindeki tarihlerin ve sayıların temizlenmesi, haber başlıklarındaki tarih ve sayıların ise “####” işareti ile temsil edilecek şekilde değiştirilmesi

- 4- Türkçe'deki frekansı en yüksek 10.000 sözcük içerisinde seçilen durak sözcüklerinin¹ (stop words) metin içerisinde temizlenmesi

Bütün bu aşamalar ve bu aşamalardan sonra üç karakterden kısa sözcüklerin atılmasıyla bütün metni küçük harf olarak döndüren işlemler, haber ve başlık verileri için ayrı ayrı fonksiyonlar kullanarak sağlanmıştır. Ön işlemde önceki ve sonraki metinler Çizelge 5.3, Çizelge 5.4 ve Çizelge 5.5'te gösterilmiştir.

Çizelge 5.3. Ön işlenmiş haber ve başlık örneği - 1.

	Orijinal Metin	Ön İşlenmiş Metin
Haber	Özel yetkili Ankara 12. Ağır Ceza Mahkemesi, 28 Şubat soruşturmasını yürüten savcıların itirazı üzerine, nöbetçi hâkimlikçe serbest bırakılan emekli Orgeneral Teoman Koman ile emekli Korgeneraller Engin Alan ve Kamuran Orhon hakkında "yakalama kararı" çıkarttı. Mahkeme kararın gerekçesini "zanlılara atılı suçun niteliği" olarak belirtti. MHP'den milletvekili seçilen Alan, Balyoz davasından tutuklu bulunuyor.'	özel yetkili ankara ağır ceza mahkemesi şubat soruşturmasını yürüten savcıların itirazı üzerine nöbetçi hâkimlikçe serbest bırakılan emekli orgeneral teoman koman emekli korgeneraller engin alan kamuran orhon hakkında yakalama kararı çıkarttı mahkeme kararın gerekçesini zanlılara atılı suçun niteliği belirtti mhp den milletvekili seçilen alan balyoz davasından tutuklu bulunuyor
Başlık	28 Şubat komutanlarına yakalama kararı çıktı	### şubat komutanlarına yakalama kararı çıktı

Çizelge 5.4. Ön işlenmiş haber ve başlık örneği - 2.

	Orijinal Metin	Ön İşlenmiş Metin
Haber	Türk Hava Yolları'nın 2016'nın ilk iki ayındaki yolcu sayısı geçen yılın aynı dönemine göre yüzde 11.2 artışla 9.2 milyona ulaştı. Bu rakam 2015'te 8.3 milyon olmuştu. Yolcu sayısındaki artış iç hatlarda yüzde 12.6, dış hatlarda yüzde 10.2 oranında gerçekleşti. Dış Hatlar Business/Comfort Class yolcu sayısı ve Dıştan Dışa Transfer Yolcu sayılarında da Ocak-Şubat 2015 dönemine kıyasla sırasıyla yüzde 5.8 ve 20.9 artış sağlandı. Doluluk oranı 3 puanlık düşüş ile yüzde 73.3 oldu.	türk hava yolları ilk ayındaki yolcu sayısı geçen yılın aynı dönemine yüzde artışla milyona ulaştı rakam milyon olmuştu yolcu sayısındaki artış hatlarda yüzde dış hatlarda yüzde oranında gerçekleşti dış hatlar business/comfort class yolcu sayısı dıştan dışa transfer yolcu sayılarında ocak şubat dönemine kıyasla sırasıyla yüzde artış sağlandı doluluk oranı puanlık düşüş yüzde oldu
Başlık	THY yolcu sayısını 9.2 milyona çıkardı	thy yolcu sayısını ### milyona çıkardı

¹ Durak sözcüklerine <https://github.com/ahmetax/trstop> adresinden erişilebilir.

Çizelge 5.5. Ön işlenmiş haber ve başlık örneği - 3.

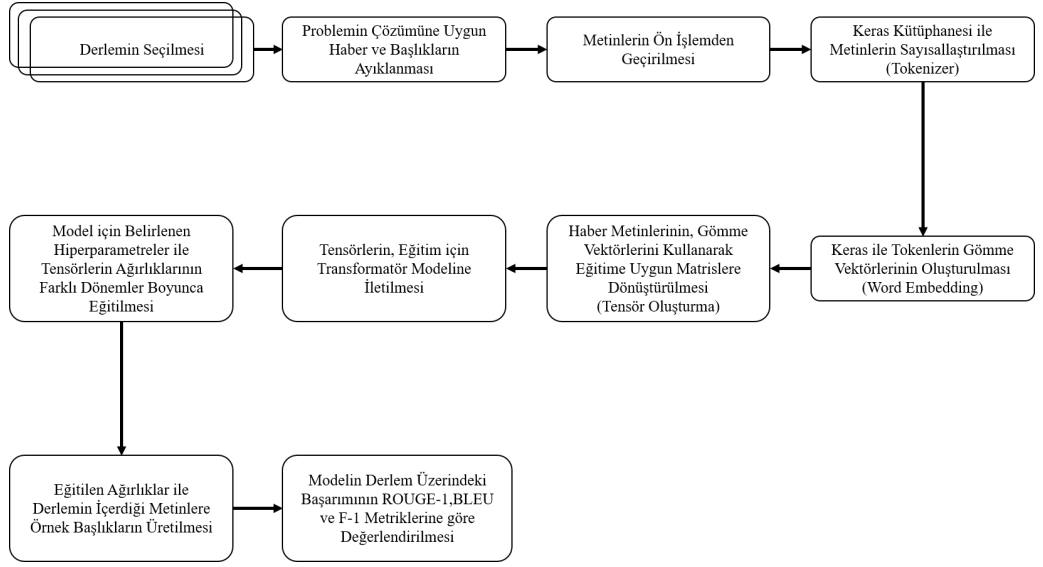
	Orijinal Metin	Ön İşlenmiş Metin
Haber	Diyarbakır'da terörle mücadele polisleri, Demokratik Bölgeler Partisi (DBP) İl Örgütü binasına gelerek, arama başlattı. Polislerin, binadaki aramaları sürdürüyor. Diyarbakır Emniyet Müdürlüğü Terörle Mücadele Şubesi ekiplerince, DBP Diyarbakır İl Örgütü binası basıldı. Öğle saatlerinde geldikleri parti binasını abluka altına alan polisler, çevrede de geniş güvenlik önlemleri aldıktan sonra, arama başlattı. Ekiplerin, parti binasındaki arama ve incelemeleri sürdürüyor.	diyarbakır terörle mücadele polisleri demokratik bölgeler partisi dbp örgütü binasına gelerek arama başlattı polislerin binadaki aramaları sürdürüyor diyarbakır emniyet müdürlüğü terörle mücadele şubesi ekiplerince dbp diyarbakır örgütü binası basıldı öğle saatlerinde geldikleri parti binasını abluka altına alan polisler çevrede geniş güvenlik önlemleri aldıktan arama başlattı ekiplerin parti binasındaki arama incelemeleri sürdürüyor
Başlık	DBP Diyarbakır İl Binasına polis baskını	dbp diyarbakır il binasına polis baskını

Daha sonra eğitim için kullanacağımız haber metinleri ve hedef haber başlıklarımızın başına ve sonuna modelin öğrenme ve tahmin aşamalarında sınırlarını anlayabilmesi amacıyla başlangıç ve bitiş işaretleri eklenmiştir.

5.3. Eğitim Modeli


Eğitimde altyapı olarak Google tarafından derin öğrenme işlemleri için yayımlanan Tensorflow kütüphanesi ile Tensorflow'u arka uç olarak çalıştırabilen derin öğrenme konusunda çok yetenekli bileşenler içeren Keras kütüphanesi birlikte kullanıldı. Geliştirme ortamı olarak ise yine Google tarafından sağlanan ve Jupyter Notebook altyapısını kullanan, aynı zamanda eğitimler için hız konusunda öne çıkan NVIDIA Tesla P100 gibi yüksek performanslı ekran belleği hizmeti sunan Google Colab Pro servisi kullanıldı.

Derlemin eğitimi için mimari altyapı olarak günümüzde DDİ ve diğer birçok problemin çözümünde kullanılan, son teknoloji (state-of-the-art) olarak kabul edilen temel transformatör mimarisi kullanıldı. Hiperparametreler farklı denemelerden sonra orijinal makaledeki değerler olarak seçildi. Kodlayıcı ve kod çözücü blok sayısı 6, blok alt katmanlarının nöron sayısı 2048, kelime vektörlerinin gömme boyutu 512, çok başlı dikkat kafa sayısı 8 olarak seçildi (Vaswani vd., 2017). Derlemin eğitim sürecine kadar olan verilerin hazırlanması, sonuç ve değerlendirme adımlarını gösteren diyagram ise Şekil 5.1 verilmiştir.



Şekil 5.1. Modelin süreç adımlarını gösteren blok diyagram.

Oluşturulan modelle 20 ve 25 dönem eğitim sonunda sırasıyla ortalama %75 ve %85 doğruluk oranı (Şekil 5.1) elde edildi.



Şekil 5.2. Modelin eğitim doğruluk oranı.

Keras kütüphanesi tarafından geliştirilen serileştirilebilir öğrenme oranı düşüş programı yöntemiyle (learning rate scheduler) önceden belirlenmiş olan, modelin

öğrenme oranını her eğitim adımında hesaplayıp güncelleyerek en iyi öğrenme oranını bulabilmek için orijinal makalede de kullanılan bir hesaplama fonksiyonu kullanılmıştır (Denklemler 5.1). Bu sayede öğrenmenin durmasına sebep olan, modelin lokal minimuma sıkışması olasılığının azalması sağlanmıştır.

$$\text{Öğrenme } O. = (\text{VektörBoyutu})^{-0.5} \times \min(\text{Öğrenme Adımı}^{-0.5}, (\text{Öğrenme Adımı}^{-0.5} \times \text{Isınma Adımı}^{-1.5})) \quad (5.1)$$

BÖLÜM 6

SONUÇLAR

6.1. Değerlendirme

Değerlendirme ölçümü, genel olarak makine çevirisi için kullanılan BLEU ve genel olarak metin özetleme görevlerinde kullanılan ROUGE metriği kullanılarak yapılmıştır. ROUGE metriği üç değer hesaplar. İlk olarak Recall (geri çağırma) değeri olarak hesaplanan (Denklem 6.1), aynı zamanda BLEU olarak bilinen değerdir. İkinci olarak Precision (hassas) değeri olarak hesaplanan (Denklem 6.2), aynı zamanda ROUGE olarak bilinen değer ve üçüncü olarak bu iki değer harmonik ortalaması hesaplanarak elde edilen F1 skor (Denklem 6.3) değeridir (Özkan, 2019).

$$Rouge Recall = \frac{\text{Çakışan Sözcük Sayısı}}{\text{Referans Başlıktaki Toplam Sözcük Sayısı}} \quad (6.1)$$

$$Rouge Precision = \frac{\text{Çakışan Sözcük Sayısı}}{\text{Sistemin Ürettiği Başlıktaki Toplam Sözcük Sayısı}} \quad (6.2)$$

$$Rouge F1 Skoru = 2 * \frac{Rouge Recall \times Rouge Precision}{Rouge Recall + Rouge Precision} \quad (6.3)$$

Sistemin farklı eğitim süreleri sonunda ürettiği sonuçlar ve belirtilen ölçüm metriği ile gerçek başlık arasındaki benzerlik ölçümleri Çizelge 6.1, Çizelge 6.2 ve Çizelge 6.3'te gösterilmiştir. Geliştirilen sistemle üretilen sonuçlardan bazıları ayrıca (*Ek*) verilmiştir.

Çizelge 6.1. Sistem tarafından üretilen başlık - 1.

Haber	Özel yetkili Ankara 12. Ağır Ceza Mahkemesi, 28 Şubat soruşturmasını yürüten savcıların itirazı üzerine, nöbetçi hâkimlikçe serbest bırakılan emekli Orgeneral Teoman Koman ile emekli Korgeneraller Engin Alan ve Kamuran Orhon hakkında "yakalama kararı" çıkarttı. Mahkeme kararın gerekçesini "zanlılara atılı suçun niteliği" olarak belirtti. MHP'den milletvekili seçilen Alan, Balyoz davasından tutuklu bulunuyor.			
Başlık	28 Şubat komutanlarına yakalama kararı çıktı			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	### şubat kumpasına ### yakalama kararı	0.8	0.57	0.66
25 Dönem	### şubat komutanlarına yakalama kararı çıktı	1.0	0.85	0.92

Çizelge 6.2. Sistem tarafından üretilen başlık - 2.

Haber	Diyarbakır'da terörle mücadele polisleri, Demokratik Bölgeler Partisi (DBP) İl Örgütü binasına gelerek, arama başlattı. Polislerin, binadaki aramaları sürdürüyor. Diyarbakır Emniyet Müdürlüğü Terörle Mücadele Şubesi ekiplerince, DBP Diyarbakır İl Örgütü binası basıldı. Öğle saatlerinde geldikleri parti binasını abluka altına alan polisler, çevrede de geniş güvenlik önlemleri aldıktan sonra, arama başlattı. Ekiplerin, parti binasındaki arama ve incelemeleri sürdürüyor.			
Başlık	DBP Diyarbakır İl Binasına polis baskını			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	dbp il binasına eş zamanlı operasyon	0.42	0.3	0.35
25 Dönem	diyarbakır da dbp binasına eş zamanlı saldırı	0.5	0.5	0.5

Çizelge 6.3. Sistem tarafından üretilen başlık - 3.

Haber	Türk Hava Yolları'nın 2016'nın ilk iki ayındaki yolcu sayısı geçen yılın aynı dönemine göre yüzde 11.2 artışla 9.2 milyona ulaştı. Bu rakam 2015'te 8.3 milyon olmuştu. Yolcu sayısındaki artış iç hatlarda yüzde 12.6, dış hatlarda yüzde 10.2 oranında gerçekleşti. Dış Hatlar Business/Comfort Class yolcu sayısı ve Dıştan Dışa Transfer Yolcu sayılarında da Ocak-Şubat 2015 dönemine kıyasla sırasıyla yüzde 5.8 ve 20.9 artış sağlandı. Doluluk oranı 3 puanlık düşüş ile yüzde 73.3 oldu.			
Başlık	THY yolcu sayısını 9.2 milyona çıkardı			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	thy ### ayda ### milyon yolcu taşıdı	0.33	0.22	0.26
25 Dönem	thy nin yolcu sayısı ### milyona ulaştı	0.62	0.55	0.58

Bu ölçümler yapılırken bir Python modül paketleyicisi olan pip üzerinden rouge-score 0.0.4¹ modülü kullanılmıştır. Bu modül orijinal Perl betiğinin Python programla diline uygulanmasını sağlamaktadır. Fakat resmi Google ürünü değildir (Google LLC, 2020).

6.2. Analiz

Uygulamada kullanılan temel transformatör mimarisinin ayrı ayrı 20 ve 25 dönem yapılan eğitiminin sonucunda metin bağlamını yakalayabilecek kadar iyi bir şekilde eğitilebildiği gözlemlenmiştir (Çizelge 6.4). Ayrıca üretilen sonuçların bağlam ve morfolojik açıdan da yetenekli sonuçlar üretebildiği görülebilmektedir.

Çizelge 6.4. Genel deney sonuçları.

Eğitim Süresi	ROUGE-1	BLEU	F1 Skoru
20 Dönem	0.59	0.54	0.55
25 Dönem	0.77	0.70	0.73

¹ Modüle <https://pypi.org/project/rouge-score/> adresinden erişilebilir.

Fakat bu çalışmada önerilen modelin genel kullanıma çok uygun olmaması yani kısmen derleme bağı sonuçlar üretmesi, derlem içindeki haber çeşitliliğinin kısıtlı olmasından dolayı dili temsil edebilecek kadar kapsamlı genel bir sözlük oluşturamamasından kaynaklanmaktadır.

6.3. Yorumlar

Haber başlığı üretme gibi metin içeriğini tanımlama işlemleri bağlamı ifade ederken yazardan yazara, gazeteden gazeteğe farklılık göstermektedir. Eğitimde orijinal makale metninde kullanılan temel transformatör mimarisi kullanılmıştır. Bu mimari derleme bağı kalmaktadır. Fakat üzerine yapılan geliştirmelerle, bağlamı iyi anlayabilen, derleme bağı kalmayan Transformer-XL ve Google tarafından yayınlanan Pegasus vb. model mimarilerde tercih edilerek daha iyi sonuçlar elde edilebilir. Bağlamdan bağımsız görevler için Türkçe'nin morfolojik yapısına uygun jetonlaştırma (tokenizer) ve çift yönlü transformatör kodlayıcı temsilleriyle (Bidirectional Encoder Representation from Transformer, BERT) veya Google tarafından (Google BERT) Wikipedia verileriyle eğitilen ön eğitilmiş derlem sözlüğü ve dil modeli kullanılabilir. Bir kaynaktan eğitilen, fakat eğitildiği kaynağa bağı kalmadan başarılı içerik üretebilen genel dil modelleri oluşturulabilir. Aynı zamanda üretim aşamasında kod çözücü bloğunda varsayılan olarak kullanılan en yüksek oranlı tahmini kullanarak ilerleyen, teknik olarak Greedy algoritması olarak isimlendirilen yöntem yerine, sezgisel ışın arama (Heuristic Beam Search, HBS) algoritması ile n farklı en yüksek oranlı tahminleri de hesaba katarak bir üretim ağaç yapısı sayesinde daha başarılı sonuçlar elde edilebilir. Greedy algoritması aslında HBS algoritmasındaki n 'nin 1'e eşit olmasıyla aynı şeyi ifade etmektedir.

KAYNAKLAR

Britz, D. (2016, Nisan 6). *Deep Learning for Chatbots, Part 1 - Introduction*. 10 Ocak 2021 tarihinde <http://www.wildml.com/2016/04/deep-learning-for-chatbots-part-1-introduction/> adresinden erişildi.

Brownlee, J. (2019, Ağustos 7). *What is Natural Language Processing?*. 17 Ocak 2021 tarihinde <https://machinelearningmastery.com/natural-language-processing> adresinden erişildi.

Cerebro Tech. (2018, 26 Mart). *Doğal Dil İşleme Rehberi*. 10 Ocak 2021 tarihinde <https://medium.com/türkiye/doğal-dil-işleme-rehberi-2c4c41260f74> adresinden erişildi.

Chollet, F. (2019). *Python ile Derin Öğrenme*. Ankara: Buzdağı

Erkan, G. & Radev, D.R. (2004). LexRank: Graph-based Lexical Centrality as Saliency in Text Summarization. *Journal Of Artificial Intelligence Research, Volume 22, pages 457-479. DOI: 10.1613/jair.1523*

Goodfellow, I., Bengio, Y. & Courville, A. (2018). *Derin Öğrenme*. Ankara: Buzdağı

Google LLC. (2020, Haziran 12). Python ROUGE Implementation. 29 Aralık 2020 tarihinde <https://pypi.org/project/rouge-score/> web adresinden erişildi.

Gu, X., Mao, Y., Han, J., Liu, J., Yu, H., Wu, Y., Yu, C., Finnie, D., Zhai, J. & Zukoski, N. (2020). Generating Representative Headlines for News Stories. The Web Conference '20, April 20 – 24, Taipei. arXiv:2001.09386v4.

Harris, D. (2014, Mayıs 2). *DARPA is working on its own deep-learning project for natural-language processing*. 10 Ocak 2021 tarihinde <https://gigaom.com/2014/05/02/darpa-is-working-on-its-own-deep-learning-project-for-natural-language-processing/> adresinden erişildi.

Karpathy, A. (2015, Mayıs 21). *The Unreasonable Effectiveness of Recurrent Neural Networks*. 10 Ocak 2021 tarihinde <http://karpathy.github.io/2015/05/21/rnn-effectiveness/> adresinden erişildi.

Karpathy, A. & Fei-Fei, L. (2015). Deep Visual-Semantic Alignments for Generating Image Descriptions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. DOI: 10.1109/CVPR.2015.7298932

Kavlakoglu, E. (2020, Kasım 12). *NLP vs. NLU vs. NLG: The Differences Between Three Natural Language Processing Concepts*. 17 Ocak 2021 tarihinde <https://www.ibm.com/blogs/watson/2020/11/nlp-vs-nlu-vs-nlg-the-differences-between-three-natural-language-processing-concepts/> adresinden erişildi.

Kurt, F. (2015, Temmuz 21). *Derin Öğrenme (Deep Learning) Nedir?*. 10 Ocak 2021 tarihinde <http://www.derinogrenme.com/2015/07/21/derin-ogrenme-deep-learning-nedir/> adresinden erişildi.

Lopyrev, K. (2015). Generating News Headlines with Recurrent Neural Networks. arXiv:1512.01712v1.

Microsoft. (2021, Ocak 10). Çözüm mimarisi: Derin Öğrenme ve Doğal Dil İşleme Özellikleriyle Bilgi Keşfi. 10 Ocak 2021 tarihinde <https://azure.microsoft.com/tr-tr/solutions/architecture/information-discovery-with-deep-learning-and-nlp/> adresinden erişildi.

Nekic, M. (2019). NDC Conferences - Automatic Text Summarization [Video slayt]. 15 Mayıs 2020 tarihinde https://www.youtube.com/watch?v=_d0OXm0dRZ4 adresinden erişildi.

Özkan, C. (2019). *İnternet Tabanlı Türkçe Metinler İçin Otomatik Özetleme Tekniği*. (Yayımlanmamış Yüksek Lisans Tezi). T.C. Maltepe Üniversitesi/Fen Bilimleri Enstitüsü, İstanbul. Erişim adresi: <https://openaccess.maltepe.edu.tr/xmlui/bitstream/handle/20.500.12415/2952/10306152.pdf?sequence=1>

Popper, B. (2017, Ekim 24). *Baidu's New System Can Learn to Imitate Every Accent*. 10 Ocak 2021 tarihinde <https://www.theverge.com/2017/10/24/16526370/baidu-deepvoice-3-ai-text-to-speech-voice> adresinden erişildi.

Şen, M.U. & Yanıkoğlu, B. (2018). Document classification of SuDer Turkish News Corpora. *2018 26th Signal Processing and Communications Applications Conference (SIU)*. DOI: 10.1109/SIU.2018.8404790

Şener, S. (2017, Eylül 10). *Yapay Zeka, Makine Öğrenimi ve Derin Öğrenme Arasındaki Farklar*. 10 Ocak 2021 tarihinde <https://www.endustri40.com/yapay-zeka-makine-ogrenimi-ve-derin-ogrenme-arasindaki-farklar/> adresinden erişildi.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L. & Polosukhin, I. (2017). Attention Is All You Need. arXiv:1706.03762v5.

Zhang, A., Lipton, Z.C., Li, M. & Smola, A.J. (2020). *Dive into Deep Learning*. Erişim adresi: <https://d2l.ai/d2l-en.pdf>

EKLER

Ek: Sistemin Ürettiği Diğer Sonuçlar

Haber	Bitlis İl Jandarma Komutanlığı tarafından düzenlenen operasyonda 6 terörist silahları birlikte etkisiz hale getirildi. Bitlis Valiliğinden yapılan açıklamaya göre Tatvan'a bağlı Anadere ve Odabaşı bölgesinde bölücü terör örgütüne yönelik yapılan operasyonlarda 6 terörist etkisiz hale getirilirken, çok sayıda silah ve mühimmatın ele geçirildiğini bildirdi. Valilikten yapılan açıklamada şu ifadeler yer verildi. "Bitlis İli Jandarma sorumluluk bölgesinde teröristle mücadele harekâtı kapsamında kış operasyonlarına devam edilmekte olup, Tatvan ilçesi Anadere-Odabaşı bölgesinde 03 Nisan 2017 tarihinde başlatılan Şehit J. Ütgm. Ömer Bozkurt operasyonu başlatılmış ve halen devam etmektedir. Operasyonda 04 Nisan 2017 günü bir grup BTÖ mensubu ile sıcak temas sağlanmış, bölgeye silahlı helikopterler ve uçaklarla Hava Hücum Harekâtı düzenlenmiştir. Hava Hücum Harekâtını müteakip 04 Nisan 2017 tarihinde operasyon bölgesinde yapılan arazi araması sonucunda; (6) PKK/BTÖ mensubu silahları ile birlikte etkisiz hale getirilmiştir. Ayrıca 04-05 Nisan 2017 tarihlerinde bölgede yapılan arazi aramasında (2) adet sığınak tespit edilerek imha edilmiştir. Etkisiz hale getirilen teröristlerin üzerinden ve imha edilen sığınaklardan; (4) adet Kaleşnikof P.Tf, (2) adet M-16 P.Tf, ve bu tüfeklere ait çok sayıda mühimmat, (2) adet el bombası, (400) kg amonyum nitrat, (2) adet Yeasu marka el telsizi, (15) adet 12 kg'lık büyük tüp, (5) adet 2 kg'lık küçük tüp, (1) adet DVD okuyucu, (1) adet radyo, (1) adet batarya, çok miktarda yaşam malzemesi ve muhtelif örgütsel doküman ele geçirilmiştir. Bitlis Jandarma Bölge Komutanlığınca, sorumluluk bölgesinde bulunduğu değerlendirilen teröristlerin tamamı etkisiz hale getirilinceye kadar, zaman mefhumu gözetmeksizin, her türlü hava koşullarında aralıksız olarak operasyonlara kararlılıkla devam edilecektir. Kamuoyuna saygı ile duyurulur." denildi.			
Başlık	Bitlis'te 6 teröristin öldürüldüğü operasyonda çok sayıda silah mühimmat ele geçirildi.			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	### hedef imha edildi ### terörist öldürüldü	0.5	0.22	0.30
25 Dönem	### terörist etkisiz hale getirildi	0.2	0.055	0.089

Haber	Deri ürünlerine Tercihli Ticaret Anlaşması ile gümrük indirimi avantajı getirilmemesine rağmen İran'a ihracatı ikiye katladıklarını söyleyen Türkiye Ayakkabı Sanayicileri Derneği Başkanı Hüseyin Çetin, "Tercihli ticaretin rüzgârı yetti diyebiliriz. İran'a ayakkabı ihracatını yüzde 111 artırdık. Ambargoların kalkması ve ticaretin normalleşmesiyle birlikte İran'dan daha çok talep bekliyoruz. 2016'da İran'a ayakkabı ihracatımızı 45-50 milyon dolara çıkarmayı hedefliyoruz" diye konuştu.			
Başlık	İran'a ayakkabı ihracatı yüzde 111 arttı			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	ihracat ihracatı ### arttı	0.66	0.22	0.33
25 Dönem	ihracatı ### milyar dolar arttı	0.5	0.22	0.30

Haber	Millî Eğitim Bakanlığı'nın şubat ayında atayacağı 30 bin öğretmen, bir eğitim-öğretim dönemi boyunca staj yapacak. Her stajyer öğretmene, bir danışman öğretmen verilecek. Millî Eğitim Bakanlığı (MEB), Türkiye'de ilk kez yapılacak bir uygulama ile öğretmenlikte usta-çırak ilişkisi başlatacak. Şubat ayında ataması gerçekleştirilecek 30 bin yeni öğretmen için, 6 ay üstatlık yapacak 30 bin danışman öğretmen seçilecek. Danışman öğretmen kriterleri arasında, tecrübe, iletişim becerisi aranacak. Millî Eğitim Bakanlığı, okullarda görev yapan yaklaşık 1 milyon öğretmen arasından en iyi 30 bin öğretmeni seçecek. Bu kapsamda, ilk kez şubat ayı atamalarında uygulamaya geçirilecek stajyer öğretmenlik programı için hazırlıklar da başladı. Şubat ayında atanacak 30 bin öğretmen, atama sonrasında bir eğitim-öğretim süresi boyunca staj yapacak. Her stajyer öğretmene, bir usta/üstat konumunda danışman öğretmen verilecek. Stajyer öğretmen, danışman öğretmenin sınıfında haftanın 3 günü derslere girecek. Öğrencilerle ilişkisini, ders yapma tekniklerini yerinde sınıfta takip edecek. Stajyer öğretmen, haftanın bir günü okul yönetiminde bir günü de ilçe millî eğitim müdürlüğünde bakanlığa ilişkin yürütülen işlemleri yerinde izleyecek. Eğitim-öğretim döneminin sonunda ise yaz tatili ya da sömestr tatilinde stajyer öğretmen ilk atamasının yapıldığı bölgenin, ilin sosyokültürel özelliklerine dair eğitim alacak. Usta/üstat konumunda görev yapacak danışman öğretmenlerde şu özellikler aranacak: En az öğretmenlik yapmış, Ulusal veya uluslararası projelerde görev almış, Sosyal ve kültürel faaliyetlere katılım sağlamış, iletişim beceresi ve temsil yeteneği güçlü, mesleğine temayüz etmiş olmak.			
Başlık	30 bin öğretmene 30 bin danışman			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	### bin ### öğretmene ### bin başvuru	0.6	0.46	0.5
25 Dönem	### bin öğretmen adayı yeniden okuyacak	0.2	0.14	0.16

Haber	Borsa İstanbul'un Yönetim Kurulu Başkanı Himmet Karadağ oldu. Borsa İstanbul'un yeni yönetim kurulu başkanı belli oldu. Borsa İstanbul Genel Kurulu'nda A grubu payları temsilen Himmet Karadağ ve Osman Saraç yönetim kuruluna girdi. Borsa İstanbul'un Yönetim Kurulu Başkanı Himmet Karadağ oldu.			
Başlık	Borsa İstanbul'un yeni başkanı Himmet Karadağ			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	borsa yeni genel kurulu ### yeni isim	0.33	0.22	0.26
25 Dönem	işte borsa nin yeni genel müdürü	0.33	0.33	0.33

Haber	Tokat'ta, yolcu minibüsü ile kamyonetin çarpışması sonucu 8 kişi yaralandı. Alınan bilgiye göre, Yunus Gırğaç idaresindeki 55 AGB 41 plakalı kamyonet, Tokat-Niksar Karayolu üzerindeki Bula köyü yakınlarında, Ayhan Ergökmen'in kullandığı 60 M 6350 plakalı yolcu minibüsü ile çarpıştı. Çarpışmanın etkisi ile yan yatan minibüsteki 8 yolcu yaralandı. Yaralılar ambulanslarla kentteki çeşitli hastanelere kaldırıldı.			
Başlık	Yolcu minibüsü ile kamyonet çarpıştı: 8 yaralı			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	yolcu minibüsü ile kamyonet çarpıştı ### yaralı	1.0	0.88	0.94
25 Dönem	yolcu otobüsü ile kamyonet çarpıştı ### yaralı	0.87	0.77	0.82

Haber	Şirnak'ın İdil ilçesinde PKK'nın gençlik yapılanması olarak bilinen Yurtsever Devrimci Gençlik Hareketi (YDG-H) üyelerinin polis ekiplerine silahla saldırması üzerine çıkan çatışmada 2 kişi yaralandı. Edinilen bilgiye göre olay İdil ilçesi Turgut Özal Mahallesi'nde meydana geldi. Turgut Özal Mahallesi'nde sözde kanton bölge oluşturdukları iddia edilen yüzleri kapalı yaklaşık 20 kişilik grubu dağıtmak üzere bölgeye gelen polis ekipleri anons yaptı. Zırhlı polis ekipleri tarafından yapılan anonslara rağmen dağılmayan gruba biber gazı ile müdahale edildi. Polisin biber gazı ile müdahale ettiği grup, silahlarla polise ateş açtı. Grup tarafından silahlarla açılan ateşin ardından polisin karşılık vermesiyle çatışma çıktı. Sabaha karşı saat 03.00'da yaşanan çatışmada 2 YDG-H üyesi yaralandı. Yaralılardan birinin İdil Devlet Hastanesi'ne kaldırıldığı belirtilirken, diğer yaralının ise durumunun iyi olmasından dolayı hastaneye kaldırılmadığı öğrenildi. Olay ile ilgili soruşturma başlatıldığı belirtildi.			
Başlık	Polis ile YDG-H arasında çatışma: 2 yaralı			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	iki polis arasında bıçaklı kavga ### yaralı	0.5	0.4	0.44
25 Dönem	polis ile ydg çatışma ### yaralı	1.0	0.6	0.74

Haber	Bursa'nın İnegöl ilçesinde 'okula gidiyorum' diyerek evden ayrıldıktan sonra bir daha kendisinden haber alınamayan 16 yaşındaki kız, 28 gün sonra bulundu. Erkek arkadaşının yanında olduğu ortaya çıkan kız, ailesine teslim edildi. Suriye'deki iç savaştan kaçarak İnegöl'e gelip, Mesudiye Mahallesi Gülistan Sokak'ta kiradıkları dairede ikamet eden Kaddur ailesinin kızlarının kayıp olması hayatlarını alt üst etmişti. İnegöl Anadolu İmam Hatip Lisesi 10. sınıf öğrencisi olan 16 yaşındaki R.K., 28 gün önce okula gitmek için evinden çıktı. Ancak genç kız bir daha evine dönmedi. Kızlarının eve dönmesini bekleyen baba Muhammed K. ile anne Visal K., kızlarının eve dönmemesi üzerine emniyete başvurmuşlardı. Emniyet ekipleri genç kızın gidebileceği yerlerdeki güvenlik kameralarını inceledi. İncelemeler sonucunda genç kızın bir erkekle birlikte Bursa istikametine gittiği bilgisine ulaşıldı. Lise öğrencisinin izine ulaşan ekipler, Bursa'ya birlikte gittiği erkeğin evine giderek kızını buldu. Bulunan genç kız emniyet ekiplerince İnegöl'e getirilerek ailesine teslim edildi. Kızlarına kavuşan aile mutluluk gözyaşı döktü.			
Başlık	28 gündür aranan genç kız bulundu			
Üretilen Başlık		Ölçüm		
		ROUGE-1	BLEU	F1 Skoru
20 Dönem	### gündür kayıp kız arkadaşında çıktı	0.5	0.55	0.52
25 Dönem	### yaşındaki genç kız yol kenarında ölü bulundu	0.4	0.44	0.42

ÖZGEÇMİŞ

Abdulkadir KARACA, 05.11.1994 tarihinde İstanbul'da doğdu. İlköğrenim ve ortaöğrenimini İstanbul'da bitirdi. Lisans eğitimine 2012 yılında Trakya Üniversitesi Bilgisayar Mühendisliği Bölümü'nde başladı ve 2016 yılında mezun oldu. 2018 yılında ise Trakya Üniversitesi Bilgisayar Mühendisliği Bölümü'nde yüksek lisans eğitimine başladı.