



**TANI/TEDAVİ SÜRECİNDE KULLANILMAK ÜZERE TIBBİ
GÖRÜNTÜLEME RAPORLARININ OTOMATİK ÖZETLENMESİ**

Sümevra KUŞ ORDU

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Sümevra KUŞ ORDU

07/07/2023

TANI/TEDAVİ SÜRECİNDE KULLANILMAK ÜZERE TIBBİ GÖRÜNTÜLEME RAPORLARININ OTOMATİK ÖZETLENMESİ

(Yüksek Lisans Tezi)

Sümeyra KUŞ ORDU

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2023

ÖZET

Tıbbi görüntüleme raporları, hastalıkların teşhis ve tedavisinde önemli bir rol oynamaktadır. Tedavi sürecinde özellikle en son tetkik edilen tıbbi görüntüleme raporları kullanılıyor olsa da hastaya ait önceki görüntüleme raporlarının da dikkate alınması önemli olabilir. Hastanın durumu ve tedavi sürecinin etkileri önceki görüntüleme sonuç raporlarının dikkate alınmasıyla en doğru bir şekilde belirlenebilir. Günümüzde yaygın olarak kullanılan sağlık bilgi sistemleri hastalara ait klinik bilgilerle birlikte tüm tıbbi görüntüleme raporlarını da saklamaktadır. Ülkemizde, e-Nabız ile kişilere ait tüm sağlık bilgileri tek bir noktadan erişilebilir hale gelmiştir. Hekimler bu sistem sayesinde hastalara ait sağlık bilgilerine erişebilmekte, tanı ve tedavide bu bilgileri kullanabilmektedirler. Ancak geçmiş sağlık verilerine tek tek erişmek ve yeniden yorumlamak hekim açısından oldukça zahmetli ve zaman alıcıdır. Çalışmada tıbbi görüntüleme raporlarının otomatik özetlenmesi ve tanı ve tedavi sürecinde etkin bir şekilde kullanılması amaçlanmıştır. Özetleme çalışmasında, Tıbbi Görüntüleme Merkezlerinden alınan 2457 tıbbi görüntüleme raporu kullanılmıştır. Tıbbi görüntüleme raporlarının özetlenmesi için literatürde sıklıkla kullanılan doğal dil işleme yöntemleri kullanılmıştır. Doğal dil işleme verilerin önışlem sürecinde kullanılmıştır. Verinin vektörlerle ifade edilmesinde ve model çıkarımında literatürde yaygın ve başarılı bir şekilde kullanılan farklı metin özetleme yaklaşımları kullanılmıştır. Doğal dil işlemenin gelişiminde etkin rol oynayan derin öğrenmeyle de özetleme çalışmaları yapılmıştır. Elde edilen model başarıları ROUGE metriği ile değerlendirilmiştir. ROUGE, sistem tarafından oluşturulan özetini insan tarafından oluşturulan özet ile karşılaştırmaktadır. Elde edilen özetler, doktor tarafından oluşturulan ve tıbbi görüntüleme raporlarının önemli kısımlarının vurgulandığı sonuç ve not bölümüyle kıyaslanmıştır. Raporların sonuç bölümünde yer alan kritik bulgular, çalışmada elde edilen özetinde de yer almıştır. Türkçe metinlerin özetlenmesi üzerine yapılan çalışmalarının azlığı ve sağlık alanında özetleme sistemlerine olan ihtiyaç, bu çalışmayı önemli kılmaktadır.

Bilim Kodu : 92432

Anahtar Kelimeler : Doğal dil işleme, metin özetleme, tıbbi görüntüleme raporu, radyoloji

Sayfa Adedi : 64

Danışman : Doç. Dr. Oktay YILDIZ

AUTOMATIC SUMMARY OF MEDICAL IMAGING REPORTS TO BE USED IN THE DIAGNOSIS/TREATMENT PROCESS

(M. Sc. Thesis)

Sümeysra KUŞ ORDU

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2023

ABSTRACT

Medical imaging reports play a significant role in the diagnosis and treatment of diseases. Although the most recent medical imaging reports are used in the diagnosis and treatment process, it may be important to consider the previous imaging reports of the patient. The patient's condition and the effects of the treatment process can most accurately be determined by considering previous imaging results reports. Today, widely used health information systems store all medical imaging reports as well as clinical information of patients. In addition, with e-Nabız, all health information of individuals has become accessible from a single point. Thanks to this system, physicians can access the health information of patients and use this information in diagnosis and treatment. However, accessing and reinterpreting past health data one by one is very laborious and time-consuming for the physician. The study, it is aimed to automatically summarize medical imaging reports and to use them effectively in the diagnosis and treatment process. In the recapitulation study, 2457 medical imaging reports from Medical Imaging Centers were used. Natural language processing methods, which are frequently used in the literature, were used to summarize medical imaging reports. Natural language processing was used in the preprocessing of the data. Different text summarization approaches, which are widely and successfully used in the literature, have been used in the expression of data with vectors and model extraction. Summarization studies have also been carried out with deep learning, which plays an active role in the development of natural language processing. The model achievements obtained were evaluated with the ROUGE metric. ROUGE compares the system-generated summary with the human-generated summary. The summaries obtained are compared with the conclusion and note section of the physician-generated medical imaging reports, where important parts of the medical imaging report are highlighted. The critical findings in the conclusion part of the reports are also included in the summary obtained in the study. The scarcity of studies on summarizing Turkish texts, and the need for summary systems in the field of health makes the study important.

Science Code : 92432

Key Words : Natural language processing, text summarization, medical imaging report, radiology

Page Number : 64

Supervisor : Assoc. Prof. Dr. Oktay YILDIZ

TEŞEKKÜR

Çalışmam süresince desteklerini esirgemeyen, bilgi ve tecrübesiyle yol gösteren, beni motive eden, kendisinden çok şey öğrendiğim ve öğrencisi olmaktan gurur duyduğum danışmanım sayın Doç. Dr. Oktay YILDIZ hocama sonsuz teşekkür ederim. Lisans ve yüksek lisans eğitimim süresince bilgi ve tecrübelerinden faydalandığım ve birlikte çalışmaktan keyif aldığım Gazi Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümündeki tüm hocalarıma teşekkürlerimi sunarım. Hayatımın her safhasında desteklerini üzerimde hissettiğim, beni yeni şeyler öğrenmeye ve kendimi geliştirmeye teşvik eden canım aileme ve her konuda yardımcı ve anlayışlı olan, beni cesaretlendiren sevgili eşime teşekkürü borç bilirim. Çalışmam boyunca bana az ya da çok yardımı dokunan herkese teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
RESİMLERİN LİSTESİ.....	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	5
3. TEORİK ARKA PLAN.....	11
3.1. Doğal Dil İşleme.....	11
3.1.1. Uygulama alanı	11
3.1.2. Doğal dil işlemede zorluklar	12
3.1.3. Doğal dil işleme kütüphaneleri	13
3.2. Metin Özetleme	15
3.2.1. Kelime vektörleri.....	19
3.2.2. Çıkarımsal özetleme	24
3.3. Derin Öğrenme	25
3.4. Başarı Ölçütleri	27
3.4.1. Kosinüs benzerliği.....	28
3.4.2. Recall-oriented understudy for gisting evaluation (ROUGE).....	28

	Sayfa
4. DENEYSEL ÇALIŞMA	31
4.1. Veri Kümesi	31
4.2. Veri Ön işleme	35
4.2.1. Ayırma ve normalleştirme adımları	37
4.2.2. Sözdizimsel analiz adımı.....	40
4.3. Kelime Vektörlerinin Çıkarılması	42
4.4. Model Çıkarımı	44
4.4.1. LSTM.....	44
4.4.2. TextRank.....	49
4.4.3. LSA.....	51
4.4.4. Kural tabanlı özetleme	53
4.5. Deneysel Sonuçlar	54
4. SONUÇ VE TARTIŞMA	55
KAYNAKLAR	59
ÖZGEÇMİŞ	65

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Doğal dil işleme kütüphaneleri	14
Çizelge 3.2. One- hot vektör için cümle örneği.....	21
Çizelge 3.3. One-hot encoding matris örneği	22
Çizelge 4.1. Tıbbi terimlere karşılık gelen düzeltme önerileri	40
Çizelge 4.2. Bulgu ve sonuç için kelime dağılım yüzdeleri	45
Çizelge 4.3. Sonuç ve elde edilen özet örneklerden biri.....	48
Çizelge 4.4. Sonuç ve elde edilen özet örneklerden bir diğeri	49
Çizelge 4.5. Metinden cümle örnekleri	50
Çizelge 4.6. Cümlelerin kosinüs benzerlikleri.....	51
Çizelge 4.7. Deneysel sonuçlar.....	54

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Metin özetleme türleri sınıflandırması.....	16
Şekil 3.2. Çıkarımsal özetleme yaklaşımı.....	17
Şekil 3.3. Soyutlayıcı özetleme yaklaşımı	18
Şekil 3.4. CBOW ve Skip-gram modellerinin genel yapısı	22
Şekil 3.5. TextRank ile özetleme işlem adımları	25
Şekil 3.6. LSTM yönteminin genel yapısı	26
Şekil 4.1. Tez çalışmasının genel yapısı	31
Şekil 4.2. Veri kümesindeki öznitelikler birlikte ilk beş satır.....	35
Şekil 4.3. Doğal dil işleme adımları.....	36
Şekil 4.4. Tıbbi görüntüleme raporlarında noktanın kullanımına örnek.....	37
Şekil 4.5. Cümlelerine ayırma	37
Şekil 4.6. Kelimelerine ayırmada noktalama işaretlerine örnek	38
Şekil 4.7. Kelimelerine ayırmada normalizasyon sonucu noktalama işaretlerine örnek	38
Şekil 4.8. Kelimelerine ayırma	38
Şekil 4.9. Normalizasyon sonucunda kelimelerine ayırma.....	39
Şekil 4.10, Yazım yanlışı düzeltme örneği (doğru)	40
Şekil 4.11. Yazım yanlışı düzeltme örneği (hatalı).....	40
Şekil 4.12. POS etiketleme	42
Şekil 4.13. BOW kelime vektörü örneği.....	43
Şekil 4.14. Word2Vec kelime vektörü örneği	43
Şekil 4.15. Word2Vec kelime benzerlik vektörü.....	44
Şekil 4.16. Kelime dağılımları	44

Şekil	Sayfa
Şekil 4.17. Geliştirilen model	46
Şekil 4.18. Model test ve eğitim kayıp grafiği (Epoch 50, batch boyutu: 128).....	47
Şekil 4.19. Model test ve eğitim kayıp grafiği (Epoch 10, batch boyutu: 32).....	47
Şekil 4.20. LSTM metin örneği	48
Şekil 4.21. LSTM bir başka metin örneği.....	49
Şekil 4.22. Metin graf gösterimi	50
Şekil 4.23. TextRank özetlemede metin örneği	51
Şekil 4.24. TextRank ile elde edilen özet örneği	51
Şekil 4.25. LSA ile iki raporun cümle puanları	52
Şekil 4.26. LSA ile özetlemede metin örneği	52
Şekil 4.27. LSA ile elde edilen özet örneği	52
Şekil 4.28. Bir hastaya ait son tetkik raporu	53
Şekil 4.29. Bir hastaya ait rapor.....	53
Şekil 4.30. Kural tabanlı özetleme ile elde edilen sonuç	54

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 4.1. Bir hastaya ait tıbbi görüntüleme raporu örneği	33
Resim 4.2. Bir hastaya ait not bölümü olan tıbbi görüntüleme raporu örneği.....	34



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

mm

Milimetre

Kısaltmalar

Açıklamalar

ARDS

Akut Solunum Sıkıntısı Sendromu

BOW

Bag of Words

BT

Bilgisayarlı Tomografi

CBOW

Continuous Bag of Words

CNN

Convolutional Neural Networks

CRF

Conditional Random Field

DT

Decision Tree

GA

Genetic Algorithm

GloVe

Global Vectors for Word Representation

NLP

Natural Language Processing

MR

Manyetik Rezonans

NLTK

Natural Language Toolkit

KNN

K-Nearest Neighbors

LSA

Latent Semantic Analysis

LSTM

Long Short-Term Memory

PGN

Pointer-Generator Networks

POS

Part-of-Speech

RNN

Recurrent Neural Network

ROUGE

Recall-Oriented Understudy for Gisting Evaluation

SVM

Support Vector Machine

TF- IDF

Term Frequency - Inverse Document Frequency

1. GİRİŞ

Bilgisayar teknolojilerinde yaşanan gelişme, internet ve sosyal medya kullanımında yaşanan artış, dijital ortamda bulunan veri miktarını artırmıştır. Sürekli olarak, üretilen içerik ve bilgi boyutu artmaktadır. Günümüzde herhangi bir konu hakkında araştırma yapıldığında sayısız kaynakla karşılaşmaktadır. Bu kaynakların çoğu ise metin türünde verilerdir. Günlük yaşamda üretilen veriler (ses, konuşma, yazılı metin vb.) üzerinde işlem yapmak Doğal Dil İşlemenin (NLP-Natural Language Processing) konusudur. NLP insana özgü dillerin işlenmesi ve kullanılması için araştırma yapan bir bilim dalıdır. NLP, yazım denetimi, otomatik düzeltme ve anahtar kelime bulma gibi temel işlemler ve makine çevirisi, sınıflandırma ve bilgi çıkarımı gibi daha karmaşık işlemler için kullanılmaktadır. Günlük yaşamda karşılaşılan kaynakların tamamını okuyabilmek veya inceleyebilmek mümkün değildir. Verilerin bu kadar çok olduğu ortamda istenen bilgiye ulaşmak ciddi bir problemdir. Günümüz bilgi çağı, aranan bilgiye daha çabuk ve hızlı erişmeyi zorunlu hale getirmektedir. Bununla birlikte NLP'nin önemli problemlerinden biri olan metin özetleme önem kazanmıştır. Metin özetleme, aranan konu ile ilgili en önemli bilgileri hızlı bir şekilde sunmaktadır. Metin özetleme sistemleri orijinal metni alarak bu metni daha kısa bir şekilde metin içerisindeki önemli içeriği barındıracak şekilde yeniden ifade edilmesi olarak tanımlanabilir [1-3].

Son yıllarda derin öğrenmede yaşanan gelişmelerle birlikte doğal dil işleme alanında da gelişmeler yaşanmıştır. Çoğu büyük firmanın yapısında NLP birimi olmakla birlikte NLP'de derin öğrenmeden faydalanılmaktadır. Apple-Siri, Microsoft Cortana, Google Asistan ve Amazon-Alexa bu duruma örnek olarak gösterilebilir. Geçmişte ise doğal dil işlemede daha çok kural tabanlı yöntemler kullanılmaktaydı. 1966 yılında Weizenbaum tarafından geliştirilen Eliza ve 1972 yılında Colby tarafından geliştirilen Parry sohbet programları kural tabanlı doğal dil işlemeye örnek olarak gösterilebilir. Geçmişten günümüze NLP alanında yaşanan gelişmeleri bu programlar daha somut bir şekilde gözler önüne sermektedir [4-6].

Dünyada konuşulan çok sayıda farklı dil olması, dillerde çok fazla kelime olması ve aynı kelimenin birden fazla olması NLP'yi zorlu bir problem haline getirmektedir. Türkçe ise sondan eklemeli bir dil olduğu için kelimeyi analiz etmek, üzerinde işlem yapmak ekstra zordur. Türkçe metinler üzerinde çalışmanın bir zorluğu da uygun veri kümesinin

bulunmayışıdır. UCI ve Kaggle gibi araştırmalarda kullanılmak üzere veri kümesi sunan sistemlerde Türkçe metin içeren veri kümesi oldukça azdır. Bu sistemlerde metin sınıflandırması için “benchmark” veri kümesi bulunmaktadır. Bu veri kümesinin içeriğini ise farklı portallardan elde edilen farklı kategorilerdeki haber metinleri oluşturmaktadır. Bu durum Türkçe metinler için NLP çalışmalarını zorlaştırmaktadır. Dolayısıyla Türkçe metinler için yapılan çalışmalar yetersizdir ve çoğunluğu haber metinleri ile sınırlıdır [7, 8].

Son yıllarda pandeminin (COVID-19) de etkisiyle sağlık alanındaki çalışmalar da önem kazanmıştır. Hastalıkların teşhisinde ve tedavi sürecinde tıbbi görüntüleme (radyoloji) raporları önemli rol oynamaktadır. Radyoloji, tıpta önemli bir uzmanlık alanı olup, kanser, kalp ve damar hastalıkları, iskelet sistemi hastalıkları gibi pek çok hastalığın teşhisinde, sinir sisteminin kontrolü ve gebeliğin takibi gibi bazı kontrol ve takiplerde radyolojiden faydalanılır. Radyolojide, mamografi, manyetik rezonans (MR), bilgisayarlı tomografi (BT), ultrason ve röntgen gibi çeşitli tıbbi görüntüleme yöntemleri kullanılarak canlıların iç yapısı ayrıntılı olarak görüntülenir. Görüntüler, radyologlar tarafından yorumlanır ve rapor hazırlanır [1]. Radyoloji raporlarının belirli standartlara göre hazırlanması gerekse de çoğu zaman tanımlı olan kurallar ihlal edilmektedir. Bazı raporlar uzun paragraflar halinde, bazıları ise maddeler halinde yazılmaktadır. 2018 yılında yapılan bir anket sonucunda doktorların sadece %55,7’sinin radyoloji raporlarını tam olarak okudukları görülmüştür [9]. Ayrıca yapılan araştırmalar ve anketler doktorların serbest metin yerine yapılandırılmış metin tercih ettiklerini göstermektedir [9, 10]. Uzun raporları okumak hem zordur hem de bu raporlar önemli noktaların gözden kaçmasına neden olabilir. Radyoloji raporlarının yapılandırılması raporların karşılaştırılabilirliğini artırır ve belirsizliği aza indirir [10-13]. Radyoloji raporları NLP ile doktorlar için daha verimli hale getirilebilir.

Hastalığın doğru teşhisi ve tedavisi açısından yeni yapılan tetkiklere ek olarak geçmiş tetkik sonuçlarını içeren raporların incelenmesi önem arz etmektedir. Ayrıca belirli bir hastalığın takibi açısından da yeni test sonuçlarının geçmiş sonuçlarla birlikte incelenmesi gerekmektedir. Günümüzde yaygın olarak kullanılan sağlık bilgi sistemleri, hastaların klinik bilgilerinin yanı sıra tüm tıbbi görüntüleme raporlarını da saklamaktadır. Türkiye’de “e-Nabız” sistemi ile tüm bireylerin sağlık bilgilerine tek noktadan ulaşılabilir hale gelmiştir. Bu sistem sayesinde hekimler hastalarının sağlık bilgilerine ulaşabilmekte ve bu bilgileri tanı ve tedavide kullanabilmektedir. Geçmişte geçirilen bazı hastalıkların etkileri yanlış teşhise neden olabilmektedir. Örneğin, geçmişte yaşanan bazı hastalıkların neden olduğu

akciğer tahribatları, günümüzde COVID-19'un neden olduğu akciğer tutumu ile karıştırılabilmektedir. Akciğer hasarını içeren akut solunum sıkıntısı sendromu (ARDS), Pnömoni gibi hastalıklar sıklıkla COVID-19 ile ilişkilendirilmektedir [14]. Bu gibi durumlar geçmişteki tıbbi görüntüleme raporlarının incelenmesinin önemini göstermektedir. Geçmişte geçirilen hastalıklar nedeniyle organlarında çeşitli tahribatları olan hastaların geçmiş raporları incelenerek aslında bu hasarların COVID-19 ile ilişkili olmadığı anlaşılabilir. Doktorların iş yükü düşünüldüğünde bir hastaya ait sisteme kayıtlı tüm raporların incelenmesi zaman alıcı olması nedeniyle oldukça zordur. Bu sebeple tanı ve tedavi sürecinde genellikle en son tetkik raporlarının kullanılmaktadır. Hastaya ait önceki raporların dikkate alınamaması tanı ve tedavinin başarısını önemli derecede etkilemektedir. Hastalığın tanısı ve tedavi süreci önceki görüntüleme raporlarının dikkate alınmasıyla en doğru şekilde belirlenebilir. Tez Çalışmasında, hastaya ait önceki görüntüleme raporlarının otomatik özetlenmesi gerçekleştirilerek elde edilen özet raporların tanı ve tedavi sürecinde etkili bir şekilde kullanılabilmesi hedeflenmektedir.

Gerçekleştirilen çalışma ile:

- Hastalara ait geçmiş tıbbi görüntüleme raporlarının otomatik özetlenmesi,
- Doğru tanı ve etkin tedavi için güncel ve önceki tüm görüntüleme raporlarının etkin bir şekilde kullanılabilmesi,
- Önceki görüntüleme sonuç raporlarının hızlı sorgulanması ve raporlara kolay erişme ve böylece hastalığın tanı ve tedavisinde başarımın arttırılması amaçlanmaktadır.

Özet raporlarla hastaların geçmiş görüntüleme sonuçları ile mevcut sonuçlar hızlı bir şekilde karşılaştırılacak ve daha doğru teşhis ve tedavi için mevcut ve önceki tüm raporlar etkin bir şekilde kullanılacaktır. Özet raporlar, uzman hekimlere yardımcı olarak zaman kazandıracak ve iş yükünü azaltacaktır. Uzun raporların yerine özet raporların tamamının okunması daha olası olacağından önemli detayların gözden kaçma olasılığı azalacaktır.



2. LİTERATÜR TARAMASI

Günümüz bilgi çağı metin özetleme çalışmalarını gerekli kılmaktadır. Metin özetleme çalışmaları son yıllardaki karşımıza çıkan büyük veri ve derin öğrenme kavramları ile yeni bir boyut kazanmıştır. Metin özetleme çalışmaları, teknolojik gelişmelerden ve COVID-19 pandemiden etkilense ve yaygınlaşsa da 20. Yüzyılın ortalarından beri üzerinde çalışılan bir problemdir. İlk başlarda yapılan çalışmalar daha çok kural tabanlıyken 20. yüzyılın sonlarında doğru istatistiksel yaklaşımlar önem kazanmıştır. Daha sonraları, istatistiksel yaklaşımlar makine öğrenmesi ile birlikte kullanılmıştır. Son yıllarda derin öğrenmede yaşanan gelişmelerle NLP alanında da gelişmeler olmuş ve NLP yöntemleri de değişmiştir. İlk sohbet robotu ELİZA ile 2022 yılında piyasaya sürülen ChatGPT arasındaki fark NLP'de yaşanan gelişmeyi somut bir şekilde gözler önüne sermektedir [6, 15, 16].

Metin özetleme çalışmaları ilk olarak 1950'lerde İngilizce metinler için yapılmıştır. Luhn [17], özet çıkarmak için kelimelerin cümle içinde kullanılma frekanslarından yararlanmıştır. Yaptığı çalışmada, bir terimin metin içerisinde kullanılma sıklığının terimin metin içindeki önemini gösterdiğini belirtmiştir. Böylece, terim sıklığı, diğer bir ifadeyle kelime frekansı kavramını literatüre kazandırmıştır. Edmundson [18], kelime frekanslarına ek olarak, “özetle”, “sonuç olarak” gibi ipucu içeren ifadeleri, başlığı oluşturan kelimeleri ve cümlelerin metin içerisindeki pozisyonunu yeni birer özellikler olarak almıştır. Yapılan diğer çalışmaların pek çoğunda bunlara başlık, anahtar kelime vb. ek özellikler eklenerek özetleme yapılmıştır. Belirlenen özelliklere bakılarak puanlandırma ve ağırlıklandırma yapılarak özet metinler elde edilmiştir. Özetleme çalışmalarında, soyutlayıcı ve çıkarımsal özetleme şeklinde iki farklı özetleme yaklaşımı kullanılmaktadır. Çıkarımsal özetlemede metin içerisindeki cümleler önemine göre seçilir. Metindeki cümleler olduğu gibi alınarak bir araya getirilir. Soyutlayıcı özetlemede ise metnin içeriği ve konusu incelendikten sonra özet, yeni cümleler ve farklı kelimelerle oluşturulur. Çıkarımsal özetlemede cümleler metinden alındığı için farklı kelime bulunmaz ve gelişmiş dilbilimsel yöntemlere ihtiyaç duyulmaz. Bundan dolayı soyutlayıcı özetlemeye göre daha az karmaşıktır. Literatür taramasında, metin özetleme çalışmalarında çıkarımsal özetleme yaklaşımının daha fazla kullanıldığı gözlemlenmiştir. Literatürdeki kaynakların büyük çoğunluğunda, metin özetleme çalışmaları İngilizce ve Çince dilleri üzerine yoğunlaşmaktadır. Türkçe pek çok kaynakta Türkçe için yapılan çalışmaların yetersiz olduğu belirtilmiştir.

Türkçe metin içeren veri kümesinin sayılı olması nedeniyle Türkçe metinler için yapılan çalışmalar da yetersizdir ve çoğunluğu kamuya açık verilerden olan haber metinleri ile sınırlıdır. Çöltekin ve arkadaşları [19] makalelerinde, Türkçe NLP çalışmalarında kullanılan veya toplanan Türkçe metin içeren veri kümelerini paylaşmıştır. Yapılan çalışmalarda gazetelerde yayınlanmış olan haber metinleri, Türkçe tweetler ve ürün ya da hizmet sunan çeşitli web sitelerdeki değerlendirmelerin veri olarak kullanılmakta olduğu gözlemlenmiştir.

Türkçe NLP çalışmalarında daha çok Türkçe metinlerin sınıflandırılması üzerine yoğunlaşmıştır. Gürçan yaptığı [20] Türkçe metinlerin sınıflandırılmasında Naive Bayes (Multinomial ve Bernoulli) Destek Vektör Makineleri (Support Vector Machine- SVM), K-En Yakın Komşu (K-Nearest Neighbors – KNN) ve Karar Ağaçları (Decision Tree - DT) gibi farklı makine öğrenmesi algoritmaları ile çalışmıştır. Deneysel çalışmasında veri olarak haber metinlerini kullanmıştır. En başarılı sınıflandırmayı Naive Bayes (Multinomial) yöntemi vermiştir (%90). Amasyalı ve Diri [21] metnin türü, yazarı, yazarın cinsiyeti açısından Türkçe metinleri sınıflandırmıştır. Spor, politika, popüler konular gibi farklı konulara göre haber metinleri rasgele seçilmiş ve üzerinde çalışılmıştır. Sınıflandırmada Naive Bayes, SVM, C 4.5 ve Rassal Orman yöntemleri kullanılmıştır. En başarılı sonucu Rassal Orman algoritması vermiştir (%96). Kuyumcu, Aksakalli ve Delil [22] Türkçe metinlerin sınıflandırılması üzerine yaptıkları çalışmada haber metinlerini kullanmışlardır. Kök bulmada Zemberek aracını kullanmışlardır. Sınıflandırmada Facebook'un geliştirdiği fastText aracını, KNN ve Naive Bayes yöntemlerini kullanmışlardır. %93 başarıyla en hızlı şekilde (0,20 saniye) sınıflandırmayı fastText vermiştir. Bu çalışmalarda görüldüğü gibi NLP'de istatistiksel yöntemler de yaygın ve başarılı bir şekilde kullanılmaktadır.

Türkçe haber metinleri sadece sınıflandırmada değil özetlemede de yaygın olarak kullanılmaktadır. Türkçe özetleme çalışmaları genel olarak terim sıklığı kavramına bazı özellikler eklenerek puanlandırmaya dayalı yapılan özetleme çalışmalarıdır. Çalışmalarda metinler genel olarak çıkarımsal yaklaşımla özetlenmektedir. Çıkarımsal özetleme çalışmalarında istatistiksel ve sezgisel yöntemler yaygın olarak kullanılmaktadır. Uzundere ve arkadaşları yaptıkları çalışmada [23], özeti çıkarılacak metnin cümlelerini yüksek frekans, anahtar kelimeler, negatif/pozitif kelimeler, özel isimler, sayılar gibi önceden belirledikleri on üç özelliğe göre sezgisel olarak puanlandırmış, kullanıcının istediği özetleme oranına göre en yüksek puanlı cümleleri seçerek metnin özetini çıkarmışlardır. Çalışmada, Zemberek kütüphanesinden yararlanılmıştır. Kullanıcılarla sistemin özet olarak

kabul ettiđi aynı cümlelerin sayısının oranları hesaplanarak sistem değeriendirilmiştir. Sonuçların ortalamasının alınmasıyla sistem performansı %55 bulunmuştur. Hatipođlu ve Omurca [24] çalışmalarında, çıkarımsal özetleme yönteminin iki farklı alt yöntemi olan istatistiksel olarak puanlandırma ve gizli anlam çıkarım yöntemlerini sezgisel olarak birleştirerek cümle seçimi yapan melez bir model önermiştir. Geliştirilen sistem ve farklı kullanıcılara aynı metinler verilerek elde edilen özetler karşılaştırılmıştır. Sonuçlar incelendiğinde, kısa metinlerde sistemin başarımı daha yüksek iken metinlerin uzunluğu arttıkça sistemin başarımını düşmekte olduđu görölmüştür. Farklı uzunlukta metinler özetlenmiş ve %77,5 ve %82 oranında başarı elde edilmiştir.

Metin özetlemede genetik algoritma ve bulanık mantık gibi farklı yöntemlerin de kullanıldığı çalışmalar vardır. Kaynar ve arkadaşları [25] çalışmalarında, Türkçe metinler için özellik tabanlı belge özetleme sistemi önermişlerdir. Çalışmada, ilk olarak belge içerisindeki cümleleri temsil edecek öznitelikler çıkarılmış, ardından bu özniteliklerin özet oluşturmadaki etkinliđi genetik algoritma (Genetic Algorithm - GA) yardımıyla belirlenmeye çalışılmıştır. Belgeler GA yardımıyla eğitilerek, özniteliklere ilişkin en iyi ağırlık değeri belirlenmiştir. GA'nın elde ettiđi ağırlıklar, test verileri üzerinde 0,828 Rouge- 1 ve 0,744 Rouge-2 skoru elde edilmiştir. Yapılan bu çalışmayla, GA vasıtasıyla ağırlıkları belirlenmiş olan sistemin ciddi bir oranda başarı artışı gösterdiđi gözlemlenmiştir. Soyutlayıcı özetleme ile ilgili yapılmış çalışma sayısı azdır hatta soyutlayıcı özetlemeye yönelik yapılan bir çalışmada da Türkçe metinler için soyutlayıcı özetleme çalışmalarının mevcut olmadığı belirtilmiştir.

Türkçe harici diller için yapılmış ve yapılmakta olan pek çok çalışma vardır. Türkçe için yapılan çalışmalara kıyasla çok daha fazla ve farklı tekniklerle yapılmış çalışma vardır. Literatürde istatistiksel [26], graf tabanlı [27], bulanık mantık tabanlı [28, 29] ve küme tabanlı yaklaşımları kullanan birçok çalışma bulunmaktadır [30-32]. Hark ve arkadaşları [2], çıkarımsal bir metin özetleme yöntemi önerdikleri çalışmalarında, özetlenmesi istenen metinleri yönlendirilmemiş ve ağırlıklı çizgeler ile temsil etmişlerdir. Çizgeler üzerinde yapısal kararlılıđı ve mevcut bilgi miktarını belirlemek için çizge entropiyi kullanmışlardır. Önerilen yöntem, açık erişimli metinler ve bu metinlere ait özetleri içeren DUC 2002 veri seti üzerinde ROUGE metriđi ile değeriendirilmiştir. N değeri 1, 2, 3 ve 4 olarak belirlenmiş ve literatürdeki bazı çalışmalar ile duyarlılık, kararlılık ve F1-Skor değeri karşılaştırılmıştır. ROUGE-1 için TextRank 0,48 duyarlılık, 0,44 kesinlik, 0,46 F1-Skor

değerinde, LexRank 0,48 duyarlılık, 0,46 kesinlik, 0,47 F- skor değerinde önerilen yöntem ise 0,45 duyarlılık, 0,42 kesinlik, 0,43 F- skor değerinde performans göstermiştir. Çalışmanın sonucunda, önerilen yöntemin diğer çalışmalarda kullanılan yöntemlerle rekabetçi olduğu, rekabet edebilecek düzeyde performans gösterdiği görülmüştür. Hark ve arkadaşları [27] bir başka çalışmalarında, çizgeler üzerinde farklı özellik çıkarım yöntemleri uygulamışlardır. Cümlelerin önemine dair lineer bir ağırlıklandırma yöntemi üzerinde durmuşlardır. Bu çalışmalarında başarılarını artırarak 0,50'nin üstünde ROUGE değeri elde etmişlerdir. Radev ve Fan [26], arama motoru listelerinin otomatik olarak özetlenmesi üzerine çalışmışlardır. Özetleme yöntemi olarak çıkarımsal özetleme yöntemi kullanılmıştır. Cümleleri ayrı ayrı puanlandırarak en yüksek puan verenler kümelenip çıktı alınmıştır. Puanlandırmada, kelime sıklığı, konumsal değer gibi çeşitli faktörler ele alınmıştır. Gong ve Liu [33], belgeleri özetlemede cümleleri ilişkilerine göre sıralamak için alaka düzeyi ölçüsünü, anlamsal olarak önemli cümleleri tanımlamak için gizli anlamsal analiz yöntemini kullanmışlardır. Yöntemler, kesinlik, duyarlılık ve f ölçeğine göre değerlendirilmiştir. Gizli anlamsal analiz tekniğinin diğer yöntemlere göre daha başarılı performans gösterdiği görülmüştür (0,53 duyarlılık 0,61 kesinlik 0,57 fl-skor). Binwahlan, Salim ve Suanmali [34], özetlemede önemli olan özelliğin belirlenmesinde parçacık sürü optimizasyon tekniklerini kullanmıştır.

Derin öğrenme alanındaki gelişmeler sayesinde son yıllarda metin özetleme çalışmalarında derin öğrenme yöntemleri sıklıkla kullanılmaya başlanmıştır. Evrişimsel Sinir Ağları (Convolutional Neural Networks - CNN), Yinelemeli Sinir Ağı (Recurrent Neural Network - RNN) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) yöntemleri etkili bir şekilde özetlemektedir. Diziden diziye (seq2seq) modeli, soyutlayıcı özetleme üzerine yapılan çalışmalarda yaygın olarak kullanılmaktadır. Alınan hizmet ya da ürün hakkında yapılan değerlendirmeler üzerinde yapılan doğal dil işleme çalışmaları da oldukça yaygındır. Derin öğrenme ise bu tür çalışmalarda yaygın olarak kullanılmaktadır. Yang çalışmasında [35], ürünler hakkında yapılan değerlendirmeleri soyutlayıcı olarak özetlemiştir. Özetleme modelini dikkat tabanlı kodlayıcı ve kelime torbası mekanizmasına sahip ileri beslemeli sinir ağı ve RNN ile geliştirmiştir. Değerlendirmelerin özetlerinin çıkarıldığı sistem başarısını ROUGE-N metriği kullanarak ölçmüştür. Toplam üç modelin geliştirilip kıyaslandığı çalışmada %80'lerde başarı elde edilse de başarısı daha düşük olan diğer modelin (dikkat tabanlı RNN) daha genel özetleme yaptığı ve özetlerin daha anlamlı olduğu yazar tarafından ifade edilmiştir. Zhang ve arkadaşları [36], soyutlayıcı özetleme ile ilgili yaptıkları

çalışmada CNN seq2seq mimarisine dayalı bir model geliştirmişlerdir. Nadir görülen sözcüklerle başa çıkabilmek, performansı artırmak için kopyalama mekanizmasını kullanmışlardır. Ayrıca, anahtar kelime ve cümleleri eş zamanlı modelleyebilmek için dikkat mekanizmasını modele eklemişlerdir. 3 farklı veri kümesi üzerinde test edilen model %30 ile %42 arasında performans göstermiştir (ROUGE-1). Song, Huang ve Ruan [37], soyutlayıcı metin özetleme ile yaptıkları çalışmada, LSTM- CNN tabanlı bir seq2seq modeli benimsemişlerdir. Kaynak cümlelerden cümleleri çıkaran ve derin öğrenmeyi kullanarak metin özetleri oluşturan iki aşamalı bir model geliştirmişlerdir. Değerlendirme metinleri sadece özetleme de değil duygu analizinde de kullanılmaktadır. Muhammad ve arkadaşları [38], 2500 adet otel değerlendirmelerini kullanarak metinden duygu analizi yapmışlardır. Duygu analizi için Word2Vec ve LSTM kullanmışlardır. Geliştirilen modelin başarısı %85,96'dır.

Sağlık verilerinin özetlenmesi ile ilgili çalışmalar son yıllarda önem kazanmıştır. Ancak, Sağlık sektöründe özetleme çalışmaları normal özetleme çalışmalarına kıyasla daha azdır. Klinik hasta bilgilerini ve elektronik hasta kayıtlarını özetlemek için yapılan çalışmalar bulunmaktadır. Türkçe sağlık metinleri üzerine yapılan çalışmalar genellikle sınıflandırma ile ilgilidir. Türk araştırmacılar tarafından bu alanda yapılan çalışmalarda ise genellikle bu konuyla ilgili Türkçe kamuya açık veri kümesi bulunmayışından kaynaklı İngilizce veriler kullanılmaktadır. Toplu ve Cangur [39] sağlık alanında dokümanları sınıflandırmak için yaptıkları çalışmada veri olarak Pubmed veri tabanından dokümanları (İngilizce) kullanmışlardır. Tabi ki, oluşturulan yeni bir veri kümesiyle yapılan çalışmalar da az da olsa mevcuttur. Yapılan araştırmalar sonucunda, çalışmalarında veri olarak tıbbi görüntüleme raporlarını kullanan az sayıda çalışma olduğu gözlemlenmiştir. Türkçe radyoloji raporlarının sınıflandırılmasına yönelik [40] ve raporlardan bilgi çıkarmaya yönelik bir çalışma [41] yapıldığı görülmüştür.

Derin öğrenme yöntemleri sağlık çalışmalarında etkin bir şekilde kullanılmaktadır. Laxmisan ve arkadaşları [12], bilinen bir hipertansiyon ve diyabet teşhisi içeren hastaların elektronik sağlık kayıtlarından bu hastalıklarla ilgili çıkarımsal özetler oluşturan bir sistem geliştirmişlerdir. Cümleleri sınıflandırmada doğrusal SVM, sıra olarak modellemede doğrusal zincir (linear chain) Koşullu Rastgele Alan (Conditional random field - CRF) ve özetlemede basit bir CNN kullanmışlardır. Sistem başarısını değerlendirmede ROUGE aracının F skor metriğini kullanmışlardır. Hipertansiyon ve diyabet için sırasıyla 0,657 ve

0,679 sistem performansı elde edilmiştir. Zhang ve arkadaşları [42], radyolojik bulguların sinirsel seq2seq ile otomatik özetleme üzerine çalışmışlardır. Kodlayıcı ve kod çözücü olarak çift yönlü LSTM ve kopyalama için İşaretçi Üreteci Ağı (Pointer-Generator/PG) kullanılmıştır. Sistem başarısı ROUGE-1, ROUGE-2 VE ROUGE-L ile değerlendirilmiştir. Sistem özetlerinin %67'si radyologlar tarafından çıkarılan özetler kadar iyi olduğu belirtilmiştir. MacAvaney ve arkadaşları [43], klinik raporları ontolojiye duyarlı bir şekilde soyutlayıcı olarak özetleyen bir sistem önermişlerdir. Özetlemede seq2seq modelini, ontolojiye duyarlı işaretçi üreteci (Ontology PG) yöntemini ve kodlayıcı ve kod çözücü olarak çift yönlü LSTM yöntemini kullanmışlardır. Soyutlayıcı özetlemede seq2seq mimari modelini benimseyerek Bir radyolog tarafından yapılan değerlendirmelerle sistem tarafından elde edilen özetler karşılaştırılarak sistem performansı değerlendirilmiştir. Ayrıca önerilen sistem, özetlemede Gizli Anlamsal Analiz (Latent Semantic Analysis -LSA) ve LexRank gibi kullanılan son yaklaşımlarla karşılaştırılmıştır. ROUGE değerlendirme sonucuna göre yapılan çalışmada önerilen yöntem karşılaştırılan yöntemlere göre daha iyi performans göstermiştir. Kim ve arkadaşları [44], elektronik sağlık kayıtlarındaki patoloji raporlarından anahtar kelimeleri çıkarmak için doğal dil işleme ve derin öğrenme yöntemlerinden faydalanmışlardır. Çalışmada BERT algoritması, LSTM, CNN ve Bayes gibi farklı yöntemlerle kıyaslanmıştır. BERT diğerlerine göre daha yüksek kesinlik ve duyarlılıkla birlikte daha iyi performans göstermiştir. Bozkurt ve arkadaşları [45], radyoloji raporlarındaki ölçümler ve tanımlayıcıları otomatik olarak algılamak için doğal dil işlemeden faydalanmışlardır. CT ve MR radyoloji raporları CRF modelini eğitmek ve test etmek için kullanılmıştır. Modelin genellenebilirliğini değerlendirmek için mamografi raporlarından da faydalanılmıştır.

3. TEORİK ARKA PLAN

Bu bölümde, çalışma için gerekli teorik altyapı sunulmuş, çalışmada kullanılan yöntemler ele alınmıştır. Metin, ses ve konuşma ile ilgili verilerle çalışmak doğal dil işleme kapsamına girmektedir. Metin özetleme ise zorlu bir NLP problemidir. NLP ve metin özetleme hakkında gerekli bilgiler aktarıldıktan sonra literatürde metin özetleme için kullanılan yöntemlerden bahsedilmiştir.

3.1. Doğal Dil İşleme

Metin, ses ve konuşma ile ilgili verilerle çalışmak doğal dil işleme kapsamına girmektedir. Metin verileri doğrudan işlenir fakat ses içeren veriler üzerinde doğrudan işlem yapılamamaktadır. Bu veriler yazılı metinlere çevrilir ve bu metinler doğal dil işlemeye uygun hale getirilip makine tarafından işlenir. Günlük yaşamda üretilen ses, konuşma, yazılı metin gibi veriler üzerinde işlem yapmak NLP'nin konusudur. NLP insana özgü dillerin işlenmesi ve kullanılması için araştırma yapan bir bilim dalıdır. Metinleri insan gibi anlamayabilmeyi ve insan gibi konuşabilmeyi amaçlar [16].

3.1.1. Uygulama alanı

Doğal dil işlemenin uygulama alanı oldukça geniştir. Metin üzerinde temel işlemlerde kullanımı olduğu gibi daha karmaşık işlemler için de kullanımı mevcuttur. NLP'nin uygulama alanından bazıları:

- Yazım Denetimi
- Otomatik düzeltme
- Anahtar kelime bulma
- Soru Cevaplama
- Metin Sınıflandırma
- Varlık ismi Tanıma
- Konuşma Etiketleme
- Bilgi çıkarımı
- Metin özetleme

- Makine Çevirisi
- Ses Tanıma
- Duygu analizi

Doğal dil işleme hayatımızın her alanında yer almakta ve birçok fayda ve imkân sağlamaktadır. Google veya Bing arama motorlarından arama yaparken, sistem bulduğu sonuçları sıralar. Yazım hatası mevcutsa “bunu mu demek istediniz” şeklinde düzeltmeler sunar. Burada NLP’nin makine çevirisi uygulamasına örnek verilmiştir. Doğal dil işlemenin uygulama alanı olan metin analizlerine firmaların iş alım sürecinden bir örnek verilebilir. Firmalar, bir işe başvuran kişilerin öz geçmiş metinlerini tarayarak kişileri aradıkları kriterlere göre sıralayabilir. Ayrıca yine metin üzerinde tarama yaparken iş ilan sayfalarından aradıkları kişiyi bulabilirler. Spam maillerin algılanmasında da doğal dil işleme yöntemlerinden faydalanılmaktadır. Gmail, Outlook gibi programlar metinleri algılamada bu yöntemden faydalanmaktadır. Atılan tweetlerin içeriğinin iyi ve kötü şeklinde sınıflandırılması ve Siri Alexa gibi insanlarla konuşan sistemler de doğal dil işlemeye örnek olarak verilebilir. Bu örneklerin sayısını artırmak mümkündür [6, 46].

3.1.2. Doğal dil işlemede zorluklar

Dil, C++, Java ve Python gibi makine dilleri ve Türkçe, İngilizce ve Çince gibi konuşulan doğal diller olmak üzere iki çeşittir. Makine dillerinde belirli kurallar vardır ve az sayıda kelime ile temsil edilir. Doğal diller ise bünyesinde çok kelime bulundurur ve kesin kurallar yoktur. Bundan dolayı doğal diller üzerinde işlem yapmak karmaşık bir problemdir.

Türkçe sondan eklemeli dil yapısı nedeniyle NLP için zorluk teşkil etmektedir. Türkçede kelimeler yaklaşık 30 bin kelime köküne yapım ve çekim ekleri eklenerek oluşturulmaktadır. Türkçe tarih boyunca Arapça ve Farsça gibi farklı pek çok dilin etkisi altında kalmıştır. Birden fazla yapım ekinin bir araya gelmesiyle oluşan kelime kullanımı yaygındır. Bilgisayar kelime köklerine ayırma işlemini Türkçe dilbilgisindeki gibi yapmaz. Kök bulmaya karşılık gelen *stemming* işleminde Türkçe dili için ekler fazla kırpıldığında problemler çıkmaktadır. Örneğin, “*yermek*” ve “*yemek*” kelimeleri köken olarak farklı olmasına rağmen kökü “*ye*” olarak bulunacaktır.

Kelimeler biçim birimlerine ayrılırken kelimenin biçim birimlere farklı bir şekilde ayrılması ve aynı ayrılan biçimbirimlerin farklı yorumlanması gibi durumlar mevcuttur. Örneğin "okuma" kelimesini ele alırsak "oku-ma" ve "ok-um-a" şeklinde farklı bir şekilde biçimbirimlerine ayrılabilir. Birinde kelime kökü isimken diğerinde fiildir. Bu kelimedeki "-ma" eki ise hem emir kipi olarak hem de mastar eki olarak yorumlanabilir.

Türkçede kelimelerin birbirinden farklı anlamları vardır. Örneğin, yüz kelimesinin TDK sözlüğe göre 15 farklı anlamı bulunmaktadır. Bunlardan yaygın kullanılan anlamlarına örnek vermek gerekirse, yüz kelimesi isim olarak hem bir sayıdır hem de çehre anlamında kullanılan bir kelimedir. Bu kökün farklı eklerle farklı kullanımı da mevcuttur. Kelimenin cümle de hangi anlamında kullanıldığını algılamak bilgisayarlar için zordur.

Kelimeler tek başına cümleden anlam çıkarmaya yetmemektedir. Cümle içerisinde kelimelerin kullanıldıkları sıralama değiştiği zaman verdikleri anlam da değişebilmektedir. Aynı kelime cümle içerisinde fiilden önce gelip fiili niteliyorsa zarf, isimden önce gelip ismi niteliyorsa sıfattır. "Ankara Türkiye'nin başkentidir." cümlesi ile "Türkiye'nin Ankara Başkentidir." cümlesi aynı kelimelerden oluşmalarına rağmen ikinci cümleyi anlamak daha zordur. Bu iki cümleden birincisi gramer açısından doğru olduğu için bu cümleyi anlamak daha kolaydır. NLP'de bir diğer zorluk ise zamirlerin anlaşılmasıdır. Metin içinde geçen "o", "bu", "şu" gibi zamirlere karşılık gelen nesne ya da kişileri çözümlemek zordur [16].

3.1.3. Doğal dil işleme kütüphaneleri

Metin içerisindeki cümlelerin ayrıştırılması, kelime köklerinin bulunması, edat-bağlaç-zamir gibi cümlelerin öğelerini belirleme vb. işlemler doğal dil işleme kütüphaneleriyle kolaylıkla gerçekleştirilmektedir. Bu kütüphaneler, çalışılan dilin gramer, etimolojik ve morfolojik özelliklerini içermektedir.

Doğal Dil İşleme kütüphanelerinden bazıları Çizelge 3.1'de gösterilmiştir. Doğal Dil İşleme kütüphaneleri tabloda listelenenden çok daha fazladır. NLTK, literatürde yaygın olarak kullanılmaktadır. NLTK Corpus kütüphanesinde, engellenecek kelimeleri, noktalama işaretlerini ve html etiketlerini kaldırmak için işlevler ve ayrıca kök ayırmayı gerçekleştirecek bir işlev vardır. Yapay zeka çalışmalarıyla kütüphane sayılarının artması şüphesizdir. Genelde kütüphaneler farklı birçok dili desteklemektedir. Fakat üzerinde

çalışılan dile ait özel olarak geliştirilmiş kütüphanelerin kullanılması başarıyı artırmaktadır.

Çizelge 3.1. Doğal dil işleme kütüphaneleri

Türkçe İçin Geliştirilen Kütüphaneler	Diğer Diller İçin Geliştirilen Kütüphaneler
İTÜ Türkçe Doğal Dil İşleme Yazılımı	NLTK
Zemberek	Gensim
TS Corpus	CoreNLP
TRmorph	TextBlob

Zemberek, açık kaynak kodlu bir doğal dil işleme kütüphanesidir. Türkçe ve diğer Türk dilleri için geliştirilmiştir. Türkçe için dil işleme ve metin özetleme üzerine yapılan çalışmalarda yaygın olarak kullanılan bir kütüphanedir. Platform bağımsız olması, geliştirmeye açık bir yapıda olması ve tatmin edici doğruluk seviyesinde çalışması bu kütüphanenin avantajlarındandır. Bu kütüphanenin yazım denetimi, düzeltme, heceleme, köklerine ayırma, özel isimleri bulma, cümle sonunu bulma, metin sınıflandırma, dil tanımlama, morfolojik çözümleme, sözcük üretimi ve ASCII dönüşümü gibi birçok işlevi vardır [3, 22-24].

Zemberek kütüphanesinin dışında Türkçe dili için geliştirilmiş başka doğal dil işleme kütüphaneleri de mevcuttur. TS Corpus, Doğal Dil İşleme araçlarını geliştirmeyi ve dilsel veri kümelerini derlemeyi amaçlayan ücretsiz ve bağımsız bir projedir. İTÜ Türkçe Doğal Dil İşleme Yazılım Zinciri, İTÜ tarafından web tabanlı olarak geliştirilen iki aşamalı morfolojik çözümleyici ve morfolojik bozukluk çözümleme olmak üzere üç modülden oluşan bir kütüphanedir. Bir başka kütüphane olan Nuve, morfolojik çözümleme, morfolojik oluşturma, kök-ek ayrımı, cümle sonunu belirleme ve N-gram ayıklama özelliklerine sahiptir. NLP Toolkit, TRmorph, seq2seq ise literatürde adı geçen diğer kütüphanelerden bazılarıdır. Doğal Dil İşleme çalışmalarında birden fazla kütüphane kullanılabilir. Her bir kütüphane, aynı işlem için farklı oranlarda başarıya sahiptir. Bazen, bir kütüphane kök bulma konusunda iyiysen, başka bir kütüphane cümle sonu bulma konusunda daha iyi olabilir ve birlikte kullanılması gerekebilir.

3.2. Metin Özetleme


Özet, bir metnin içeriğinin ve anlamının korunarak daha kısa bir şekilde ifade edilmesidir. Lin ve Hovy'e [47] göre metin özetlemenin yapılabilmesi için üç farklı aşamanın uygulanması gerekmektedir. Metin özetleme, konunun belirlenmesi, yorumlama ve üretme süreçlerinden oluşmaktadır.

Konunun Belirlenmesi: Bu aşamada metin içindeki en önemli konuların belirlenmesi amaçlanır. Bunun için kelime frekanslarının hesaplanması, cümlelerin konumu, "özetle", "en önemlisi", "sonuç olarak" gibi önemli ipucu veren kelimeler, edat ve bağlaç harici sıkça kullanılan kelimeler vb. teknik olarak kullanılmaktadır.

Yorumlama: Bu aşamada birbiriyle ilişkili olan cümleler daha genel cümleler ile yeniden oluşturulmaktadır.

Üretme: Bu aşama metnin özetinin son halinin üretilmesidir. Çeşitli üretme teknikleri vardır. Birinci süreçten elde edilen kelime ve cümlelerin özete eklenmesi, en çok kullanılan anahtar kelimelerin veya ikinci süreçte yorumlanan cümlelerin özete eklenmesi, iki veya daha fazla cümlelerin birbirine bağlanması üretme yöntemlerinden bazılarıdır.

Metin özetleme çalışmaları, kullanılan algoritma türüne, özetleme yaklaşımına ve kaynak türüne göre farklı başlıklar altında kategorize edilebilir. Şekil 3.1'de Otomatik özetleme çalışmalarının sınıflandırması gösterilmiştir. Metin özetleme sistemleri, girdi olarak verilen belgelerin sayısına bağlı olarak tek belgeli ve çok belgeli olarak sınıflandırılabilir. Sadece bir dokümanı özetleme çalışmaları olduğu gibi birbirleriyle ilişkili olan veya olmayan birden fazla dokümanı özetleme çalışmaları da vardır. Özetlemede kullanılan algoritma denetimli ya da denetimsiz olabilir. Özetlenecek metin genel bir metin (haber, makale, tweet vs.) olabileceği gibi alana özgüde (sağlık raporları vs.) olabilir. Özeti diline göre de özetleme çalışmaları farklılık gösterir. Özet tek dilli, çok dilli veya diller arası olabilir. Özetleme çalışmalarında elde edilen özet türleri farklı olabilir. Metne uygun başlığın özetleme ile oluşturulduğu, yalnızca önemli kısımların vurgulandığı, cümle düzeyinde özetleme yapılan ve bir metnin tamamen özetlendiği farklı özetleme sistemleri vardır.




Şekil 3.1. Metin özetleme türleri sınıflandırması

Çıkarılacak özetlerin ne şekilde oluşturulacağına bağlı olarak farklı özetleme yaklaşımları vardır. Literatürde, temel olarak metin özetlemede iki temel yöntem vardır. Bunlar çıkarımsal ve soyutlayıcı özetleme yöntemleridir. İki yaklaşımın bir arada kullanıldığı hibrit çalışmalar da mevcuttur. Çıkarımsal özetleme yaklaşımında özet, metinde geçen kelime ve cümlelerle oluşturulurken, soyutlayıcı özetleme yaklaşımında özet, metinde geçen kelime ve cümlelerin farklı kelimelerle yeniden ifade edilmesiyle oluşturulur. Hibrit yaklaşım ise çıkarımsal ve soyutlayıcı özetleme yaklaşımlarının bir arada kullanıldığı özetleme türüdür.

Çıkarımsal özetleme

Literatürde bu yöntem seçerek ve ayıklayıcı gibi farklı isimlerde de geçebilmektedir. Metin içerisindeki cümlelerin önemine göre seçilmesiyle yapılan özetleme yöntemidir. Bu yöntemde, metindeki cümleler olduğu gibi alınarak bir araya getirilir. Şekil 3.2’de çıkarımsal özetleme yaklaşımının genel yapısı gösterilmiştir. Şekilden anlaşılacağı üzere bu yaklaşımda özet, metinde geçen kelime ve cümlelerle oluşturulur. Metin içerisindeki önemli cümleler, puanlandırma yöntemleri kullanılarak, istatistiksel metotlar ve sezgisel çıkarımlar ile seçilebilir [24].



Şekil 3.2. Çıkarımsal özetleme yaklaşımı

İstatistiksel puanlandırma, cümlelerin doğal dil açısından önemine göre cümleye puan atamaya dayanmaktadır. Cümlelerin metin içerisindeki konumu, anahtar kelime sayısı, başlık kelimesi içerip içermediği gibi öznitelikleri istatistiksel bazı yöntemler ile tespit edilir. Önceden tanımlanmış olan özelliklere bağlı olarak cümleler puanlandırılır. Puanlanmış cümleler sıralanarak yüksek puanlı cümlelerden istenilen boyuta sahip özet oluşturulur [24, 25].


Sezgisel olarak gizli anlam çıkarımı, birliktelik kuralları ile fark edilemeyen bağlantıları çözümleyip gözlemlenmesini sağlamaktadır. Bu yöntemde öncelikle kelime cümle matrisi kurulur. Bu matris, kelimelerin cümlelere göre frekanslarından oluşmaktadır. Matris metindeki kavramları vermektedir. Bu kavramlara göre cümlelere puan verilir [24].

Çıkarımsal özetleme çalışmalarında özet elde edilirken kullanılan yöntemlerden bazıları:

- Kavram ve konu tabanlı,
- Graf tabanlı,
- Semantik tabanlı,
- Makine öğrenmesi,
- Derin öğrenme,
- Optimizasyon algoritmaları,
- Bulanık mantık.

Soyutlayıcı özetleme

Bu yöntem, literatürde yorumlayıcı ve oluşturucu şeklinde de geçebilmektedir. Metnin içeriği ve konusu incelendikten sonra özetin yeni cümleler, farklı kelimelerle oluşturulmasıdır. Şekil 3.3'te soyutlayıcı özetleme yaklaşımının genel yapısı gösterilmiştir. Şekilden anlaşılacağı üzere bu yaklaşımda özet, metinde geçen kelime ve cümlelerin farklı kelimelerle yeniden ifade edilmesiyle oluşturulur. Bu yöntemde, öncelikle gelişmiş dilbilimsel yöntemler kullanılarak metin incelenir ve konuyla ilgili kavramlar belirlenir. Daha sonra metindeki önemli bilgiler, belirlenen kavram çerçevesinde en iyi şekilde yeniden ifade edilerek özet metin oluşturulur. Bu tip özetleme yapabilmek için çok geniş sembolik kelime bilgisine ihtiyaç duyulmaktadır. Bu yöntem orijinal metni anlamaya yorumlamaya ve daha az kelime kullanarak yeniden ifade etmeye dayanan bir yöntemdir. Bu nedenle orijinal metinde geçmeyen bazı cümle veya kelimeler özet içerisinde bulunabilir [25, 27].



Şekil 3.3. Soyutlayıcı özetleme yaklaşımı

Soyutlayıcı özetleme çalışmalarında özet elde edilirken kullanılan yöntemlerden bazıları:

- Yapı tabanlı,
- Graf tabanlı,
- Ağaç tabanlı,
- Kural tabanlı,
- Ontoloji tabanlı,
- Semantik tabanlı,

- Derin öğrenme.

Çıkarımsal özetlemede cümleler metinden alındığı için farklı kelime bulunmaz ve gelişmiş dilbilimsel yöntemlere ihtiyaç duyulmaz. Bundan dolayı yorumlayarak özetlemeye göre daha az karmaşıktır. Literatür taramasında, metin özetleme çalışmalarında çıkarımsal özetleme yaklaşımının daha fazla kullanıldığı gözlemlenmiştir.

3.2.1. Kelime vektörleri

Bilgisayarın doğal dili anlayabilmesi için metinlerin küçük yapıtaşları olan kelimeleri anlaması gerekir. Kelimeler makinelerin anlayacağı şekilde sembolize edilmelidir. Bunun için kelimeler sayısal olarak temsil edilmelidir. Kelimelerin sayısal temsili ile kelimeler üzerinde her türlü matematiksel işlem yapılabilir. Tüm sözlük üzerinde vektör oluşturulabilir. Kelime vektörleri, literatürde kelime gömmeleri olarak da geçmektedir. Literatürde farklı kelime vektör yöntemleri mevcuttur.

One-hot encoding

Kelimelerin one-hot vektör her bir kelimenin cümlede geçip geçmemesine göre 0 ve 1 değerleri ile ifade edilmesidir. Çizelge 3.2’de verilen cümle örneğinin one-hot encoding ile temsil edilmesinin bir örneği Çizelge 3.3’te gösterilmiştir. Kelimelerin one-hot encoding ile temsil edilmesi bilgisayar hafızalarında çok yer gerektirir. Çünkü her kelime ayrı ayrı matriste tutulur. Ayrıca one-hot vektörlerde metin içindeki kelimeler arasındaki anlamsal ve istatistiksel ilişki saklanmaz. Bu durumdan dolayı kullanımı günümüzde yaygın değildir. Metin içinde kelime çeşitliliğinin olmadığı ve kelimeler arasındaki ilişkilerin modellenmesine gerek duyulmayan durumlarda kullanılır.

Çizelge 3.2. One- hot vektör için cümle örneği

bilateral	serebral	hemisfer	serebellum	boyun	bölge	patolojik	f-18	fdg	tutulum	izle
1	2	3	4	5	6	7	8	9	10	11

Çizelge 3.3. One-hot encoding matris örneği

	1	2	3	4	5	6	7	8	9	10	11
bilateral	1	0	0	0	0	0	0	0	0	0	0
serebral	0	1	0	0	0	0	0	0	0	0	0
hemisfer	0	0	1	0	0	0	0	0	0	0	0
serebellum	0	0	0	1	0	0	0	0	0	0	0
boyun	0	0	0	0	1	0	0	0	0	0	0
bölge	0	0	0	0	0	1	0	0	0	0	0
patolojik	0	0	0	0	0	0	1	0	0	0	0
f-18	0	0	0	0	0	0	0	1	0	0	0
fdg	0	0	0	0	0	0	0	0	1	0	0
tutulum	0	0	0	0	0	0	0	0	0	1	0
izle	0	0	0	0	0	0	0	0	0	0	1

Bag of words (BOW)

Bag of Words (BoW) yönteminin Türkçesi literatürde kelime çantası ve kelime torbası şeklinde geçmektedir. Dil modellemede kullanılan bir NLP yöntemidir. Metin sınıflandırma çalışmalarında sıklıkla kullanılan bir yöntemdir. Bag of Words modeli, makine öğrenimi algoritmalarıyla modellenen metin verilerini temsil etmenin bir yoludur. BoW, bir belgedeki kelimelerin oluşumunu açıklayan metnin yerine geçmektedir. BoW, metindeki bütün kelimeleri kontrol eder ve kelimelerin metinde geçme sıklığını hesaplar. Belirli bir cümlede kelimenin varlığını analiz ederek kelimeleri sayılara dönüştürmektedir. Bir sayı, kelimeye karşı kodlanmış bir değer olarak gösterilir. Bu, kelimenin cümlede temsil edilme sayısıdır. Cümlede kelime varsa 1 yoksa 0 olarak gösterilir [48].

TF-IDF

Dil modelleme de kullanılan yöntemlerden bir diğeri ise TF-IDF (Terim Frekansı- Ters Belge Frekansı) yöntemidir. Çıkarımsal özetlemede de tek başına kullanılmakta olduğu çalışmalar mevcuttur. TF-IDF, belgelerdeki sözcüğün önemlilik derecesini ölçmek için

kullanılan bir tekniktir. Bu teknikle birlikte, belgede bulunan her kelime için bir ağırlık değeri hesaplanır. Bu ağırlığın hesaplanması için önce kelimeler vektör haline getirilir. Bu vektörler üzerinden en önemli kelimeler tespit edilerek alaka sırasına göre en iyi kelimeler gösterilmektedir. Belgelerdeki en önemli kelimeleri tespit edip sıralamak amaçlanır.

TF bir belgedeki kelimenin sıklığını ölçmektedir. TF, belgenin uzunluğuna ve kelimelerin sıklığına bağlıdır. Frekans değerinde normalleştirme yapmak için frekansı belgedeki toplam kelime sayısına bölmektedir. Böylece uzun belgelerle kısa belgeler arasında denge sağlanmış olur. Belgeler vektörleştirilirken her kelimenin sayımı kontrol edilir. Sorgu belgede yoksa TF değeri 0 olur ya da sorguyla belgedeki bütün sözcükler aynıysa TF değeri 1 olur. Normalizasyon işleminden sonra TF değerleri [0-1] arasında olmaktadır [49, 50].

IDF, t teriminin bilişimselliğini ölçen belge frekansının tersidir. DF, belge kümesindeki belgelerin önemini ölçmektedir ve sorgunun bulunduğu belge sayısını toplam belge sayısına bölerek normalize etmektedir. TF-IDF'nin amacı terimlerin önemini bilmektir bu yüzden de DF ters çevrilerek IDF elde edilir. Kelime haznesinde olmayan bir kelime sorgulandığı zaman DF değeri 0 olacaktır. Sayılar 0'a bölünemediği için paydaya 1 eklenmiştir [49, 50].

$$TF(i, j) = \frac{j \text{ belgesindeki } i \text{ sıklığı}}{j \text{ belgesindeki toplam kelime sayısı}} \quad (3.1)$$


$$IDF(i) = \log_2 \frac{\text{Toplam belgeler}}{i \text{ terimine sahip belgeler}} \quad (3.2)$$

$$TF - IDF(i, j) = TF(i, j) \times IDF(i) \quad (3.3)$$

Eş. 3.1' de gösterildiği gibi TF, bir kelimenin doküman içerisinde kaç kere geçtiğini bularak daha sonra bu sayıyı dokümandaki toplam kelime sayısına böler ve bu şekilde her bir kelimenin ağırlığını hesaplar. Bu adımdan sonra IDF hesaplanmaktadır. Eş. 3.2'de gösterildiği gibi IDF, kelimenin geçtiği doküman sayısını toplam doküman sayısına böler ve kelimelerin belgelerde geçme sıklığını hesaplar. Son olarak TF-IDF hesaplanır. Eş. 3.3'te gösterildiği gibi TF-IDF, TF ve IDF skorlar çarpılarak hesaplanmaktadır. Böylece her kelimenin bir TF-IDF puanı olmakta ve buna göre belgelerde bulunan konuyla en ilişkili kelimeler tespit edilebilmektedir [49, 50].

Word2Vec

Word2Vec kelime vektörü oluşturmada kullanılan modern yöntemlerden biridir. Word2Vec ile kelimeler arasındaki anlamsal ilişki saklanır. Benzer kelimelerin vektörleri birbirine yakın olur. Word2Vec ile her kelime belirli uzunlukta bir vektörle temsil edilir. Word2Vec kelimeler arasındaki uzaklığı vektörel olarak hesaplayan denetimsiz ve tahmin temelli bir NLP yöntemidir. Bu vektörel yapının üzerine yazılmış araçlar ile bir kelimeye en yakın kelimeler listelenmektedir. Kelimeler arası anoloji kurulabilmektedir. Continuous Bag of Words (CBOW) ve Skip-Gram olmak üzere iki çeşit alt yöntem vardır. Şekil 3.4'te CBOW ve Skip-Gram modellerinin yapısı gösterilmiştir. CBOW ve Skip-Gram modelleri birbirlerinden çıktıyı ve girdiyi alma açısından farklılaşmaktadır. Bir cümleye uygulanan bu işlemler tüm cümlelere uygulanmaktadır [51, 52].



Şekil 3.4. CBOW ve Skip-gram modellerinin genel yapısı [52]

Continuous bag of words (CBOW)

CBOW modelinde kenardaki kelimeler girdi olarak alınıp, merkezinde olan kelime çıktı olarak tahmin edilmeye çalışılır.

- Eğitim Skip-gram modeline göre daha hızlıdır.
- Sık kullanılan kelimeler daha iyi temsil edilir.
- Daha az işlem gücü gerekir.

- Birden fazla anlamlı kelimeleri anlamada zorluk çeker.

Skip-gram

Skip-Gram modelinde ise merkezdeki kelime girdi olarak alınıp merkezde olmayan kelimeler çıktı olarak tahmin edilmeye çalışılır. Bu işlem cümle bitene kadar devam etmektedir.

- CBOW modeline göre daha yavaştır.
- Küçük veri tabanlarıyla daha iyi çalışır.
- Nadir kelimeler iyi temsil edilir.
- Daha fazla işlem gücü gerekir.

Global vectors for word representation (GloVe)

Global Vectors For Word Representation (GloVe), denetimsiz bir dil modelleme yöntemidir. Word2Vec modelinin geliştirilmiş bir versiyonudur. Word2Vec'te veri kümesindeki tüm kelime incelenerek etrafındaki kelimeler tahmin edilir. Her iki kelimenin birbiriyle ne sıklıkta kullanıldığı da vektörde temsil edilmektedir. Word2Vec kelimelerin eş dizimini dikkate almaz. Pennington ve diğerleri tarafından geliştirilen GloVe kullanım istatistiklerini de dikkate alır. Yani, Word2Vec modeline ek olarak yan yana geçen kelimeleri de sayar. İki kelimenin yan yana kaç kere kullanıldığını dikkate alır. GloVe algoritmasının maliyet fonksiyonu Eş. 3.4'teki gibi hesaplanır [53].

$$J = \sum_{i,j=1}^V f(X_{ij}) (w_i^T \tilde{w}_j + b_i + \tilde{b}_j - \log X_{ij})^2 \quad (3.4)$$

Bu eşitlikteki X_{ij} kelime çiftlerinin birlikte oluşma sıklığını, w kelime vektörünü ve b sapma değerini göstermektedir. GloVe, hem büyük hem küçük veri tabanları için etkili bir şekilde kullanılmaktadır.

3.2.2. Çıkarımsal özetleme

Çıkarımsal özetleme yaklaşımı için literatürde kullanılan yöntemlere değinilmiştir. Bu başlık altında sadece Tez çalışmasında kullanılan yöntemlerden bahsedilmiştir.

Gizli anlamsal analiz (Latent semantic analysis – LSA)


Gizli Anlamsal Analiz (LSA), bir dizi belge ve bu belgeler içerisindeki terimler arasındaki ilişkileri, bunlarla ilişkili bir dizi kavram üreterek analiz eden bir tekniktir. LSA'ya göre, anlamca birbirine yakın kelimeler benzer metin parçalarında yer almaktadır. LSA modelinde girdi olarak bir doküman koleksiyonu kullanılmaktadır. Bu doküman eş oluşum matrisi ile bir kelime-doküman matrisi oluşturulmaktadır. Oluşturulan bu matristeki gereksiz yüksek frekanslı kelimelerin ağırlığını azaltmak için TF- IDF dönüşümü kullanılmaktadır. Bu işlem gerçekleştirildikten sonra her dokümanın ağırlığı, birim uzunluğuna normalize edilmektedir. Son adımda ise tekil değer ayrıştırması (singular value decomposition-SVD) kullanılarak en büyük tekil değerler seçilmekte ve boyut azaltılmaktadır. Belgeler, iki sütun tarafından oluşturulan iki vektör arasındaki açının kosinüsü veya iki vektörün normalizasyonu arasındaki iç çarpımı alınarak karşılaştırılmaktadır. Bunun sonucunda 1'e yakın değerler çok benzer belgeleri temsil ederken 0'a yakın belgeler birbirine benzemeyen belgeleri göstermektedir [54].

TextRank

TextRank, çıkarımsal ve denetimsiz otomatik metin özetleme yöntemlerinden biridir. TextRank algoritması [55], PageRank [56] algoritmasından esinlenerek geliştirilmiştir. Google'ın web sayfalarını sıralamada kullandığı PageRank algoritmasının gelişmiş bir versiyonudur. PageRank arama sorgusu sonuçlarının sıralamasını iyileştirmeye yönelik bağlantı tabanlı bir algoritmadır. PageRank algoritması, herhangi bir özel arama sorgusundan bağımsız olarak Web sayfalarının göreceli önemini yakalamak için web sayfasının bağlantı yapısını kullanarak tek bir vektörü hesaplar. Etkiyi ölçer ve yalnızca ağırlık bağlantı yapısını dikkate alır. TextRank en yaygın kullanılan graf tabanlı yöntemlerden biridir. TextRank algoritmasında PageRank algoritmasındaki web sayfaları yerine cümleler kullanılmaktadır. Herhangi iki cümle arasındaki benzerlik hesaplanır ve bir kare matriste

saklanır. Graf tabanlı bu algorithmada cümleler düğümlerle, cümleler arası benzerlikler ise kenarlarla temsil edilir.

TextRank ile gerçekleştirilen adımlar Şekil 3.5'te gösterilmiştir. Dokümanlar tek metin haline getirilir. Metin cümlelerine ayrıştırılır. Daha sonra, cümlelerin kelime vektörleri çıkarılır. Kelime vektörlerinin benzerlik matrisi oluşturulur. Cümleler düğümleri, benzerlikler kenarları temsil edecek şekilde graf oluşturulur ve cümleler önem derecesine göre sıralanarak dokümanların özeti elde edilir.



Şekil 3.5. TextRank ile özetleme işlem adımları

3.3. Derin Öğrenme

Derin öğrenme kavramı yapay sinir ağlarının geliştirilmesiyle ortaya çıkmıştır. Makine öğrenmesinde başarı, verinin kalitesine ve özelliklerin doğru seçilmesine bağlıdır. Bunun için önışlem, boyut indirgeme ve özellik seçme gibi işlemler yapılmaktadır. Derin öğrenme bu önışlem adımlarını bünyesinde barındırır, verilerin boyutunu indirgeme ve özellik seçme işlemleri derin öğrenme algoritmaları tarafından gerçekleştirilir. CNN, RNN ve LSTM gibi farklı derin öğrenme algoritmaları mevcuttur. Derin öğrenme mimarileri farklı katmanlardan oluşmaktadır. Giriş (input) katmanı, evrişim (convolution) katmanı, havuzlama (pooling) katmanı, düzleştirme (flattening) katmanı, tam bağlı (full-connected) katman ve


normalleştirme (normalization) katmanı bunlardan bazılarıdır. Kısaca değinmek gerekirse, evrişim katmanında veri parçalar halinde analiz edilir ve yüksek ve düşük seviyeli özellikler algılanır. Havuzlama katmanında en kritik özellikler alınarak boyut indirgenir. Normalleştirme katmanında katmanlardan gelen farklı aralıktaki işlenmiş verilerin aynı dağıma sahip olmasını sağlanır. Düzleştirme katmanında veriler sinir ağına hazırlanır. Tam bağlı katmanında ise sinir ağı aracılığıyla öğrenme işlemi gerçekleşir.

Günümüzde, metin özetleme gibi doğal dil işleme problemlerine derin öğrenmeyle çözümler sunulmaktadır. Derin öğrenmede yaşanan hızlı gelişimle birlikte bir girdi dizisini başka bir çıktı dizisine yansıtmak için birçok sıralı sıralama (sequence to sequence – seq2seq) modelleri önerilmiştir. Sıralı bilgi içeren herhangi bir problem üzerine bir Seq2Seq modeli uygulanabilir. Varlık tanıma, makine çevirisi gibi işlemlerde sıklıkla kullanılan bir modeldir. Seq2seq, girdisi uzun bir kelime dizisi olan çıktısı ise kısa bir özet dizisi olan bir metin özetleyici oluşturmayı amaçlar. Seq2seq modelin kodlayıcı ve kod çözücü olmak üzere iki temel bileşeni vardır. Kodlayıcı(encoder) ve kod çözücü mimarisi seq2seq problemlerin çözümünde kullanılmaktadır. Genellikle, kodlayıcı ve kod çözücü bileşenleri olarak Evrişimsel Sinir Ağları (CNN), Tekrarlayan Sinir Ağlarının (RNN ve varyantları olan Geçitli Tekrarlayan Sinir Ağı (GRU) veya Uzun Kısa Süreli Bellek (LSTM), tercih edilmektedir. Gradyanların kaybolması sorununun üstesinden gelerek uzun vadeli bağımlılıkları yakalayabildikleri için bu algoritmalar (LSTM ve GRU) tercih edilir [35, 57].

LSTM, gradyan kaybı probleminin üstesinden gelerek uzun vadeli bağımlılıkları yakalayabildiği için tercih edilmiştir. Çalışmada kodlayıcı ve kod çözücü olarak LSTM derin öğrenme yöntemi kullanılmıştır. Bir Kodlayıcı Uzun Kısa Süreli Bellek modeli (LSTM), her zaman adımında kodlayıcıya bir sözcüğün beslendiği girdi dizisinin tamamını okur. Daha sonra bilgileri her zaman adımında işler ve girdi dizisindeki bağlamsal bilgileri yakalar. Kod çözücü aynı zamanda tüm hedef diziyi kelime kelime okuyan ve aynı sekans ofsetini tek seferlik bir adımla tahmin eden bir LSTM ağıdır. Kod çözücü, bir önceki kelime verilen dizideki bir sonraki kelimeyi tahmin etmek üzere eğitilir. Eğitimden sonra model, hedef dizinin bilinmediği yeni kaynak diziler üzerinde test edilir [35, 57].

LSTM, sıralı bilgileri kullanan ve gizli katman çıktısını girdiyle aynı katmana geri gönderebilen bir derin öğrenme algoritmasıdır. Yani, birimler arasındaki bağlantılar yönlendirilmiş bir döngü oluşturur. Bu döngü, dinamik zamansal davranış sergilemesine izin

verir. LSTM derin öğrenme yönteminin genel yapısı Şekil 3.6'da gösterilmiştir. LSTM'lerde gizli durumu hesaplamak için farklı bir fonksiyon kullanılır. LSTM'de bellek yapıları vardır. Bunlara hücre de denir. Hücreler önceki durumu ve giriş bilgilerini tutar. Bu hücreler, verilerin saklanmasına veya silinmesine karar verir. Önceki durum, mevcut bellek ve giriş bilgisi birleştirilir. Böylece uzun vadeli bağımlılıklar ortadan kaldırılmış olur [37, 58].



Şekil 3.6. LSTM yönteminin genel yapısı

Şekil 3.6'da unutmaya kapısı mavi, giriş kapısı yeşil ve çıkış kapısı sarı ile gösterilmiştir. Unutmaya kapısı, önceki hücreden hangi bilgilerin atılması gerektiğine karar verir. Sigmoid tarafından 0 ve 1 arasında çıkış için değer verilir. Bu değer 1 ise verinin tamamını tutulur, 0 ise tamamını unutulur. Kısacası, hücrenin durumunu sıfırlamak içindir. Giriş kapısı, giriş verilerini aktarmak için kullanılır. Hangi bilgilerin saklanacağını belirler. Sigmoid, güncellenecek değerlere karar verirken tahn yeni aday değerler vektörü oluşturmaktadır. Çıkış kapısı, çıkış verilerini aktarmak için kullanılır. Hücrenin durumuna göre çıkışa ne göndereceğine karar verir [58].

3.4. Başarı Ölçütleri

Metin özetlemede elde edilen özetlerin başarısının değerlendirilmesi gerekmektedir. Bazı durumlarda elde edilen özet yetersizdir, daha iyi ifade edilmesi gerekir. Özetlemede kullanılan yöntemler kaynak ve vakit israfına neden olabilir. Ortak kullanılan tek bir başarı ölçümü, belirli bir çözüm yoktur. Metin özetleme sistemlerinin başarısını değerlendirmek için pek çok araç geliştirilmiştir.

Başarı değerlendirmede kullanılan araçlardan bazıları:

- Özet Değerlendirme Ortamı (Summary Evaluation Environment -SEE):
- MEAD Eval
- ROUGE
- Kosinüs Benzerliği

Özet değerlendirme ortamı (summary evaluation environment - SEE)

Kullanıcının girdiği iki farklı metin yan yana kıyaslanarak başarı ölçümü yapılmaktadır. Girilen metin özetlerinden birisi, referans özet iken diğeri emsal özetir. Uygulama, metinleri ön-işleme tabii tutarak kıyaslama öncesi cümle seviyesinde bölütleme yapmakta ve kullanıcının seçeceği kriterlere göre ölçüm yapmaktadır [59].

MEAD Eval

MEAD ölçüm sistemini kullanan ve Belge Anlama Konferansları (Document Understanding Conferences- DUC) tarzı ayıklama özetleri oluşturan bu uygulama, özet oluşturma ve ölçümleme yapabilmektedir. MEAD, cümleleri puanlarken, cümle uzunluğu, ağırlık merkezi ve cümle pozisyonu olmak üzere üç farklı kıstası değerlendirir. Referans ve emsal özetler arasındaki cümle örtüşmeleri üzerinden değerlendirme sonucu oluşturur [60].

Çalışmada başarı ölçütü olarak ROUGE, benzerlik ölçütü olarak kosinüs benzerliği kullanıldığı için bu metrikler ayrı başlık altında incelenmiştir.

3.4.1. Kosinüs benzerliği

Kosinüs benzerliği, benzerlik ölçütü olarak kullanılmıştır. Bu metrik çıkarımsal özetlemede bir işlem adımı olarak uygulanmaktadır. Kosinüs benzerliği, cümle, paragraf veya metnin tamamı gibi herhangi iki metne uygulanabilir. Kosinüs benzerliğinde dokümanlar arasında veya cümleler arasında benzerlik değeri ölçülerek en yüksekte en düşüğe doğru sıralanır. Yüksek kosinüs benzerliği, belgelerin alaka düzeyinin yüksek olduğu anlamına gelmektedir. Kosinüs benzerliği, iki metni kelime benzerliği açısından iyi bir şekilde ele alsa da anlamsal

olarak ele alması konusunda bazen problemler yaşanabilmektedir. Sözdizimi açısından eşleşen belgeler, her zaman anlam olarak birbirine yakın olmayabilmektedir. Vektör benzerliğine dayalı olarak, iki vektör arasındaki benzerlik Eş. 3.5'teki gibi tanımlanır. Formüldeki w_q ve w_d bir metin içindeki terim sıklığını ifade etmektedir ve her vektörün boyutu ise belgede bulunan bir terime karşılık gelir [61].

$$Sim(\vec{q}, \vec{d}) = \frac{\vec{q} \cdot \vec{d}}{|\vec{q}| |\vec{d}|} = \frac{\sum_{k=1}^t w_{qk} x w_{dk}}{\sqrt{\sum_{k=1}^t (w_{qk})^2} \cdot \sqrt{\sum_{k=1}^t (w_{dk})^2}} \quad (3.5)$$

3.4.2. Recall-oriented understudy for gisting evaluation (ROUGE)

IBM'in İki Dilli Değerlendirme Desteği (Bilingual Evaluation Understudy- BLEU) ölçüm metriğinin güncellenmiş versiyonudur. DUC-2002'deki çalışmaların ölçümlemesi yapılırken kullanılan bu yöntem, şaşırtıcı derecede yüksek başarı yakalamış ve insan değerlendirmesine yakın sonuçlar üretmiştir. DUC çalışmalarında olduğu gibi günümüzdeki birçok metin özetleme çalışmasında, insan değerlendirmesine en yakın sonuçlar ürettiği için ROUGE kullanılmaktadır [2, 12, 25, 27, 25, 43]. ROUGE, BLEU'nun aksine "uzunluk" hatası vermez. ROUGE, geliştirilen özetleme modeli tarafından oluşturulan özet (emsal özet) insan tarafından oluşturulan özet (referans özet) ile karşılaştırır. ROUGE, kelime zincirinin uzunluğunu belirterek, N-gram kullanarak iki özet arasındaki örtüşmeleri hesaplar. Sonuca göre 0 ile 1 arasında bir yüzdelik dilim döndürür. ROUGE ile duyarlılık (recall), kesinlik (precision) ve F1-Skor ölçümleri yapılabilir. Bu ölçümler, Eş. 3.6, 3.7 ve 3.8'deki formülle hesaplanır.

$$Rouge_{duyarlılık} = \frac{\text{Çakışan Kelime Sayısı}}{\text{Referans Özetteki Toplam Kelime Sayısı}} \quad (3.6)$$


$$Rouge_{kesinlik} = \frac{\text{Çakışan Kelime Sayısı}}{\text{Sistem Özetindeki Toplam Kelime Sayısı}} \quad (3.7)$$

$$Rouge_{f1-skor} = 2x \frac{\text{Duyarlılık} x \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3.8)$$



4. DENEYSEL ÇALIŞMA

Tez çalışmasının genel yapısı Şekil 4.1’de gösterilmiştir. Çalışmada kullanılan veri Tıbbi Görüntüleme Merkezinden alınmıştır. Veri kümesi oluşturulduktan sonra, raporlar üzerinde yazım hatalarını düzeltme, kelime köklerini bulma ve gereksiz kelimeleri çıkarma gibi bazı ön işlemler uygulanmıştır. Tıbbi görüntüleme raporları ön işlemden geçirildikten ve cümlelerine ayrıştırıldıktan sonra kelime vektörleri oluşturulmuştur. Sonrasında ise literatürdeki farklı özetleme yöntemleri ile model çıkarımı yapılmıştır. Model çıkarımında kullanılan özetleme algoritmalarının performansı değerlendirilmiştir. Model başarısı ROUGE metriği ile değerlendirilmiştir. Çalışma ile elde edilen başarılı özetler daha sonra doktorların hastalıkları etkin ve hızlı bir şekilde teşhis etmesinde yardımcı rol oynaması hedeflenmektedir.



Şekil 4.1. Tez çalışmasının genel yapısı

4.1. Veri Kümesi

Gazi Üniversitesinden etik kurul izni alındıktan sonra Tıbbi Görüntüleme Merkezlerinden 2019 yılı itibariyle 2022 yılı mayıs ayına kadar olan 2457 adet rapor veri olarak alınmıştır. Bir hastaya ait raporun örneği Resim 4.1 gösterilmiştir. Veri kümesi isimler baş harflerine göre sıraları olacak bir şekilde oluşturulmuştur. Kişisel verilerin güvenliği açısından hastanın isim bilgisi anonimleştirilmiş ve her bir hasta için ID numarası verilmiştir. Aynı kişiye ait raporlara aynı ID verilmiştir. 2457 rapordan 258 adeti aynı hastaya ait birden fazla

raporu içermektedir. Geri kalan raporlar tek hastaya aittir. Aynı ID numarasına sahip raporlarda ise kendi içinde en yeni tarihli olan ilk sırada olacak şekilde sıralama yapılmıştır. Raporlarda bulunan farklı bölümler farklı özellik olacak şekilde veri kümesi oluşturulmuştur. Resim 4.1 ve Resim 4.2’de görüldüğü gibi raporlarda adı soyadı, yaş, tetkik tarihi, klinik bilgi, kan şekeri, ICD kod, yöntem, bulgular, sonuç bilgileri vardır. Bazı raporlarda raporda not bölümü varken (bkz. Resim 4.2) bazı raporlarda yoktur (bkz. Resim 4.1). Raporun her bölümü veri kümesinde ayrı bir sütun olarak tutulmuştur. Çalışmada önemli olan kısımlar bulgular, sonuç ve not bölümleridir. Bulgular kısmı özetlemede kullanılmış, not ve sonuç kısımları ise genelde başarı değerlendirmede kullanılmıştır. Oluşturulan veri kümesi csv formatındadır.



Adı Soyadı : XXXXXXXXXX
Yaş : 62

Tetkik Tarihi : 17.03.2022

¹⁸F-FDG TUM VUCUT GORUNTULEME

Klinik Bilgi : Bel ağrısı sebebi ile tetkik edilen hastada T12 vertebrada kopresyon fraktürü tespit edilmiştir (metastaz?). Malignite araştırılması amacıyla F-18 FDG PET/BT tetkiki yapılmıştır.

Kan Şekeri : 110

ICD KODU : C 80

YÖNTEM : Hastaya 6 saatlik açlığı takiben IV yoldan (0.144mCi/kg) ¹⁸F-FDG (fluorodeoksiglukoz) enjeksiyonu sonrası hastanın konuşma ve çiğneme yapmadan uygun sakin ortamda 1 saat istirahati sonrası tüm vücut protokolü kullanarak (3D) kafa tavanından uyluğa kadar PET görüntüleri elde edildi. Elde edilen görüntüler kontrast kullanmadan BT ile atenuasyon düzeltilmesi yapıldıktan sonra transaksial, sagittal ve coronal düzlemde değerlendirilmiştir.

BULGULAR :

Bilateral serebral hemisferlerde, serebellumda ve supkortikal yapılarda F-18 FDG 'nin tutulumu normal fizyolojik sınırlardadır.

Nazofarenkste, palatin tonsillerde ve larenkste patolojik boyutta F-18 FDG tutulumu izlenmemiştir.

Sağ tiroid lobunda ~ 13x16 mm boyutlarında hiperdens nodül izlenmekte olup artmış F-18 FDG tutulumu vardır (SUV maks 5.5).

Baş-boyun bölgesinde diğer kesimlerde patolojik F-18 FDG tutulumu saptanamamıştır.

Bilateral aksiller bölgelerde patolojik boyutta F-18 FDG tutulumu mevcut değildir.

Mediastende ve bilateral hiler bölgede patolojik F-18 FDG tutulumu saptanamamıştır.

Her akciğer parankiminde nodüler lezyon, kitle lezyonu veya patolojik F-18 FDG tutulumu izlenmemiştir.

Plevral yüzeylerde effüzyon, kalınlaşma veya patolojik F-18 FDG tutulumu izlenmemiştir.

Sağ 3.kot lateralinde (SUV maks 2.6), sağ 4.kot lateralinde (SUV maks 1.8), sağ 5.kot lateralinde (SUV maks 2.1), sol 3.kot anteriorda (SUV maks 2.9), sol 5.kot lateralinde (SUV maks 2.9) ve sol 4.kot anteriorda (SUV maks 4.0) izlenmekte olan fraktür hatlarında fokal artmış F-18 FDG tutulumları gözlenmektedir.

Toraksta diğer kesimlerde patolojik F-18 FDG tutulumu mevcut değildir.

Karaciğerde, midede, dalakta, pankreasta ve bilateral sürrenal lojda patolojik boyutta F-18 FDG tutulumu izlenmemiştir.

Mesane belirgin distandü görünümde olup bilateral üreter trasesi vizüalize olmuştur.

Abdominopelvik bölgede diğer kesimlerde ve bilateral inguinal bölgelerde patolojik boyutta lenf nodu, kitle lezyonu veya artmış F-18 FDG tutulumu mevcut değildir.

Kemik yapılar bariz osteoporotik görünümündedir.

T12 vertebrada yükseklik kaybı gözlenmekte olup patolojik boyutta F-18 FDG tutulumu mevcut değildir (osteoporoza bağlı çökme kırığı?).

Görüntüleme alanına giren diğer vücut kesitlerinde F-18 FDG' nin tutulumu normal fizyolojik sınırlarda izlenmektedir.

SONUÇ:

1- Tiroid bezi sağ lobunda tanımlanan hiperdens nodülde patolojik artmış metabolik aktivite izlenmektedir. T11AB önerilir.

2- Her iki hemitoraksta kostalarda fraktür hatları ve fokal artmış F-18 FDG tutulumu izlenmektedir (fraktüre bağlı inflamasyon).

3- Vücudun diğer kesimlerinde malignite lehine değerlendirilebilecek hipermetabolik bir başka odak saptanamamıştır.

Resim 4.1. Bir hastaya ait tıbbi görüntüleme raporu örneği

Yaş : 56

Tetkik Tarihi : 26.08.2021

¹⁸F-FDG TUM VUCUT GORUNTULEME

Klinik Bilgi : Sağ akciğerde kitle, malignite araştırılması, tanı ve metabolik karakterizasyon amacıyla F-18 FDG PET/BT tetkiki yapılmıştır

Kan Şekeri : 95

ICD KODU : C 34

YÖNTEM : Hastaya 6 saatlik açlığı takiben IV yoldan 10,7 mCi ¹⁸F-FDG (fluorodeoksiglukoz) enjeksiyonu sonrası hastanın konuşma ve çiğneme yapmadan uygun sakin ortamda 1 saat istirahati sonrası tüm vücut protokolü kullanılarak (3D) kafa tavanından uyluğa kadar PET görüntüleri elde edildi. Elde edilen görüntüler kontrast kullanmadan BT ile atenuasyon düzeltilmesi yapıldıktan sonra transaksial, sagittal ve coronal düzlemde değerlendirilmiştir.

BULGULAR : Bilateral serebral hemisferlerde, serebellumda ve supkortikal yapılarda F-18 FDG tutulumu normal fizyolojik sınırlardadır.

Nazofarenkste, palatin tonsillerde ve larenkste patolojik F-18 FDG tutulumu izlenmemiştir.

Baş-boyun bölgesinde diğer kesimlerde patolojik F-18 FDG tutulumu izlenmemiştir.

Bilateral aksiller bölgelerde patolojik F-18 FDG tutulumu saptanmamıştır.

Sağ hiler bölgeyi kaplayarak sağ akciğer üst lob posterior segmente paramediastinal alana doğru uzanım gösteren, mediastende sağ alt paratrakeal alanı işgal eden düzensiz sınırlı ~ 34x52x49 mm boyutlarında lobüle kontürlü kitle izlenmekte olup artmış F-18 FDG tutulumu mevcuttur (SUV maks 12.5).

Tanımlanan lezyonun üst kesiminde paramediastinal plevra ve devamındaki apikal plevrada ~ 1.5 cm'ye ulaşan kalınlaşma alanları gözlenmekte olup artmış F-18 FDG tutulumları mevcuttur (SUV maks 3.5).

Sağ hemitoraksta derinliği ~ 8 cm'ye ulaşan plevral effüzyon alanı içerisinde patolojik F-18 FDG tutulumu izlenmemiştir.

En büyükleri karinal bölgede ~ 8 mm çaplı lenf nodu olmak üzere mediastende birkaç adet supsantimetrik boyutlarda lenf nodları izlenmekte olup patolojik F-18 FDG tutulumu izlenmemiştir.

Sol hiler bölgede patolojik F-18 FDG tutulumu izlenmemiştir.

Sol akciğerde üst lob apikoposteriorda ~ 7 mm çaplı (SUV maks 0.7), alt lob superior segmentte fissür komşuluğunda ~ 4.5 mm çaplı (SUV maks 0.9) ve yine alt lob superior segmentte ~ 6x7 mm boyutlarında supplevral yerleşimli (SUV maks 1.0) nodüller izlenmekte olup patolojik F-18 FDG tutulumu izlenmemiştir. Nodüller sırasıyla BT'de 122, 142 ve 163 nolu kesitlerde izlenmektedirler.

Toraksta diğer kesimlerde patolojik F-18 FDG tutulumu saptanmamıştır.

Karaciğerde, dalakta, pankreasta, mide lojunda ve surrenal lojlarda patolojik F-18 FDG tutulumu saptanmamıştır.

Abdominopelvik bölgede diğer kesimlerde, bilateral inguinal bölgelerde patolojik F-18 FDG tutulumu izlenmemiştir.

Kas-iskelet sisteminde ve görüntüleme alanına giren diğer vücut kesitlerinde patolojik F-18 FDG tutulumu izlenmemiştir.

SONUÇ :

Sağ akciğerde hiler bölgeden başlayarak üst lob superior segmentte uzanım gösteren paramediastinal yerleşimli kitlede ve kitle ile devamlılık gösterecek şekilde apikale uzanım gösteren plevral kalınlaşma alanlarında patolojik metabolik aktiviteler izlenmiştir. Bu bulgulara sağ hemitoraksta masif plevral effüzyon alanları ve sol akciğerde F-18 FDG tutulumu izlenmeyen milimetrik nodüller eşlik etmektedir.

NOT: Güncel bulgular 29/07/2019 tarihli F-18 FDG PET BT tetkiki raporu ile kıyaslandığında (CD' ye ulaşılamamıştır):

- 1- Önceki tetkikte mediastende tanımlanan hipermetabolik lenf nodları (pretrakeal ve sağ alt paratrakeal) güncel çalışmada izlenmemiştir.
- 2- Sağ akciğer üst lob posterior segmentte izlenen kitlenin boyutları takipte minimal azalmış olmakla birlikte güncel çalışmada kitlenin sağ hiler bölgeyi kaplayacak şekilde genişlediği anlaşılmaktadır. Bu kitlenin üst kesiminde güncel çalışmada gözlenen plevral kalınlaşma alanları takip aralığında ortaya çıkmıştır.
- 3- Sağ hemitoraksta izlenen masif plevral effüzyon alanı takip aralığında gelişmiştir.
- 4- Önceki çalışmada sağ akciğerde tanımlanan nodüller güncel çalışmada ayırt edilememiştir. Bunun nedeni takip aralığında gelişen masif plevral effüzyon olabilir.
- 5- Sol akciğer üst lob apikoposteriorda izlenen 7 mm çaplı nodülün boyutları stabildir ancak metabolik aktivitesi azalmıştır (SUV maks 1.9 dan 0.7' e).
- 6- Sol akciğer alt lob superior segmentte önceki çalışmada 3 adet nodül tanımlanmıştır. Güncel çalışmada 2 nodül mevcuttur.
- 7- Sol akciğer alt lob lateral bazal ve posterior bazal segmentlerde önceki çalışmada gözlenmekte olan ve inflamasyon lehine değerlendirilen bulgular güncel çalışmada izlenmemiştir.
- 8- Diğer bulgularda anlamlı farklılık saptanmamıştır.

Resim 4.2. Bir hastaya ait not bölümü olan tıbbi görüntüleme raporu örneği


Veri kümesinde, ID, yaş, tarih, başlık, klinik bilgi, kan şekeri, ICD kod, yöntem, bulgular 1, bulgular 2, sonuç ve not olmak üzere 13 özellik vardır. Oluşturulan veri kümesinden bazı örnekler Şekil 4.2’de gösterilmiştir.

	id	yaş	tarih	başlık	klinik bilgi	kan şekeri	ICD kod	yöntem	bulgular	sonuç	not
0	1	57	22.04.2022	18F-FDG TUM VÜCUT GÖRÜNTÜLEME	Sırt bölgesinden opere malign mezenkimal tümör...	131.0	R 22	Hastaya 6 saatlik açlığı takiben IV yoldan (0....	Bilateral serebral hemisferlerde, serebellumda...	Malign mezenkimal tümör nedeni ile sağ hemitor...	NaN
1	2	61	04.08.2021	18F-FDG TUM VÜCUT GÖRÜNTÜLEME	01.07.2021 tarihli toraks BT incelemesinde sağ...	123.0	C 34	Hastaya 6 saatlik açlığı takiben IV yoldan (0....	Bilateral serebral hemisferlerde, serebellumda...	Sol hiler bölgede artmış F-18 FDG tutulumu izl...	NaN
2	3	85	16.08.2021	18F-FDG TUM VÜCUT GÖRÜNTÜLEME	05.08.2021 tarihli toraks BT tetkikinde sağ ak...	127.0	C 34	Hastaya 6 saatlik açlığı takiben IV yoldan (0....	Bilateral serebral hemisferlerde, serebellumda...	Sağ akciğerde alt lobda tanımlanan kitilde pat...	NaN
3	4	45	30.11.2020	18F-FDG TUM VÜCUT GÖRÜNTÜLEME	09.10.2020 tarihli tanısal toraks BT’de sol ak...	92.0	C 34	Hastaya 6 saatlik açlığı takiben IV yoldan 18F...	Bilateral serebral hemisferlerde, serebellumda...	Sol akciğerde alt lobda tanımlanan ve hiler bö...	NaN
4	5	54	17.01.2022	18F-FDG TUM VÜCUT GÖRÜNTÜLEME	10.01.2022 tarihli toraks BT incelemede medias...	97.0	C 34	Hastaya 6 saatlik açlığı takiben IV yoldan (0....	Bilateral serebral hemisferlerde, serebellumda...	Bilateral hiler bölgede gözlenen lenf nodla...	NaN

Şekil 4.2. Veri kümesindeki öznitelikler birlikte ilk beş satır

4.2. Veri Önileme

Tıbbi görüntüleme raporları genel olarak yapılandırılmamış, serbest metin türündedir. Bu tür veriler üzerinde çalışmayı kolaylaştırmak ve başarıyı artırmak için cümleleri kelimelerine ayırma, kelimelerin kökünü bulma ve anlama etki etmeyen kelimeleri cümleden çıkarma gibi bazı işlemlerden geçirilmelidir. Bu işlemlerde NLP kapsamına girmektedir. Şekil 4.3’te gösterilen, çalışmada kullanılacak NLP teknikleri NLP kütüphaneleriyle kolaylıkla yapılabilir. Proje çalışmasında bu kütüphaneler, küçük/büyük harf düzenlemesi gibi basit işlemlerde kullanılabilir. “Saptanmıştır”, “incelenmiştir”, “izlenmiştir” vb. tıbbi görüntüleme raporunda sıkça geçen ifadeler üzerinde işlem yapılması, anlama etki etmeyen kelimelerin atılması gibi işlemlerde Zemberek ve NLTK kütüphanesi kullanılabilir. Ancak, radyoloji raporlarında tıbbi terimler yer almaktadır ve bu terimler genellikle Latince ve İngilizcedir. Ayrıca bu terimler günlük yaşamda kullanılmaz. Bundan dolayı bu kütüphaneler yetersiz kalmaktadır. Radyoloji raporlarında kullanılan tıbbi terimler bazı önileme adımları için kütüphanelerin sözlük listesine eklenmiştir.



Şekil 4.3. Doğal dil işleme adımları

Raporları özetleme işlemine geçmeden önce temel ön işleme adımlarının gerçekleştirilmesi çok önemlidir. Dağınık ve temizlenmemiş metin verilerini kullanmak, işlemleri zorlaştırır ve performansı düşürür. İlk olarak metin üzerinde ayırma ve normalleştirme işlemleri yapılmalıdır.

Metin özetleme zorlu bir doğal dil işleme problemidir. Türkçe sondan eklemeli bir dil olması nedeniyle bu metinleri işlemek ekstra zordur. Çok fazla ek olduğu için bunların analiz edilmesi zaman almaktadır. Kelimelerin morfolojik ve sözdizimsel olarak analiz edilmesinde başarılı ve yaygın olarak kullanılan NLTK kütüphanesi, Türkçe için geliştirilmiş olan Zemberek, İTÜ Türkçe Doğal Dil İşleme Yazılım Zinciri ve TS Corpus gibi araçlardan yararlanılmıştır. NLP çalışma seviyelerinden ilk olarak kelime ve cümle düzeyinde morfolojik ve sözdizimsel analizde bu kütüphanelerden NLTK ve Zemberek daha başarılı sonuç vermiştir. Bundan dolayı çalışmada Zemberek ve NLTK kütüphaneleri kullanılmıştır. Örneğin, İTÜ Türkçe Doğal Dil İşleme Yazılım Zinciri kullanılarak ayırma işleminde boşluklara ek olarak noktalama işaretlerini de dikkate almıştır. Yazım hatası

düzeltilmede otomatik olarak “FDG”, “Feda” olarak düzeltilmektedir. TS Corpus’ta da aynı şekilde sadece bir kelime uyuşsa bile hatalı bir şekilde otomatik düzeltme olmuştur.

4.2.1. Ayırma ve normalleştirme adımları

İlk olarak metin üzerinde ayırma ve normalleştirme işlemleri yapılmalıdır. Tıbbi görüntüleme raporları genellikle başlık, bulgular, sonuç ve öneri gibi farklı bölümlere sahiptir. Metin cümlelerine ve kelimelerine ayrılacaktır. Metni cümlelerine ayırmada temel olarak noktalama işaretlerinden faydalanılmaktadır. Nokta, cümlelerin sonuna konur ve cümlelerin sonuna geldiğini gösterir. Çalışmalarda genellikle metin içerisindeki noktalar dikkate alınarak cümlelerine ayırma işlemi gerçekleştirilmektedir. Kelimeler ise cümle içerisinde boşluklarla birbirlerinden ayrılır. Nokta işaretinin tıbbi görüntüleme raporlarında ondalık sayılarda kullanımı mevcuttur. Şekil 4.4’te bu kullanıma örnek gösterilmiştir. Bunun için düzenli ifadeler kullanılmış ve cümle sonunda kullanılan nokta haricinde olan “.” işareti düzenli ifadelerle belirtilmiştir. İki sayı arasında kullanılan nokta ise bu cümle sonu değildir gibi ifadelerle veri normalize edilmiştir.

suv maks 2.4

1.3 - 1.5 inflamatuvar

Şekil 4.4. Tıbbi görüntüleme raporlarında noktanın kullanımına örnek

Metin cümlelerine ve kelimelerine ayrılmıştır. Şekil 4.5’te cümlelerine ayırma işleminin sonucu gösterilmiştir. Şeklin anlaşılır olması için cümleler kırmızı renkle 1, 2 ve 3 şeklinde gösterilmiştir.

1 bilateral serebral hemisferlerde serebellumda ve boyun bölgesinde f-18 fdg nin tutulumu fizyolojik sınırlardadır. 2 nazofarinkste palatin tonsillerde ve larenkste patolojik f-18 fdg tutulumu izlenmemiştir. 3 tiroid bezi multinodüler hiperplazik izlenmekte olup patolojik f-18 fdg tutulumu saptanamamıştır. 4 bilateral aksiller bölgede birkaç adet hilusları gözlenmekte olan lenf nodlarında patolojik f-18 fdg tutulumu saptanamamıştır. 5 mediastende suprakarinal alanda izlenmekte olan ~20x13 mm boyutlarındaki lenf nodunda ve sağ trakeaobronşial alanda izlenen ~11x15 mm boyutlarındaki lenf nodunda artmış f-18 fdg tutulumları gözlenmektedir. 6 sağ alt hilus bölgesinde izlenmekte olan ~25x20 mm boyutlarındaki lenf nodunda artmış f-18 fdg tutulumu vardır. 7 mediastende ayrıca prevasküler pretrakeal prekarinal ve aortikopulmoner bölgelerde birkaç adet milimetrik boyutlarda lenf nodları izlenmekle beraber patolojik f-18 fdg tutulumu izlenmemiştir. 8 özefagus alt ucunda ılımlı artmış f-18 fdg tutulumu mevcuttur. 9 sol akciğer parankiminde nodüler lezyon kitle lezyonu veya patolojik f-18 fdg tutulumu izlenmemiştir. 10 sağ akciğerde alt lobda yer işgal eden ve alt lob a nabronşunu oblitere eden ~8x7x7 cm boyutlarında düzensiz sınırlı spiküler uzanımlı periferinde lenfanjetik infiltrasyon lehine değerlendirilen infiltrasyon alanlarının eşlik ettiği kitlede artmış f-18 fdg tutulumu mevcuttur. 11 plevral yüzeylerde effüzyon kalınlaşma veya patolojik f-18 fdg tutulumu saptanamamıştır. 12 toraksta diğer kesimlerde patolojik f-18 fdg tutulumu izlenmemiştir. 13 karaciğerde dalakta ve pankreasta patolojik f-18 fdg tutulumu izlenmemiştir. 14 midede korpusta belirgin olmak üzere belirgin artmış f-18 fdg tutulumu mevcuttur. 15 hiperplazik olarak izlenmekte olan sağ sürrenal bezde patolojik f-18 fdg tutulumu saptanamamıştır. 16 sol sürrenal bez gövdesinde izlenen ~12 mm çaplı nodüler lezyonda düşük seviyede artmış f-18 fdg tutulumu mevcuttur. 17 barsaklarda fizyolojik sınırlarda artmış f-18 fdg tutulumları mevcuttur. 18 abdominopelvik bölgede diğer kesimlerde ve bilateral inguinal bölgelerde patolojik f-18 fdg tutulumu saptanamamıştır. 19 kas-iskelet sisteminde ve görüntüleme alanına giren diğer vücut kesitlerinde patolojik f-18 fdg tutulumu izlenmemiştir.]

Şekil 4.5. Cümlelerine ayırma

Cümlelerine ayırma işleminden sonra ise kelimelerine ayırma işlemi gerçekleştirilmiştir. Herhangi bir ön işlem yapmadan kelimelerine ayırma işlemi yapıldığında Şekil 4.6'daki gibi noktalama işaretlerinden kaynaklı bazı kelimeler birbirinden ayrı kelime olarak ayrıştırılmıştır.

'F', '-', '18' '~', '2', 'cm' '9', '.5',

Şekil 4.6. Kelimelerine ayırmada noktalama işaretlerine örnek

Şekil 4.8'de bir rapor için kelimelerine ayırma işleminin sonucu gösterilmiştir. Şekil 4.6'daki duruma benzer ayrıştırmalar çerçeve içinde gösterilmiştir. Bunun için yine düzenli ifadelerle normalizasyon işlemi yapılmıştır. Normalizasyondan sonra Şekil 4.7'deki gibi kelimelerine ayırma işleminde ondalık sayılar tek bir kelime olarak ayrıştırılmıştır.

'6.5' 'f-18' '3.3'

Şekil 4.7. Kelimelerine ayırmada normalizasyon sonucu noktalama işaretlerine örnek

Bir rapor için kelimelerine ayırma işleminin sonucu ise Şekil 4.9'da verilmiştir. Şekil 4.7'deki duruma benzer ayrıştırmalar çerçeve içinde gösterilmiştir.

['Bilateral', 'serebral', 'hemisferlerde', ',', 'serebellumda', 'boyun', 'bölgesinde', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'saptanmamıştır', '.', 'Nazofarenkste', ',', 'palatin', 'tonsillerde', 'larenkste', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Bilateral', 'aksilları', 'bölgede', 'hilusları', 'izlenen', 'milimetrik', 'lenf', 'nodlarında', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Mediastende', 'izlenen', 'subsantimetrik', 'lenf', 'nodlarında', 'sol', 'hiler', 'bölgede', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Büyük', 'vas', 'küler', 'yapılarda', 'belirgin', 'cidar', 'kalsifikasyonları', 'dikkati', 'çekmiştir', '.', 'Sternumda', 'sternotomi', 'defekt', 'i', 'dens', 'sütür', 'materyalleri', 'mevcuttur', '.', 'Sağ', 'akciğerde', 'belirgin', 'hacim', 'kaybı', 'izlenmiştir', 'Sağ', 'hemitoraksta', '14', 'mm', 'derinlikte', 'plevral', 'efüzyon', 'alanları', 'izlenmiş', 'olup', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Karaciğerde', 'segment', '6', '-', '7', 'bileşkesinde', 'izlenen', '~', '2', 'cm', 'çaplı', 'ametabolik', 'kist', 'izlenmiştir', '.', 'Karaciğerde', 'dalakta', 'pankreaasta', 'mide', 'lojunda', 'sağ', 'sürrenalde', 'lojlarda', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Sol', 'sürrenal', 'gland', 'gö', 'vdesinde', 'izlenen', '9', '.5', 'mm', 'çaplı', 'nodüler', 'lezyonda', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'saptanmamıştır', 'adenom', 'Vasküler', 'yapılarda', 'belirgin', 'cidar', 'kalsifikasyonları', 'dikkati', 'çekmiştir', '.', 'Barsaklarda', 'fizyolojik', 'sınırlarda', 'artmış', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Kas', 'iskelet', 'sisteminde', 'diğer', 'kesimlerde', 'görüntüleme', 'alanına', 'giren', 'diğer', 'vücut', 'kesitlerinde', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Abdominopelvik', 'bölgede', 'diğer', 'kesimlerde', 'bilateral', 'inguinal', 'alanlarda', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.', 'Vertebralarda', 'osteodejeneratif', 'değişiklikler', 'izlenmiş', 'olup', 'patolojik', 'F', '-', '18', 'FDG', 'tutulumu', 'izlenmemiştir', '.']

Şekil 4.8. Kelimelerine ayırma

['bilateral', 'serebral', 'hemisferlerde', 'serebellumda', 'supkortikal', 'yapılarda', 'f-18', 'fdg', 'tutulumu', 'normal', 'fizyolojik', 'sınırlardadır', '.', 'nazofarenkste', 'palatin', 'tonsillerde', 'larenkste', 'patolojik', 'boyutta', 'f-18', 'fdg', 'tutulumu', 'izlenmemiştir', '.', 'sol', 'supraklaviküler', 'bölgede', '~9x6', 'mm', 'boyutlarında', 'lenf', 'nodu', 'izlenmemekt e', 'olup', 'minimal', 'artmış', 'f-18', 'fdg', 'tutulumu', 'vardır', '.', 'boyun', 'bölgesinde', 'sağda', 'c3-c7', 'vertebrala r', 'seviyesinde', 'paravertebral', 'kaslar', 'içerisinde', 'gözlenen', '~74x55x79', 'mm', 'boyutlarında', 'yumuşak', 'doku', 'yapılanmasında', 'minimal', 'artmış', 'f-18', 'fdg', 'tutulumu', 'gözlenmektedir', '.', 'baş-boyun', 'bölgesinde', 'diğer', 'k esimlerde', 'patolojik', 'boyutta', 'f-18', 'fdg', 'tutulumu', 'saptanamamıştır', '.', 'bilateral', 'aksiller', 'bölgede', 'pat olojik', 'f-18', 'fdg', 'tutulumu', 'saptanamamıştır', '.', 'mediastende', 'bilateral', 'hiler', 'bölgelede', 'patolojik', 'f-1 8', 'fdg', 'tutulumu', 'mevcut', 'değildir', '.', 'sol', 'akciğer', 'parankiminde', 'nodüler', 'lezyon', 'kitle', 'lezyonu', 'p atolojik', 'boyutta', 'f-18', 'fdg', 'tutulumu', 'izlenmemiştir', '.', 'sağ', 'akciğerde', 'orta', 'alt', 'lob', 'posterior', 'kesimlerde', 'periferel', 'yerleşimli', 'fibrotik', 'sekel', 'değişiklikler', 'yer', 'yer', 'infiltrasyon', 'alanları', 'izlen mekte', 'olup', 'ılımlı', 'artmış', 'f-18', 'fdg', 'tutulumu', 'mevcuttur', '.', 'plevral', 'yüzeylerde', 'effüzyon', 'kalın laşma', 'patolojik', 'f-18', 'fdg', 'tutulumu', 'izlenmemiştir', '.', 'karaciğerde', 'dalakta', 'midede', 'pankreasda', 'bilate ral', 'sürrenal', 'bezlerde', 'patolojik', 'boyutta', 'f-18', 'fdg', 'tutulumu', 'izlenmemiştir', '.', 'barsaklarda', 'fizyoloj ik', 'sınırlarda', 'artmış', 'f-18', 'fdg', 'tutulumu', 'mevcuttur', '.', 'abdominopelvik', 'bölgede', 'diğer', 'kesimlerd e', 'bilateral', 'inguinal', 'bölgelede', 'patolojik', 'boyutta', 'lenf', 'nodu', 'kitle', 'lezyonu', 'artmış', 'f-18', 'fdg', 'tutulumu', 'mevcut', 'değildir', '.', 'sağ', 'hemitoraksta', 'posteriorda', 'skapulada', 'komşuluğundaki', '2', '.', '3', '.', '4.', '5.', 'kotlarda', 'fiksasyon', 'materyallerine', 'ait', 'olduğu', 'değerlendirilen', 'dens', 'materyalleri', 'gözlenmekt e', 'olup', 'düzeylerde', 'skapula', 'kostalarda', 'irregüler', 'tarzda', 'artmış', 'f-18', 'fdg', 'tutulumu', 'gözlenmekt ed ir', '.', 'sağ', '4.', 'kot', 'posterior', 'komşuluğunda', 'aynı', 'düzlemde', 'sağ', 'paravertebral', 'kas', 'yapılar', 'içeri sinde', 'irregüler', 'tarzda', 'artmış', 'f-18', 'fdg', 'tutulumu', 'gözlenmektedir', '.', 'sağ', '7.', 'kot', 'posterolater alinde', 'fuziform', 'tarzda', 'artmış', 'f-18', 'fdg', 'tutulumu', 'vardır', '.', 'sol', 'omuz', 'ekleminde', 'sol', 'kalça', 'ekleminde', 'bilateral', 'diz', 'eklemlerinde', 'yumuşak', 'dokularda', 'ılımlı', 'irregüler', 'tarzda', 'artmış', 'f-18', 'fd g', 'tutulumu', 'gözlenmektedir', '.', 'sol', 'femur', 'torakanter', 'majör', 'lateral', 'komşuluğunda', 'yumuşak', 'dokud a', 'ılımlı', 'artmış', 'f-18', 'fdg', 'tutulumu', 'vardır', '.', 'sol', '5.', 'metatars', 'inferior', 'kesiminde', 'sol', 'tal us', 'lateral', 'kesiminde', 'yumuşak', 'dokuda', 'ılımlı', 'artmış', 'f-18', 'fdg', 'tutulumu', 'gözlenmektedir', '.', 'gör üntüleme', 'alanına', 'giren', 'diğer', 'vücut', 'kesitlerinde', 'f-18', 'fdg', 'tutulumu', 'normal', 'fizyolojik', 'sınırlarda dır', '.']

Şekil 4.9. Normalizasyon sonucunda kelimelerine ayırma

Çalışmada gerçekleştirilen ön işlemler:

- Tüm kelimeler küçük harfe dönüştürüldü.
- Bazı noktalama işaretleri kaldırıldı.
- Parantez içindeki kelimeler çıkarıldı.
- Anlama etki etmeyen kelimeler kaldırıldı.
- Boşluklar düzenlendi.
- Yazım hatalı düzeltildi.

Dil modeli (kelime vektörleri) oluşturulurken büyük ve küçük harfleri farklı yazılan aynı kelime ayrı vektörlerle ifade edilir. Bu, dil modelini karmaşıktırır. Bunun için tüm kelimeler küçük harfe çevrilmiştir. Tıbbi görüntüle raporlarında sayısal ifadeler önemlidir ve birbirlerinden noktalarla ayrılmaktadır. 2 sayı arasındaki nokta düzenli ifadelerle belirtilmiş ve kaldırılmamıştır. Sadece bazı noktalama işaretleri (virgül ve kesme işareti) kaldırılmıştır. Parantez içindeki kelimeler ve anlama etki etmeyen kelimeler çıkarılmıştır. Metinde bazı yerlerde birden fazla boşluk bulunmaktadır. Bunlar tek boşluğa indirgenmiştir. Noktalama işaretlerinden sonra boşluk bırakılmamıştır. Bu durumda ise cümlelerine ayırma işleminde hata olmaktadır. Bundan dolayı tüm boşluklar düzenlenmiştir.

Kütüphaneler aracılığıyla yazım hataları düzeltirken doğru sonuç alındığı (Şekil 4.10) durumlar olsa da bazı durumlarda bu kütüphaneler sorun oluşturmaktadır. Tıbbi ifadeler kütüphanelerde yer almadığı için yanlış yazıldığı düşünülüp kendisine en benzeyen düzeltildiği durumlar mevcuttur (Şekil 4.11).

```
--unnormalized sentences:
Barsaklarda oral antidiyabetik ilaç kullanımına sekonder geliştiği değerlendirilen artmış F-18 FDG tutulumları izlenmiştir.
++normalized sentences:
bağırsaklara oral antidiyabetik ilaç kullanımına sekonder geliştiği değerlendirilen artmış f-18 fdg tutulumları izlenmiştir
```

Şekil 4.10, Yazım yanlış düzeltme örneği (doğru)

```
--unnormalized sentences:
Karaciğerde, dalakta, pankreasta, mide lojunda ve bilateral sürrenal lojlarda patolojik F-18 FDG tutulumu izlenmemiştir.
++normalized sentences:
karaciğerde dalakta pankreasta mide loşunda ve bilateral sürrenal loşlarda patolojik f-18 fdg tutulumu izlenilmemiştir
```

Şekil 4.11. Yazım yanlış düzeltme örneği (hatalı)

Şekil 4.11’de gösterilen duruma benzer olarak tıbbi terimler Çizelge 4.1 de kendilerine karşılık gelen kelimelere çevrilebilmektedir. Bu sorunu gidermek için tıbbi terimlerin yer aldığı kelimeler kütüphanelerin kelime listesine eklenmiştir.

Çizelge 4.1. Tıbbi terimlere karşılık gelen düzeltme önerileri

Tıbbi Terim	Düzeltilme
Aksiller	Akiller
Nod	Not
Lob	Los/Lobi
Medial	Medikal
Nodüler	Modüler

4.2.2. Sözdizimsel analiz adımı

Şekil 4.1’de de gösterildiği gibi önileşim aşamasından sonra kelime vektörü oluşturma aşamasına geçilmektedir. Doğal dilin modellenmesinde belirsizlik problemleriyle

karşılaşılması için kelimeler sözdizimsel ve anlamsal olarak analiz edilmelidir. Türkçede kelimelerin birbirinden farklı anlamları vardır. Cümle içindeki kelimenin hangi anlamda kullanıldığı bu analizlerle mümkündür. Kelimelerin morfolojik olarak analizi yapıldıktan sonra cümleler dilbilgisi açısından analiz edilecektir. Kelimeler tek başına cümleden anlam çıkarmaya yetmemektedir. Cümle içerisinde kelimelerin kullanıldıkları sıralama değiştiği zaman verdikleri anlam da değişebilmektedir. Aynı kelime cümle içerisinde fiilden önce gelip fiili niteliyorsa zarf, isimden önce gelip ismi niteliyorsa sıfattır. “Ankara Türkiye’nin başkentidir.” cümlesi ile “Türkiye’nin Ankara Başkentidir.” cümlesi aynı kelimelerden oluşmalarına rağmen ikinci cümleyi anlamak daha zordur. Bu iki cümleden birincisi gramer açısından doğru olduğu için bu cümleyi anlamak daha kolaydır. Sözdizimsel analiz ayrıştırma olarak da bilinmektedir. Kelime grupları veya cümlelerin dilbilgisi açısından analiz edilmesidir. Sözdizimsel analizle kelimeler arasındaki ilişki çıkarılmış olur. Ayrıca, kelimelerin cümle içerisindeki rolleri de (sıfat/zarf vb.) bulunmuş olur. Literatürde, metin içindeki kelimeler konuşma parçası (part-of-speech-PoS) olarak geçmektedir. Sözdizimsel analizde her PoS isim, fiil, sıfat, zarf, edat vb. olarak etiketlenir. PoS, sözdizimsel analizde oldukça önemlidir. Kelimelere doğru etiketlerin atanması cümlelerin doğru bir şekilde anlaşılmasını sağlar.

Sözdizimsel analiz için kelimeler analiz edilir ve etiketlenir. Etiketleme işlemi kelimenin isim, sıfat, fiil, edat, bağlaç şeklinde etiketlenmesidir. Bir kelime hem isim hem fiil olabilir. Örneğin et kelimesi isim olarak yiyecek anlamında ya da etmek fiili olarak kullanılabilir. Bundan dolayı biçimbilimsel analizde bir kelime için tüm olasılıklar çıkarılır. Raporlarda ise Latince, tıbbi terimler olduğu için hazır kütüphaneler yetersiz kalmaktadır. Bu ifadeler POS etiketlemede Şekil 4.12’de gösterildiği gibi “Unknown” olarak etiketlenmektedir. Bu şekilde etiketlenen kelime örneklerinden bazılarının altı kırmızı ile çizilmiştir. Bu sorun da yine tıbbi ifadelerin kütüphanelere eklenmesiyle çözülmüştür.

```
[('Bilateral', 'Unknown'), ('serebral', 'Noun'), ('hemisferlerde', 'Unknown'), (',', 'Punctuation'), ('serebellumda', 'Unknown'), ('ve', 'Conjunction'), ('boyun', 'Noun'), ('bölgesinde', 'Noun'), ('patolojik', 'Adjective'), ('F-18', 'Unknown'), ('FDG', 'Unknown'), ('tutulumu', 'Noun'), ('izlenmemiştir', 'Verb'), ('.', 'Punctuation'), ('Aksiller', 'Unknown'), ('bölgelede', 'Noun'), ('hilusları', 'Unknown'), ('izlenen', 'Adjective'), ('ve', 'Conjunction'), ('oval', 'Adjective'), ('yapıları', 'Noun'), ('korunmuş', 'Adjective'), ('bulunan', 'Adjective'), ('ve', 'Conjunction'), ('kısa', 'Adjective'), ('çapları', 'Noun'), ('1', 'Numeral'), ('cm'yi', 'Noun'), ('geçmeyenbirkaç', 'Unknown'), ('adet', 'Noun'), ('lenf', 'Noun'), ('nodu', 'Unknown'), ('izlenm', 'Noun'), ('birliktepatolojik', 'Unknown'), ('F-18', 'Unknown'), ('FDG', 'Unknown'), ('tutulumu', 'Noun'), ('izlenmemiştir', 'Verb'), ('.', 'Punctuation'), ('Mediastende', 'Unknown'), ('diğer', 'Adjective'), ('kesimlerde', 'Noun'), ('ve', 'Conjunction'), ('bilateral', 'Unknown'), ('hiler', 'Noun'), ('bölgelede', 'Noun'), ('patolojik', 'Adjective'), ('F-18', 'Unknown'), ('FDG', 'Unknown'), ('tutulumu', 'Noun'), ('izlenmemiştir', 'Verb'), ('.', 'Punctuation'), ('Sag', 'Adjective'), ('akciğer', 'Noun'), ('alt', 'Adjective'), ('lob', 'Unknown'), ('medial', 'Unknown'), ('bazal', 'Adjective'), ('segmentte', 'Noun'), ('~', 'Unknown'), ('6x12', 'Unknown'), ('mm', 'Noun'), ('boyutlarında', 'Noun'), ('nodüler', 'Unknown'), ('dansite', 'Unknown'), ('artımı', 'Noun'), ('izlenmekte', 'Verb'), ('olup', 'Adverb'), ('patolojik', 'Adjective'), ('F-18', 'Unknown'), ('FDG', 'Unknown'), ('tutulumu', 'Noun'), ('gözlenmemiştir', 'Verb'), ('.', 'Punctuation'), ('SUV', 'Noun'), ('maks', 'Noun'), ('1.2', 'Numeral'), ('.', 'Punctuation'), ('.', 'Punctuation'), ('Sol', 'Adjective'), ('akciğerde', 'Noun'), ('nodüler', 'Unknown'), ('lezyon', 'Noun'), ('.', 'Punctuation'), ('kitle', 'Verb'), ('lezyonu', 'Noun'), ('veya', 'Conjunction'), ('patolojik', 'Adjective'), ('F-18', 'Unknown'), ('FDG', 'Unknown'), ('tutulumu', 'Noun'), ('izlenmemiştir', 'Verb'), ('.', 'Punctuation'), ('Toraksta', 'Noun'), ('diğer', 'Adjective'), ('kesimlerde', 'Noun'), ('patolojik', 'Adjective'), ('F-18', 'Unknown'), ('FDG', 'Unknown'), ('tutulumu', 'Noun')]
```

Şekil 4.12. POS etiketleme

4.3. Kelime Vektörlerinin Çıkarılması

Ön işlemeden sonra kelime vektörlerinin çıkarılması aşamasına geçilir. Kelimeler makinelerin anlayacağı şekilde sembolize edilmelidir. Bunun için kelimeler sayısal olarak temsil edilmelidir. Kelime vektörlerini çıkarmada 5. Bölümde bahsedilen yöntemler kullanılmıştır. En başarılı sonucu Word2Vec vermiştir. One-hot-encoding için sonuç 3. Bölümde Çizelge 3.3’te gösterilmiştir.

BOW yöntemi için:

- Kelimelerden eşsiz bir sözlük oluşturulmuştur.
- Her kelimenin raporlarda kaç kere geçtiği hesaplanmıştır.
- Her rapor için hesaplama sonucu için ayrı bir matris elemanı şeklinde tutulmuştur.

Şekil 4.13’te BOW için kelime vektörü örneği gösterilmiştir. Bu şekle göre örnek alınan metinde “f-18”, “fdg” ve “tutulum” kelimeleri 9 kez geçmiş, “patolojik” kelimesi 8 kez geçmiştir.

```
[ 0.  9.  9.  9.  8.  6.  6.  5.  2.  2.  2.  3.  2.  2.  3.  3.  1.  2.
  2.  2.  1.  2.  2.  1.  2.  2.  2.  2.  1.  1.  1.  1.  1.  1.  1.  1.
  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.
  1.  2.  1.  1.  1.  1.  1.  1.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.
  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  1.
  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.  1.
  1.  1.  1.  1.  1.  1.  1.  1.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.
  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.
  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.  0.]
```

Şekil 4.13. BOW kelime vektörü örneği

Word2Vec modelinde 3 önemli metrik vardır. Bunlar kelime vektör uzunluğunu belirten size, ortadaki kelimenin sağından ve solundan kaç kelimenin dikkate alınacağını belirten window ve en az kaç adet geçen kelimelerin dikkate alınacağını belirten min_count metrikleridir. Word2Vec varsayılan olarak CBOW ile çalışır. Min_count ile raporlarda nadir geçen kelimeler ve yazım hatası olan kelimeler elenmiş olur. Kelime vektörü uzunluğu 100, pencere boyutu 5, min_count metriğini ise 5 (5'ten az adet geçen kelimeler dikkate alınmamıştır.) olarak alınmıştır. Lezyon kelimesinin kelime vektörü örnek olarak Şekil 4.14'te gösterilmiştir.


```
array([ 0.5386966 , -0.24338122,  0.01142201,  0.26845467,  0.29472023,
        -0.11037372,  0.7643768 ,  0.35097185, -0.11737777,  0.07226795,
         0.39561102, -0.4061793 ,  0.19508372,  0.03284172, -0.20181763,
        -0.15642197,  0.35609704, -0.20809 ,  0.8024838 , -0.25917965,
        -0.32595596,  0.24714002,  0.665393 , -0.22564803,  0.35699832,
         0.5814709 ,  0.1270333 ,  0.05435171, -0.28760213, -0.48138252,
        -0.23789674,  0.18589868, -0.25853446, -0.0300002 ,  0.18139961,
         0.14170127, -0.5775206 ,  0.6256757 ,  0.44127893, -0.81381613,
        -0.46074963, -0.360776 , -0.09481306,  0.2577638 , -0.17560884,
         0.47372475,  0.453779 ,  0.39800602,  0.7473898 ,  0.17871182,
         0.41202447,  0.07939067, -0.08530392,  0.0024755 , -0.7256809 ,
         0.1298842 ,  0.23349947, -0.11873513, -0.1593317 ,  0.27275833,
         0.19766574,  0.305611 , -0.18487673, -0.14349681, -0.6996592 ,
         0.58955353,  0.4568097 , -0.08497831, -0.24905093,  0.5777816 ,
        -0.6500168 ,  0.3941861 ,  0.2474888 , -0.31532034,  0.00990307,
         0.24205266,  0.2828148 , -0.0133454 , -0.5419339 ,  0.3702159 ,
        -0.1978464 ,  0.25191775,  0.2078219 , -0.13773207,  0.04371473,
        -0.05891849,  0.20941329,  0.37030828,  0.41239834, -0.4045962 ,
         0.32691815, -0.01220701, -0.13731994,  0.34736243,  0.21893929,
        -0.25724024,  0.01358402,  0.3619756 ,  0.07702986, -0.06857095],
        dtype=float32)
```

Şekil 4.14. Word2Vec kelime vektörü örneği

Lezyon kelimesine en benzeyen kelimeler ise Şekil 4.15'de gösterilen kelimeler çıkmıştır. Lezyon kelimesine sırasıyla en yakın çıkan kelimeler nodül, komponent, nodülarite, solit, nekrotik ve alanlar çıkmıştır.

- Lezyon: Organların yapısında görülen bozukluk, doku bozukluğudur.
- Nodül: Vücutta ortaya çıkan ve normal olmayan doku büyümesi olarak bilinir.
- Komponent: Tıp biliminde temel olarak “parça” ya da “bileşen” anlamlarına gelen bir terimdir.
- Solid: Tümörün durumunu belirtirken kullanılır (Solid tümör-katı dayanıklı).
- Nekroz: Canlı dokunun ya da dokudaki hücrelerin ölmesi demektir.

Bu listeden de anlaşılacağı üzere yazım hatası ya da tıbbi terimlere gelen ekler Word2Vec başarısını etkilememektedir. Lezyon kelimesine benzer vektöre sahip kelimeler lezyon kelimesiyle ilişkilidir. Şekil 4.15’de x ve y koordinatları kelimelerin birbirine olan uzaklıklarını belirtmektedir. Şekilde lezyon kelimesine en uzak kelimenin komponent ve görünüm kelimeleri olduğu görülmektedir.




Şekil 4.15. Word2Vec kelime benzerlik vektörü

4.4. Model Çıkarımı

Önişlem ve kelime vektörlerinin çıkarılması aşamalarında sonra özetleme aşamasına geçilir. Özetlemede, model çıkarımında farklı teknikler kullanılmıştır.

4.4.1. LSTM

LSTM ile soyutlayıcı özetlemede yukarıda bahsedilen önişlem adımları (4.2. bölüm) uygulandıktan sonra metin ve özet için maksimum uzunluk ayarlanmıştır. Metin ve özeti maksimum uzunluğunu ayarlamak için genel olarak metin ve özetlerin kaç kelime ile ifade edildiğine bakılmıştır. Şekil 4.16 metin ve referans özetinde kullanılan kelime sayısının dağılımını göstermektedir. Çalışmadaki kelime sayısı %90'ın üzerinde olduğu için maksimum metin uzunluğu 275, maksimum özet uzunluğu 75'tir (Çizelge 4.2).



Şekil 4.16. Kelime dağılımları

Çizelge 4.2. Bulgu ve sonuç için kelime dağılım yüzdeleri

	Kelime Sayısı	Yüzdelik Oranı
Bulgular	≤ 50	83%
	≤ 75	95%
	≤ 100	98%
Sonuç	≤ 250	85%
	≤ 275	90%
	≤ 300	93%


Model oluşturulmadan önce veri kümesi eğitim ve test için bölünmelidir. Veriler karıştırılarak ve rasgele olarak eğitim ve test verilerine bölünmüştür. Çalışmada, veri kümesinin %80'i eğitim verisi, %20'si ise test verisi olarak kullanılmıştır. Modelde, dönüş dizileri parametresi doğru olarak ayarlanmıştır. LSTM her zaman adımı için gizli durumu ve hücre durumunu üretir. Dönüş durumu da doğru olarak ayarlanmıştır. LSTM yalnızca son zaman adımının gizli durumunu ve hücre durumunu üretir. Yığılı LSTM, birbiri üzerine yığılmış birden çok LSTM katmanına sahiptir. Bu, dizinin daha iyi bir temsil edilmesini sağlar. Çalışmada 3 katmanlı LSTM modeli geliştirilmiştir. Geliştiren LSTM modeli Şekil 4.17'de gösterilmiştir.

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	[(None, 275)]	0	[]
embedding (Embedding)	(None, 275, 300)	241800	['input_1[0][0]']
lstm (LSTM)	[(None, 275, 300), (None, 300), (None, 300)]	721200	['embedding[0][0]']
input_2 (InputLayer)	[(None, None)]	0	[]
lstm_1 (LSTM)	[(None, 275, 300), (None, 300), (None, 300)]	721200	['lstm[0][0]']
embedding_1 (Embedding)	(None, None, 300)	69300	['input_2[0][0]']
lstm_2 (LSTM)	[(None, 275, 300), (None, 300), (None, 300)]	721200	['lstm_1[0][0]']
lstm_3 (LSTM)	[(None, None, 300), (None, 300), (None, 300)]	721200	['embedding_1[0][0]', 'lstm_2[0][1]', 'lstm_2[0][2]']
time_distributed (TimeDistributed)	(None, None, 231)	69531	['lstm_3[0][0]']


Şekil 4.17. Geliştirilen model

Ezberlemenin önüne geçmek için seyreltme katmanı (dropout) eklenmiştir. Girdilerin doğrusal dönüşümü için bırakılacak birimlerin kesrini alan dropout değeri, 3 encoder LSTM’de ve bir decoder LSTM’de 0,4 alınmıştır. Tekrarlayan durumun doğrusal dönüşümü için bırakılacak birimlerin kesrini alan recurrent dropout değeri ise 3 encoder LSTM’de 0,4, decoder LSTM’de ise 0,2 alınmıştır. Çalışmada, tamsayı dizisini anında one-hot vektöre dönüştürdüğü için kayıp fonksiyonu olarak seyrek kategorik çapraz entropi (sparse_categorical_crossentropy) kullanılmıştır. Çalışmada, loss metriğini optimize etmek için “rmsprop” optimizasyon algoritması kullanılmıştır. RMSprop öğrenme oranını ölçeklendirdiğinden hızlı bir optimizasyon algoritmasıdır. Büyük veri kümelerine sahip olduğunda ve mini batch ağırlık güncellemeleri gerçekleştirilmesi gerektiğinde kullanılır. Model tasarlanırken mini-batch parametresi olarak belirlenen değer; modelin aynı anda kaç veriyi işleyeceğini ifade etmektedir. Epoch sayısı ise modelin kaç iterasyon çalışacağını saptayan bir hiper parametredir. Derin öğrenmede problemi çözecek en uygun ağırlık değerleri adım adım hesaplandığı için ilk epoch’larda başarımlar düşük olur, epoch sayısı arttıkça başarımlar da artmaktadır. Bununla birlikte belli bir adımdan sonra modelin öğrenme durumu oldukça azalacaktır. Çalışmanın batch boyutu 128, epoch değeri 50 ayarlanmıştır. 14. epoch’ta erken durdurma yapılmıştır. Şekil 4.18 test ve eğitim aşamalarında elde edilen

kayıp değerlerini göstermektedir. Epoch değeri 10 ve batch boyutu 32 ayarlandığında ile daha başarılı bir model elde edilmiştir. Şekil 4.19 batch boyutu 32 ve epoch değeri 10 olduğunda test ve eğitim aşamalarında elde edilen kayıp değerlerini göstermektedir.



Şekil 4.18. Model test ve eğitim kayıp grafiği (Epoch 50, batch boyutu: 128)



Şekil 4.19, Model test ve eğitim kayıp grafiği (Epoch 10, batch boyutu: 32)

Tıbbi görüntüleme raporlarını özetlemek amacıyla yapılan bu çalışmada, rapordaki bulgular ana metin olarak alınmıştır. Radyologların bir kısmının sonuç ve notları referans özeti olarak alınmış ve derin öğrenme ile özetler oluşturulmuştur. LSTM yöntemi, seq2seq mimarisinde

kodlayıcı olarak kullanılır. Bazı bulgular, sonuçlar ve elde edilen özetler Şekil 4.20 ve 4.21’de gösterilmiştir. Elde edilen özet ve raporun sonucu daha anlaşılır olması için Çizelge 4.3 ve Çizelge 4.4’te tekrar gösterilmiştir. Çizelgelerden de görülebileceği gibi, atıf yapılan özet ile elde edilen özetler genellikle örtüşmektedir. Bazı özetler referans özetleriyle %100 örtüşürken, bazıları eşleşmemiştir. Ancak anlam olarak yakındır. Örneğin Çizelge 4.4’te elde edilen özetle referans özetinin önemli bölümleri de yer aldığı görülmektedir. Değerlendirmede ROUGE metriği dikkate alındığında elde edilen tüm özetler referans özetindeki kelimelerden oluştuğu için ROUGE kesinlik değeri %100’dür. Çizelge 4.4 için ROUGE duyarlılık (0,24) ve F1-Skor (0,48) değerleri düşük olmakla birlikte sonuç anlamlıdır. Çizelge 4.3 için hem duyarlılık hem de F1 Puanı 1.0’dır.

Bulgular (Findings): bilateral serebral hemisferlerde serebellumda supkortikal yapılarda f 18 fdg 'nin tutulumu normal fizyolojik sınırlardadır nazofarenkste palatin tonsillerde larenkste patolojik boyutta f 18 fdg tutulumu izlenmemiştir baş boyun bölgesinde diğer kesimlerde patolojik boyutta f 18 fdg tutulumu saptanmamıştır bilateral aksiller bölgede patolojik boyutta f 18 fdg tutulumu mevcut değildir mediastende bilateral hiler bölgede patolojik f 18 fdg tutulumu izlenmemiştir iki akciğer parankiminde nodüler lezyon kitle lezyonu patolojik f 18 fdg tutulumu izlenmemiştir plevral yüzeylerde effüzyon kalınlaşma patolojik f 18 fdg tutulumu izlenmemiştir toraksta diğer kesimlerde patolojik f 18 fdg tutulumu mevcut değildir karaciğerde dalakta midede pankreasta bilateral sürrenal bezlerde patolojik boyutta f 18 fdg tutulumu izlenmemiştir sağ üretero vezikal bileşke radyoaktif madde stazı mevcuttur u v darlık abdominopelvik bölgede diğer kesimlerde bilateral inguinal bölgelerde patolojik boyutta lenf nodu kitle lezyonu artmış f 18 fdg tutulumu mevcut değildir kas iskelet sisteminde görüntüleme alanına giren diğer vücut kesitlerinde patolojik boyutta f 18 fdg' nin tutulumu saptanmamıştır
Sonuç (Radiographic Impressions): patolojik metabolik aktivite izlenmeyen f 18 fdg pet bt çalışması
Özet (Summary): patolojik metabolik aktivite izlenmeyen f 18 fdg pet bt çalışması

Şekil 4.20. LSTM metin örneği

Çizelge 4.3. Sonuç ve elde edilen özet örneklerden biri

Sonuç	patolojik metabolik aktivite izlenmeyen f 18 fdg pet bt çalışması
Özet	patolojik metabolik aktivite izlenmeyen f 18 fdg pet bt çalışması

Bulgular (Findings): bilateral serebral hemisferlerde serebellumda supkortikal yapılarda f 18 fdg tutulumu normal fizyolojik sınırlardadır nazofarenkste palatin tonsillerde larenkste patolojik f 18 fdg tutulumu izlenmemiştir baş boyun bölgesinde patolojik f 18 fdg tutulumu saptanmamıştır sağ pektoral bölgede santral venöz katetere ait port izlenmektedir bilateral aksiller bölgelerde patolojik f 18 fdg tutulumu saptanmamıştır bilateral hiler bölgelerde ılımlı artmış f 18 fdg tutulumları izlenmektedir alt özefagusta ılımlı artmış f 18 fdg tutulumu izlenmektedir sol akciğerde apikal bölgelerde düzensiz dansite artım alanları izlenmekle beraber patolojik f 18 fdg tutulumu saptanmamıştır sağ akciğerde mass patolojik f 18 fdg tutulumu saptanmamıştır toraksta diğer kesimlerde patolojik f 18 fdg tutulumu izlenmemiştir plevral yüzeylerde effüzyon kalınlaşma patolojik f 18 fdg tutulumu izlenmemiştir karaciğerde dalakta pankreasta bilateral sürrenal lojlerde patolojik f 18 fdg tutulumu izlenmemiştir opere mide rezidü mide dokusunda düzensiz duvar kalınlaşma alanları izlenmekte olup irregüler tarzda artmış f 18 fdg tutulumu mevcuttur midede komşuluğunda yağ doku içerisinde dansite artım alanları kirlilik izlenmektedir ayrıca mide karaciğer yağ barsaklarda splenik fleksurada inen kolon orta kesiminde splenik kolon orta kesiminde belirgin olmak üzere oral antidiyabetik ilaç kullanımına sekonder geliştiği değerlendirilen alınan geç görüntü artmış f 18 fdg tutulumları izlenmektedir abdominopelvik bölgede diğer kesimlerde bilateral inguinal bölgede patolojik f 18 fdg tutulumu saptanmamıştır vertebral kolonda yer yer osteodejeneratif değişiklikler izlenmekte olup patolojik f 18 fdg tutulumu izlenmemiştir kas iskelet sisteminde görüntüleme alanına giren diğer vücut kesitlerinde patolojik f 18 fdg tutulumu izlenmemiştir
Sonuç (Radiographic Impressions): opere mide karsinoma midede tanımlandığı haliyle patolojik artmış metabolik aktiviteler izlenmektedir vücudun diğer kesimlerinde malignite lehine değerlendirilebilecek hipermetabolik bir başka odak saptanmamıştır
Özet (Summary): patolojik metabolik aktivite izlenmektedir hipermetabolik odak saptanmamıştır

Şekil 4.21. LSTM bir başka metin örneği

Çizelge 4.4. Sonuç ve elde edilen özet örneklerden bir diğeri

Sonuç	opere mide karsinoma midede tanımlandığı haliyle patolojik artmış metabolik aktiviteler izlenmektedir vücudun diğer kesimlerinde malignite lehine değerlendirilebilecek hipermetabolik bir başka odak saptanmamıştır
Özet	patolojik metabolik aktivite izlenmektedir hipermetabolik odak saptanmamıştır

Elde edilen tüm özetler için ortalama kesinlik değeri %47, duyarlılık değeri %21, F1-Skor değeri %29 olmuştur.

4.4.2. TextRank

TextRank ile Şekil 3.5'te gösterilen işlemler adım adım uygulanmıştır.


TextRank ile özetleme işlem adımları:

- Aynı ID'ye sahip raporlar tek bir metin haline getirildi.
- Metin cümlelerine ayrıldı.
- Kelime vektörleri çıkarıldı.
- Benzerlik matrisi oluşturuldu.
- Graf oluşturuldu.
- Cümleler sıralandı.
- Özet oluşturuldu.

Cümlelerine ayırma ve kelime vektörleri önceki başlıklarda incelenmişti. Bu aşamalardan sonra özetleme aşaması cümle işaretleyicilerinin ağırlığının hesaplanmasıyla başlar. Cümlelerdeki kelimeler arasındaki ilişki şekildeki graf ile gösterilmiştir. Graf, iki cümle arasındaki kelime benzerliğini göstermektedir. Grafta düğümler cümleleri, kenarlar cümleler arasındaki benzerliği temsil etmektedir. Şekil 4.22, Çizelge 4.5'te verilen 4 cümle arasındaki grafi göstermektedir. Cümleler arasındaki benzerlikler Eş. 3.5'e göre hesaplanmıştır (Çizelge 4.6). Cümle benzerliklerin hesaplanarak metrisin oluşturulması ve graf oluşturulduktan sonra cümleler önem derecesine göre sıralanmış ve özet elde edilmiştir.

Çizelge 4.5. Metinden cümle örnekleri

Cümle Numaraları	Cümle Örnekleri
1	bilateral serebral hemisferlerde serebellumda boyun bölgesinde patolojik f18 fdg tutulumu izlenmemiştir
2	abdominopelvik bölgede diğer kesimlerde bilateral inguinal alanlarda patolojik f18 fdg tutulumu izlenmemiştir
3	kas iskelet sisteminde görüntüleme alanına giren diğer vücut kesitlerinde patolojik f18 fdg tutulumu izlenmemiştir
4	nazofarenkste palatin tonsillerde larenkste patolojik f18 fdg tutulumu izlenmemiştir



Şekil 4.22. Metin graf gösterimi

Çizelge 4.6. Cümlelerin kosinüs benzerlikleri

	Cümle 1	Cümle 2	Cümle 3	Cümle 4
Cümle 1	-	0,30	0,20	0,25
Cümle 2	0,30	-	0,24	0,23
Cümle 3	0,20	0,24	-	0,22
Cümle 4	0,25	0,23	0,22	-

TextRank ile metin özetleme sonucunda elde edilen özet örneği Şekil 4.24'te gösterilmiştir. Şekildeki özet Şekil 4.23'te verilen metnin özettir. Şekillerden anlaşılacağı üzere elde

edilen özet anlamlıdır. ROUGE ile model performansı, ortalama kesinlik değeri %46, duyarlılık değeri %71 ve F1-skor değeri %56 olarak değerlendirilmiştir.

Bilateral serebral hemisferlerde, serebellumda ve boyun bölgesinde patolojik F-18 FDG tutulumu izlenmemiştir. Abdominopelvik bölgede diğer kesimlerde ve bilateral inguinal alanlarda patolojik F-18 FDG tutulumu izlenmemiştir. Kas-iskelet sisteminde ve görüntüleme alanına giren diğer vücut kesitlerinde patolojik F-18 FDG tutulumu izlenmemiştir. Nazofarenkste, palatin tonsillerde ve larenkste patolojik F-18 FDG tutulumu izlenmemiştir. Aksiller bölgelerde hilusları izlenen birkaç adet lenf nodu izlenmekle birlikte patolojik F-18 FDG tutulumu izlenmemiştir. Mediastende diğer kesimlerde ve bilateral hiler bölgelerde patolojik F-18 FDG tutulumu izlenmemiştir. Sağ akciğerde nodüler lezyon, kitle lezyonu veya patolojik F-18 FDG tutulumu izlenmemiştir. Plevral yüzeylerde effüzyon, kalınlaşma veya patolojik F-18 FDG tutulumu izlenmemiştir. Toraksta diğer kesimlerde patolojik F-18 FDG tutulumu izlenmemiştir. Karaciğerde, dalakta, pankreasta, midede ve surrenal lojlarda patolojik F-18 FDG tutulumu izlenmemiştir. Safra kesesi izlenmemiş olup lojunda sutur metaryalleri mevcuttur (opere). Üst mediastende tiroid bezi inferoposteriorunda sağ paratrakeal alanda ~ 10x19 mm boyutlarında lobulasyon gösteren lezyon izlenmiş olup artmış F-18 FDG tutulumu vardır (SUV maks 9.8 konglomere LAP?). Sol akciğerde lingular segmentlerde ve üst lob anterior segmentte en büyükleri ~ 11 mm çaplı 12-13 adet çevresel infiltrasyon alanlarının eşlik ettiği nodüler lezyonlar izlenmiş olup artmış F-18 FDG tutulumu izlenmiştir (SUV maks 2.9). Mesanede duvar kalınlaşma alanı veya patolojik F-18 FDG tutulumu saptanmamıştır.

Şekil 4.23. TextRank özetlemede metin örneği

aksiller bölgelerde hilusları izlenen birkaç adet lenf nodu izlenmekle birlikte patolojik f18 fdg tutulumu izlenmemiştir. safra kesesi izlenmemiş olup lojunda sutur metaryalleri mevcuttur. üst mediastende tiroid bezi inferoposteriorunda sağ paratrakeal alanda yaklaşık 10x19 mm boyutlarında lobulasyon gösteren lezyon izlenmiş olup artmış f18 fdg tutulumu vardır. sol akciğerde lingular segmentlerde üst lob anterior segmentte en büyükleri yaklaşık 11 mm çaplı 12 13 adet çevresel infiltrasyon alanlarının eşlik ettiği nodüler lezyonlar izlenmiş olup artmış f18 fdg tutulumu izlenmiştir.

Şekil 4.24. TextRank ile elde edilen özet örneği

4.4.3. LSA

2. Bölümdeki ön işlemler uygulandıktan sonra LSA ile metin özetlenmiştir. LSA'da işlem adımları:

- Bir kelime-metin matrisi oluşturuldu.
- Gereksiz yüksek frekanslı kelimelerin ağırlığını azaltmak için TF- IDF dönüşümü kullanılmıştır.
- En büyük tekil değerler seçilmiş ve boyut azaltılmıştır.
- Cümleler ve raporlar iki vektör arasındaki açının kosinüsü alınarak karşılaştırılmıştır.

Şekil 4.25 iki raporun LSA ile yüksek puanlı cümlelerini vektörel olarak göstermektedir.

[-0.0399441195948072,	[0.3734472663313231,
-0.21295599350291305,	0.5639334059146824,
-0.4228501798608891,	1.561977001320807,
-0.16009629942059317,	1.4684656929480087,
-0.11162058326565916,	0.7223748425968368,
0.3482156516142005,	0.35605145974323754,
0.05367258303178724,	0.49455767230212483,
-0.40333608688491007,	0.8534904699739843,
-0.5679701278377468,	1.8026661291996426,
0.15181261228647663,	0.2552078051656514,
-0.2047360099675259,	0.687952780846228,
-0.23928446614254065,	0.3359944165579319,
-0.5573017429492194,	1.2933079027796255,
0.5400808763600878,	1.3634443395903852,
0.3268481247993752,	1.0195900903473947,
0.5210648996938106,	0.7939226785274873,
0.5823742953780092,	0.9340223104011243,
0.501794912471545,	0.9208173399843383,
-0.3974658789227705,	0.9957668738938241,
-0.3124477075223583]	0.4242538574501018]

Şekil 4.25 LSA ile iki raporun cümle puanları

LSA ile metin özetleme sonucunda elde edilen özet örneği Şekil 4.27’de gösterilmiştir. Şekildeki özet Şekil 4.26’da verilen metnin özetidir. Şekillerden anlaşılacağı üzere elde edilen özet anlamlıdır. ROUGE ile model performansı, ortalama kesinlik değeri %46, duyarlılık değeri %42 ve F1-skor değeri %44 olarak değerlendirilmiştir.

Bilateral serebral hemisferlerde, serebellumda ve supkortikal yapılarda F-18 FDG’nin tutulumu normal fizyolojik sınırlardadır. Nazofarenkste, palatin tonsillerde ve larenkste patolojik boyutta F-18 FDG tutulumu izlenmemiştir. Sol supraklaviküler bölgede ~ 9x6 mm boyutlarında lenf nodu izlenmekte olup minimal artmış F-18 FDG tutulumu vardır (SUV maks 1.6, reaktif?). Boyun bölgesinde sağda C3- C7 vertebral seviyesinde paravertebral kaslar içerisinde gözlenen ~ 74x55x79 mm boyutlarında yumuşak doku yapıları anmasında minimal artmış F-18 FDG tutulumu gözlenmektedir (SUV maks 2.0). Baş-boyun bölgesinde diğer kesimlerde patolojik boyutta F-18 FDG tutulumu saptanamamıştır. Bilateral aksiller bölgede patolojik F-18 FDG tutulumu saptanamamıştır. Mediastende ve bilateral hiler bölgelerde patolojik F-18 FDG tutulumu mevcut değildir. Sol akciğer parankiminde nodüler lezyon, kitle lezyonu veya patolojik boyutta F-18 FDG tutulumu izlenmemiştir. Sağ akciğerde orta ve alt lob posterior kesimlerde periferik yerleşimli fibrotik sekel değişiklikler ve yer yer infiltrasyon alanları izlenmekte olup ılımlı artmış F-18 FDG tutulumları mevcuttur (SUV maks 2.4). Plevral yüzeylerde effüzyon, kalınlaşma veya patolojik F-18 FDG tutulumu izlenmemiştir. Karaciğerde, dalakta, midede, pankreasta ve bilateral sürrenal bölgede patolojik boyutta F-18 FDG tutulumu izlenmemiştir. Barsaklarda fizyolojik sınırlarda artmış F-18 FDG tutulumları mevcuttur. Abdominopelvik bölgede diğer kesimlerde ve bilateral inguinal bölgelerde patolojik boyutta lenf nodu, kitle lezyonu veya artmış F-18 FDG tutulumu mevcut değildir. Sağ hemitoraksta posterioriorda skapulada ve komşuluğundaki 2. 3. 4. ve 5. kotlarda fiksasyon materyallerine ait olduğu değerlendirilen dens materyalleri gözlenmekte olup bu düzeylerde skapula ve kostalarda irregüler tarzda artmış F-18 FDG tutulumları gözlenmektedir (SUV maks 8.4). Sağ 4. kot posterior komşuluğunda ve aynı düzlemde sağ paravertebral kas yapıları içerisinde irregüler tarzda artmış F-18 FDG tutulumları gözlenmektedir (SUV maks 6.5). Sağ 7. kot posterolateralinde fuziform tarzda artmış F-18 FDG tutulumu vardır (SUV maks 3.3). Sol omuz ekleminde, sol kalça ekleminde ve bilateral diz eklemlerinde yumuşak dokularda ılımlı irregüler tarzda artmış F-18 FDG tutulumları gözlenmektedir (SUV maks 1.1- 2.7, inflamatuvar süreç?). Sol femur torakanter majör lateral komşuluğunda yumuşak dokuda ılımlı artmış F-18 FDG tutulumu vardır (SUV maks 2.4, inflamasyon?). Sol 5. metatars inferior kesiminde ve sol talus lateral kesiminde yumuşak dokuda ılımlı artmış F-18 FDG tutulumları gözlenmektedir (SUV maks sırası ile 1.3- 1.5, inflamatuvar süreç?). Görüntüleme alanına giren diğer vücut kesitlerinde F-18 FDG’ nin tutulumu normal fizyolojik sınırlardadır.

Şekil 4.26. LSA ile özetlemede metin örneği

sol omuz ekleminde sol kalça ekleminde bilateral diz eklemlerinde yumuşak dokularda ılımlı irregüler tarzda artmış f-18 fdg tutulumları gözlenmektedir. sağ hemitoraksta posterioriorda skapulada komşuluğundaki 2. 3. 4. 5. kotlarda fiksasyon materyallerine ait olduğu değerlendirilen dens materyalleri gözlenmekte olup bu düzeylerde skapula kostalarda irregüler tarzda artmış f-18 fdg tutulumları gözlenmektedir. sağ 7. kot posterolateralinde fuziform tarzda artmış f-18 fdg tutulumu vardır. Sol femur torakanter majör lateral komşuluğunda yumuşak dokuda ılımlı artmış f-18 fdg tutulumu vardır. sol 5. metatars inferior kesiminde ve sol talus lateral kesiminde yumuşak dokuda ılımlı artmış f-18 fdg tutulumları gözlenmektedir.

Şekil 4.27. LSA ile elde edilen özet örneği

4.4.4 Kural tabanlı özetleme

Tıbbi görüntüleme raporları belirli kurallara göre yazılmaktadır. Veri olarak tüm vücut görüntüleme raporları kullanılmıştır. Tüm vücut görüntüleme raporları Vücudun üst bölümlerinden aşağı bölümlerine kadar tüm vücut taranır. İnceleme ilk önce beyinden başlar, ağız, baş-boyun bölgesi, boyun- göğüs bölgesi, karaciğer, dalak, mide gibi iç organlar en son da kas-iskelet sistemi incelenir. Tüm raporlar bu şekilde sıralı yazılır. Raporlar aynı terimlerle yazılmaktadır. Dolayısıyla, kural tabanlı bir özetleme sistemi ile raporların etkili bir şekilde özetlenmesi mümkündür. Bir hastaya ait birden fazla rapor var ise bu iki rapor karşılaştırılır ve herhangi bir değişiklik var ise bunlar özetle de yer almalıdır. Değişikliklerde ise en son tarihli rapordaki değişimler dikkate alınmalıdır. Raporlarda geçen “izlenmiştir”, “saptanmıştır” gibi kelimeler olumsuzluk bildirmektedir. Bu ifadeler dikkate alınarak olumsuzluk belirten ifadeler de özetlerde yer almalıdır. Şekil 4.29 ve 4.30’da bir hastaya ait iki farklı rapor bulguları gösterilmiştir.

Bilateral serebral hemisferlerde, serebellumda ve supkortikal yapılarda F-18 FDG tutulumu normal fizyolojik sınırlardadır. Nazofarenkste, palatin tonsillerde ve larenkste patolojik F-18 FDG tutulumu normal fizyolojik sınırlardadır. Baş-boyun bölgesinde diğer kesimlerde patolojik F-18 FDG tutulumu saptanmamıştır. Bilateral aksiller bölgelerde patolojik F-18 FDG tutulumu gözlenmemiştir. Mediastende ve bilateral hiler bölgelerde patolojik F-18 FDG tutulumu izlenmemiştir. Sol akciğer üst lobda apikal anteriorda ~ 8.5 mm çaplı (SUV maks 1.4) ve sağ akciğer alt lob posterobazal segmentte ~ 9x11 mm boyutlarında (SUV maks 5.1) nodüller izlenmekte olup artmış F-18 FDG tutulumları gözlenmektedir. Plevral yüzeylerde effüzyon, kalınlaşma veya patolojik F-18 FDG tutulumu izlenmemiştir. Toraksta diğer kesimlerde patolojik F-18 FDG tutulumu saptanmamıştır. Karaciğerde, dalakta, pankreasta ve sağ sürrenal lojda patolojik F-18 FDG tutulumu izlenmemiştir. Opere mide karsinoma olgusunda üst abdomende gözlenmekte olan anastomoz hattında patolojik boyutta F-18 FDG tutulumu izlenmemiştir. Sol sürrenal bez lateral bacağına izlenmekte olan nodüler lezyonda patolojik F-18 FDG tutulumu izlenmemiştir (adenom?). Barsaklarda belirgin irregüler artmış F-18 FDG tutulumları gözlenmektedir (inflamatuvar süreç?). Abdominopelvik bölgede diğer kesimlerde ve bilateral inguinal bölgelerde patolojik boyutta lenf nodu, kitle lezyonu veya patolojik F-18 FDG tutulumu izlenmemiştir. Sağ 9. kot lateralinde fraktür hattı izlenmekte olup patolojik F-18 FDG tutulumu mevcut değildir. Kas-iskelet sisteminde diğer kesimlerde ve görüntüleme alanına giren diğer vücut kesitlerinde patolojik F-18 FDG tutulumu izlenmemiştir.

Şekil 4.28. Bir hastaya ait son tetkik raporu

Bilateral serebral hemisferlerde, serebellumda ve supkortikal yapılarda F-18 FDG tutulumu normal fizyolojik sınırlardadır. Nazofarenkste, palatin tonsillerde ve larenkste patolojik F-18 FDG tutulumu normal fizyolojik sınırlardadır. Baş-boyun bölgesinde diğer kesimlerde patolojik F-18 FDG tutulumu saptanmamıştır. Bilateral aksiller bölgelerde patolojik F-18 FDG tutulumu gözlenmemiştir. Mediastende ve bilateral hiler bölgelerde patolojik F-18 FDG tutulumu izlenmemiştir. Her iki akciğer parankiminde nodüler lezyon, kitle lezyonu veya patolojik F-18 FDG tutulumu izlenmemiştir. Plevral yüzeylerde effüzyon, kalınlaşma veya patolojik F-18 FDG tutulumu izlenmemiştir. Toraksta diğer kesimlerde patolojik F-18 FDG tutulumu saptanmamıştır. Karaciğerde, dalakta, pankreasta ve sağ sürrenal lojda patolojik F-18 FDG tutulumu izlenmemiştir. Özefagus distal kesiminden başlayarak midede kardiya ve fundusa uzanan düzensiz duvar kalınlaşma alanlarında artmış F-18 FDG tutulumu izlenmiştir (SUV maks 6.3, geç SUV maks 10.4). Hepatogastrik alanda çok sayıda supsantimetrik boyutlarda lenf nodları gözlenmekte olup patolojik F-18 FDG tutulumu izlenmemiştir. Sol sürrenal bez lateral bacağına izlenmekte olan ~ 25x16 mm boyutlarındaki nodüler lezyonda patolojik F-18 FDG tutulumu izlenmemiştir (adenom?). Abdominopelvik bölgede diğer kesimlerde ve bilateral inguinal bölgelerde patolojik boyutta lenf nodu, kitle lezyonu veya patolojik F-18 FDG tutulumu izlenmemiştir. Sağ 9. kot lateralinde fraktür hattı ve artmış F-18 FDG tutulumu izlenmektedir (SUV maks 3.4, inflamasyon?). Kas-iskelet sisteminde diğer kesimlerde ve görüntüleme alanına giren diğer vücut kesitlerinde patolojik F-18 FDG tutulumu izlenmemiştir.

Şekil 4.29. Bir hastaya ait rapor

Veri 2. bölümde bahsedilen önışlemlerden geçirildikten sonra özetleme için en son tarihli rapor dikkate alınarak 2 rapor arasında farklı cümleler alınmıştır. Olumsuzluk bildiren cümleler de dikkate alınmıştır. Sonuçlar hastaya ait geçmiş raporun tarihi de eklenerek özet

olarak sunulmuştur. Elde edilen özet Şekil 4.30'da gösterilmiştir. ROUGE ile model performansı, ortalama kesinlik değeri %54, duyarlılık değeri %37 ve F1-skor değeri %44 olarak değerlendirilmiştir.

31.08.2021 ile kıyaslandığında sol akciğer üst lobda apikal anteriorda ~8.5 mm çaplı sağ akciğer alt lob posterobazal segmentte ~9x11 mm boyutlarında nodüller izlenmekte olup artmış f-18 fdg tutulumları gözlenmektedir. sol akciğer üst lobda apikal anteriorda ~8.5 mm çaplı sağ akciğer alt lob posterobazal segmentte ~9x11 mm boyutlarında nodüller izlenmekte olup artmış f-18 fdg tutulumları gözlenmektedir. opere mide karsinoma olgusunda üst abdomende gözlenmekte olan anastomoz hattında patolojik boyutta f-18 fdg tutulumu izlenmemiştir. özefagus distal kesiminden başlayarak midede kardiya ve fundusa uzanan düzensiz duvar kalınlaşma alanlarında artmış f-18 fdg tutulumu izlenmiştir. sol sürrenal bez lateral bacağında izlenmekte olan nodüler lezyonda patolojik f-18 fdg tutulumu izlenmemiştir. bağırsaklarda belirgin irregüler artmış f-18 fdg tutulumları gözlenmektedir. sağ 9. kot lateralinde fraktür hattı izlenmekte olup patolojik f-18 fdg tutulumu mevcut değildir.

Şekil 4.30, Kural tabanlı özetleme ile elde edilen sonuç

4.5. Deneysel Sonuçlar

Özetleme çalışmasında, Tıbbi Görüntüleme Merkezlerinden alınan 2457 tıbbi görüntüleme raporu kullanılmıştır. Veriler üzerinde çalışmayı kolaylaştırmak ve başarıyı artırmak için veri ön işlemlerden geçirilmiştir. Ön işlem ve analiz aşamalarında NLP yöntemleri kullanılmıştır. Kelime vektörlerinin çıkarılmasında temel ve popüler kelime vektörleri kullanılmıştır. Word2Vec modeli başarılı sonuç vermiştir. Özetleme aşamasında farklı özetleme yaklaşımları ve algoritmaları kullanılmıştır. LSA, TextRank ve derin öğrenme yöntemlerinden seq2seq mimarisine sahip LSTM algoritması ile özetleme çalışmaları yapılmıştır. Ayrıca, karşılaştırma ve olumsuzluk analizi dikkate alınarak başka bir özetleme çalışması daha yapılmıştır. TF-IDF yöntemi LSA ile birlikte, Word2Vec ise TextRank ile birlikte özetmede kullanılmıştır. Elde edilen özetler ROUGE metriği ile değerlendirilmiştir. Çizelge 4.7'de özetleme yöntemlerinin ortalama kesinlik duyarlılık ve f1 skor değerleri gösterilmiştir.

Çizelge 4.7. Deneysel sonuçlar

Yöntem	Avg-Precision	Avg-Recall	Avg-F1Score
LSTM	%47	%21	%29
TextRank	%46	%71	%56
LSA	%46	%42	%44
Kural tabanlı özetleme	%54	%37	%44

8. SONUÇ VE TARTIŞMA

Günümüzde hızla gelişen bilgisayar teknolojileri faydalarının ve hayatı kolaylaştıran işlevlerinin yanında birçok konuda da aşılması gereken problemlere neden olmuştur. Bu problemlerden biri de dijital ortamda istenilen belgeye ve içeriğe ulaşmaktır. sosyal medya ve internet kullanımının artmasıyla üretilen bilgi ve içerik artmakta, aranan bilgiye ulaşmak giderek zorlaşmaktadır. Üretilen içeriğinin fazlalığı nedeniyle, bir konuya ait belgelerin tamamını okumak mümkün değildir. Bunun için özetleme sistemlerine olan ilgi giderek artmaktadır. Metin özetleme ile bilgiye erişim çabuk ve hızlı olmaktadır. Metin özetleme, aranan konu ile ilgili en önemli bilgileri hızlı bir şekilde sunmaktadır. Metin özetleme, orijinal metni alarak bu metni daha kısa bir şekilde metin içerisindeki önemli içeriği barındıracak şekilde yeniden ifade edilmesi olarak tanımlanabilir.

Metin özetleme üzerine yapılan çalışmalar İngilizce ve Çince metinler üzerine yoğunlaşmaktadır. Türkçe metin içeren veri kümesinin sayılı olması nedeniyle Türkçe metinler için yapılan çalışmalar da yetersizdir ve çoğunluğu kamuya açık olan verilerle yapılan çalışmalardır. Türkçe için yapılan çalışmalarda haber metinlerinin, Türkçe tweetlerin ve ürün ya da hizmet sunan çeşitli web sitelerdeki değerlendirmelerin veri olarak kullanılmakta olduğu gözlemlenmiştir. Türkçe özetleme çalışmaları genel olarak terim sıklığı kavramına bazı özellikler eklenerek puanlandırmaya dayalı yapılan özetleme çalışmalarıdır. Çalışmalarda metinler genel olarak çıkarımsal yöntemle özetlenmektedir. Çıkarımsal özetleme çalışmalarında istatistiksel ve sezgisel yöntemler yaygın olarak kullanılmaktadır.

Zaman içerisinde hasta kayıt bilgilerinin artmasıyla metin özetleme çalışmaları sağlık alanında da önem kazanmaktadır. Pandeminin de etkisiyle sağlık verilerinin özetlenmesi ile ilgili çalışmalar son yıllarda önem kazanmıştır. Ancak, Sağlık sektöründe özetleme çalışmaları normal özetleme çalışmalarına kıyasla daha azdır. Klinik hasta bilgilerini ve elektronik hasta kayıtlarını özetlemek için yapılan çalışmalar bulunmaktadır. Türkçe sağlık metinleri üzerine yapılan çalışmalar genellikle sınıflandırma ile ilgilidir. Türk araştırmacılar tarafından bu alanda yapılan çalışmalarda ise genellikle bu konuyla ilgili Türkçe kamuya açık veri kümesi bulunmayışından kaynaklı İngilizce veriler kullanılmaktadır.

Metin özetleme NLP'nin zorlu problemlerinden biridir. Metin, ses, konuşma gibi veriler üzerinde işlem yapmak NLP'nin konusudur. NLP üzerine çalışmalar her ne kadar 20. yüzyılın ortalarında başlasa da derin öğrenmeyle birlikte yeni bir boyut kazanmıştır. İlk sohbet robotu olan kural tabanlı ELİZA ile günümüz sohbet robotu ChatGPT arasındaki fark, NLP ile ilgili gelişmeleri somut bir şekilde gözler önüne sermektedir. Konuştuğumuz dillerde kesin kuralların olmaması ve çok sayıda kelime bulunması NLP'yi zorlu bir problem haline getirmektedir. Türkçe sondan eklemeli bir dildir ve bünyesinde Arapça ve Farsça kelimeler barındırır. Türkçede yaklaşık 30 bin kelime köküne birden fazla yapım eki getirilerek yeni kelimeler oluşturulur. Bundan dolayı Türkçe NLP için ekstra zorluk teşkil eder. Kelimelerin farklı anlamlarının olması, cümledeki konumlarına göre yapısının değişmesi, zamirler, kinayeli konuşma ve deyimler NLP için belirsizliğe neden olur.

Tıbbi görüntüleme teknikleri, hastalık tanı ve tedavi sürecinde önemli bir yere sahiptir. Uzman hekimlerce yorumlanan bu görüntüler, sonuç raporu olarak ilgili bölüme sunulmakta, sunulan bu sonuç raporları görüntüleme ait detay bilgiler içermekte ve tanı sürecinde sıklıkla kullanılmaktadır. Hastalığın doğru teşhisi ve tedavisi açısından yeni yapılan tetkiklere ek olarak geçmiş tetkik sonuçlarını içeren raporların incelenmesi önem arz etmektedir. Günümüzde yaygın olarak kullanılan sağlık bilgi sistemleri, hastaların klinik bilgilerinin yanı sıra tüm tıbbi görüntüleme raporlarını da saklamaktadır. Türkiye'de "e-Nabız" sistemi ile tüm bireylerin sağlık bilgilerine tek noktadan ulaşılabilir hale gelmiştir. Bu sistem sayesinde hekimler hastalarının sağlık bilgilerine ulaşabilmekte ve bu bilgileri tanı ve tedavide kullanabilmektedir. Doktorların iş yükü düşünüldüğünde bir hastaya ait sisteme kayıtlı tüm raporların incelenmesi zaman alıcı olması nedeniyle oldukça zordur. Geçmişte geçirilen bazı hastalıkların etkileri yanlış teşhise neden olabilmektedir. Örneğin, geçmişte yaşanan bazı hastalıkların neden olduğu akciğer tahribatları, günümüzde COVID-19'un neden olduğu akciğer tutumu ile karıştırılabilmektedir. Bu gibi durumlar geçmişteki tıbbi görüntüleme raporlarının incelenmesinin önemini göstermektedir. Geçmişte geçirilen hastalıklar nedeniyle organlarında çeşitli tahribatları olan hastaların geçmiş raporları incelenerek aslında bu hasarların COVID-19 ile ilişkili olmadığı anlaşılabilir.

Araştırma ve anketler, doktorların serbest metin yerine yapılandırılmış metni tercih ettiğini ve doktorların bir kısmının raporların tamamını okumadığını göstermektedir. Uzun raporları okuması zordur ve önemli noktalar gözden kaçırılabilir. Uzun raporlar yerine sadece temel detayların yer aldığı özet bir rapor bu sorunu etkin bir şekilde ortadan kaldıracaktır.

Çalışmada tıbbi görüntüleme raporlarının otomatik özetlenmesi ve tanı ve tedavi sürecinde etkin bir şekilde kullanılması amaçlanmıştır.

Özetleme çalışmasında, Tıbbi Görüntüleme Merkezlerinden alınan 2457 tıbbi görüntüleme raporu kullanılmıştır. Tıbbi görüntüleme raporları genel olarak yapılandırılmamış, serbest metin türündedir. Bu tür veriler üzerinde çalışmayı kolaylaştırmak ve başarıyı artırmak için cümleleri kelimelerine ayırma, kelimelerin kökünü bulma ve anlama etki etmeyen kelimeleri cümleden çıkarma gibi bazı işlemlerden geçirilmiştir. Kelime modellenmeden önce sözdizimsel ve anlamsal olarak analiz edilmelidir. Önışlem ve analiz aşamalarında NLP yöntemleri kullanılmıştır. Kelime modellemede temel ve popüler kelime vektörleri kullanılmıştır. Word2Vec modeli başarılı sonuç vermiştir. Özetleme aşamasında farklı özetleme yaklaşımları ve algoritmaları kullanılmıştır. TF-IDF ve LSA hem kelimelerin analizinde hem de özetlemede için kullanılmıştır. TextRank ve derin öğrenme yöntemlerinden seq2seq mimarisine sahip LSTM algoritması ile özetleme çalışmaları yapılmıştır. Ayrıca, karşılaştırma ve olumsuzluk analizi dikkate alınarak başka bir özetleme çalışması daha yapılmıştır. Geliştirilen özetleme modellerinin başarısı literatürde yaygın ve başarılı bir şekilde kullanılan ROUGE metriği ile değerlendirilmiştir. ROUGE, sistem tarafından oluşturulan özetin insan tarafından oluşturulan özet ile karşılaştırmaktadır. Veri olarak toplanan Tıbbi görüntüleme raporlarında radyologların önemli kısımları özetlediği sonuç ve bazı raporlarda ayrıca not bölümü bulunmaktadır. Bundan dolayı, çalışmada elde edilen özetler, raporların sonuç ve not bölümüyle kıyaslanmıştır. Geliştirilen modellerde raporların sonuç bölümünde yer alan kritik bulgular, çalışmada elde edilen özetle de yer almıştır. Türkçe metin özetleme çalışmalarının yetersizliği, Türkçe NLP’de yaşanan zorluk, sağlık alanında özetleme çalışmalarına yönelik giderek artan ihtiyaç ve bu alanda veri kümesinin bulunmayışı çalışmayı önemli kılmaktadır. Kullanılan veri kümesinin gerçek verilerden toplanması ise çalışmanın özgünlüğünü göstermektedir.



KAYNAKLAR

1. Donnelly, L. F., Grzeszczuk, R., and Guimaraes, C. V. (2022, April). Use of Natural Language Processing (NLP) in Evaluation of Radiology Reports: An Update on Applications and Technology Advances. *Semin Ultrasound, CT MRI*, 43(2), 176-181.
2. Hark, C., Uckan, T., Seyyarer, E., and Karci, A. (2019, September). *Extractive Text Summarization via Graph*. 2019 International Artificial Intelligence and Data Processing Symposium (IDAP), 1-5.
3. Gündoğdu, Ö. E. ve Duru, N. (2016). *Türkçe Metin Özetlemede Kullanılan Yöntemler*. 18. Akademik Bilişim Konferansı-AB'16, 69-76.
4. Colby, K. M. (1975). *Artificial Paranoia: a Computer Simulation of Paranoid Processes*. (1st Edition). Oxford: Pergamon Press INC, 126.
5. Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Commun ACM*, 9(1), 36-45.
6. Shum, H., He, X., and Li, D. (2018). From Eliza to XiaoIce: challenges and opportunities with social chatbots. *Frontiers of Information Technology & Electronic Engineering*, 19, 10-26
7. Markelle, K., Longjohn, R., and Nottingham, K. The UCI Machine Learning Repository. URL: <https://archive.ics.uci.edu>. Son Erişim Tarihi: 10.09.2021.
8. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/>. Son Erişim Tarihi: 12.09.2021.
9. Ignácio, F. C. G. R., De Souza, L. R. M. F., D'Ippolito, G., and Garcia, M. M. (2018). Radiology report: what is the opinion of the referring physician?. *Radiologia Brasileira*, 51, 308-312.
10. Erdoğan, N., Baykara, M., Eren, C. S. ve Yeşildere, F. F. (2010). Radyoloji Raporlarının Değerini Artırmak İçin Kısa Bir Rehber. *Sağlık Bilimleri Tıp Dergisi*, 24(3), 209-214.
11. Feblowitz, J. C., Wright, A., Singh, H., Samal, L., and Sittig, D. F. (2011). Summarization of clinical information: A conceptual model. *Journal of Biomedical Informatics*, 44(4), 688-699.
12. Laxmisan, A., McCoy, A. B., Wright, A., and Sitting, D. F. (2012). Clinical Summarization Capabilities of Commercially available and Internally-developed Electronic Health Records. *Applied Clinical Informatics*, 3(1), 80-93
13. Weiss, D. L., and Bolos, P. R. (2009). *Practical Imaging Informatics*. New York: Springer, 147-162.
14. Arenas-Jiménez, J. J., Plasencia-Martínez, J. M., and García-Garrigós, E. (2021). When pneumonia is not COVID-19. *Radiologi'a*, 63(2), 180–192.

15. Shankar, V., and Parsana, S. (2022). An overview and empirical comparison of natural language processing (NLP) models and an introduction to and empirical application of autoencoder models in marketing. *Journal of the Academy of Marketing Science*, 50(6), 1324-1350,
16. Talan, T. ve Aktürk, C. (2021). *Bilgisayar Bilimlerinde Teorik Ve Uygulamalı Araştırmalar*. Efe Akademi Yayınları, 129-154.
17. Luhn, H. P. (1958). The Automatic Creation of Literature Abstracts. *IBM Journal*, 2(2), 159-165.
18. Edmundson, H. P. (1969). New Methods in Automatic Abstracting. *Journal of the ACM*, 16(2), 264-285.
19. Çöltekin, Ç., Doğruöz, A. S., and Çetinoğlu, Ö. (2023). Resources for Turkish natural language processing. *Lang Resources & Evaluation*, 57, 449-488.
20. Gürcan, F. (2018). *Multi-Class Classification of Turkish Texts with Machine Learning Algorithms*. 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), 1-5.
21. Amasyalı, M. F., and Diri, B. 2006. *Automatic Turkish text categorization in terms of author, genre and gender*. In International Conference on Application of Natural Language to Information Systems, 221-226.
22. Kuyumcu, B., Aksakalli, C., and Delil, S. (2019). *An automated new approach in fast text classification (fastText)*. Proceedings of the 2019 3rd International Conference on Natural Language Processing and Information Retrieval - NLPPIR 2019, 1-4.
23. Uzundere, E., Dedja, E., Diri, B. ve Amasyalı M. F. (2008). *Türkçe haber metinleri için otomatik özetleme*. Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu (ASYU), 1-4.
24. Hatipoğlu, A. ve Omurca, S. İ. (2015). Türkçe Metin Özetlemede Melez Modelleme. *Dokuz Eylül Üniversitesi Fen ve Mühendislik Dergisi*, 17(2), 95-108.
25. Kaynar, O., Işık, Y. E., Görmez, Y. ve Demirkoparan, F. (2017). Otomatik Metin Özetleme İçin Genetik Algoritma Tabanlı Cümle Çıkarımı. *Yönetim Bilişim Sistemleri Dergisi*, 3(2), 62-75.
26. Radev, D. R., and Fan, W. (2000). *Automatic summarization of search engine hit lists*. In ACL-2000 Workshop on Recent Advances in Natural Language Processing and Information Retrieval, 99-109.
27. Hark, C., Uckan, T., Seyyarer, E., and Karci, A., (2018). *Graph-Based Suggestion For Text Summarization*. 2018 International Conference on Artificial Intelligence and Data Processing (IDAP), 1-5.
28. Kyoomarsi, F., Khosravi, H., Eslami, E., and Davoudi, M. (2010). Extraction-based Text Summarization using Fuzzy Analysis. *Iranian Journal of Fuzzy Systems*, 7(3), 15-32.

29. Suanmali, L., Salem, M., Salim, B., and Salim, N. (2009). *Sentence Features Fusion for Text Summarization using Fuzzy Logic*. 2009 Ninth International Conference on Hybrid Intelligent Systems, IEEE, 142-14.
30. Rahimi, S. R., Mozhdehi, A. T., and Abdolahi, M. (2017). *An overview on extractive text summarization*. 2017 IEEE 4th International Conference on Knowledge-Based Engineering and Innovation (KBEI), 54-62.
31. El-Kassas, W. S., Salama, C. R., Rafea, A. A., and Mohammed, H. K. (2021). Automatic text summarization: A comprehensive survey. *Expert Systems with Applications*, 165.
32. Babar, S. A., and Patil, P. D. (2015). Improving Performance of Text Summarization. *Procedia Computer Science*, 354-363.
33. Gong, Y., Liu, X. (2001). *Generic text summarization using relevance measure and latent semantic analysis*. In: Proceedings of the 24th annual international ACM SIGIR conference on research and development in information retrieval, 19–25.
34. Suanmali, L., Salim, N., and Binwadhan, M. S. (2011). Genetic Algorithm Based Sentence Extraction For Text Summarization. *International Journal of Innovative Computing*, 1(1).
35. İnternet: Yang, L. (2016). Abstractive Summarization for Amazon Reviews. URL: <https://www.semanticscholar.org/paper/Abstractive-Summarization-for-Amazon-Reviews-Yang/ffc43c1264029c7fc655e190fcb34d079643f34c>. Son Erişim Tarihi: 11.04.2021.
36. Zhang, Y., Li, D., Wang, Y., Fang, Y., and Xiao, W. (2019). Abstract Text Summarization with a Convolutional Seq2seq Model. *Applied Sciences*, 9(8), 1665.
37. Song, S., Huang, H., and Ruan, T. (2018). Abstractive text summarization using LSTM-CNN based deep learning, *Multimedia Tools and Applications*.
38. Muhammad, P. F., Kusumaningrum, R., and Wibowo, A. (2021). Sentiment Analysis Using Word2vec and Long Short-Term Memory (LSTM) For Indonesian Hotel Reviews. *Procedia Computer Science*, 179, 728–735.
39. Toplu, S. Cangur, S. (2020). Text Mining Method in the Field of Health. *Konuralp Tıp Dergisi*, 12(2), 236-246.
40. Kocatekin, T., and Unay, D. (2013). *Text mining in radiology reports*. 2013 21st Signal Processing and Communications Applications Conference (SIU), 1-4.
41. Soysal, E., Çiçekli, İ. ve Baykal, N. (2009). *Radyoloji Raporları için Türkçe Bilgi Çıkarım Sistemi*. Proc. Ulusal Tıp Bilişim Kongresi.

42. Zhang, Y., Ding, D. Y., Qian, T, Manning, C. D., and Langlotz, C. P. (2018). *Learning to Summarize Radiology Finding*. EMNLP 2018 Workshop on Health Text Mining and Information Analysis.
43. MacAvaney, S., Sotudeh, S., Cohan, A., Goharian, N., Talati, I., and Filice, R. W. (2019). *Ontology-Aware Clinical Abstractive Summarization*. SIGIR'19: Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 1013-1016.
44. Kim, Y., Lee, J. H., Choi, S., Lee, J. M., Kim, J. H., Seok, J., and Joo, H. J. (2020). Validation of deep learning natural language processing algorithm for keyword extraction from pathology reports in electronic health records. *Scientific Reports*, 10(1), 20265.
45. Bozkurt, S., Alkim, E., Banerjee, I., and Rubin, D. L. (2019). Automated Detection of Measurements and Their Descriptors in Radiology Reports Using a Hybrid Natural Language Processing Algorithm. *Journal of Digital Imaging*, 32, 544–553.
46. Küçük, D. ve Arıcı, N. (2018), Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması, *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 2(2), 76-86.
47. Hovy, E., Lin, C. Y. (1998). *Automated text summarization in summarist*. Annual Meeting of the ACL Proceeding of a Workshop.
48. Zhang, Y., Jin, R. Zhou, Z. H. (2010). Understanding bag-of-words model: A statistical framework. *International Journal of Machine Learning and Cybernetics*, 1(1), 43-52.
49. Aizawa, A. (2003). An information-theoretic perspective of tf-idf measures. *Information Processing & Management*, 39(1), 45-65.
50. Zhang, W., Yoshida, T., and Tang, X. (2011). A comparative study of TF*IDF, LSI and multi-words for text classification. *Expert Systems with Applications*, 38(3), 2758-2765.
51. Sharma, A. K., Chaurasia, S., and Srivastava, D. K. (2020). Short Sentences Classification by Using CNN Deep Learning Model with Fine Tuned Word2Vec. *Procedia Computer Science*, 167, 1139-1147.
52. Mikolov, T., Chen, K., Corrado, G., and Dean, J. (2013). *Efficient Estimation of Word Representations in Vector Space*. Proceedings of Workshop at ICLR.
53. Pennington, J., Socher, R., and Manning, C. (2014). *GloVe: Global Vectors for Word Representation*. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 1532–1543.
54. Evangelopoulos, N., Zhang, X., and Prybutok, V. (2012). Latent Semantic Analysis: five methodological recommendations. *European Journal of Information Systems*, 21, 70–86.

55. Mihalcea, R., Paul Tarau, P. (2004). *TextRank: Bringing Order into Text*. In Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing, 404–411.
56. Erkan, G., Radev, D. R. (2004). LexRank: Graph-based lexical centrality as salience in text summarization. *Journal of Artificial Intelligence Research*, 22, 457–479.
57. Zhang Y, Xiao W. (2018) Keyphrase Generation Based on Deep Seq2seq Model. *In IEEE Access*, 6, 46047-46057.
58. İnternet: Olah, C. (2015). Understanding LSTM Networks. URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>. Son Erişim Tarihi: 10.05.2022.
59. Lin, C. Y., Hovy, E. (2002). *Manual and Automatic Evaluation of Summaries*. *Proceedings of the Workshop on Automatic Summarization (including DUC 2002)*, 45–51.
60. Radev, D., Allison, T., Blair-Goldensohn, S., Blitzer, J., Çelebi, A., Dimitrov, S., Drabek, E., Hakim, A., Lam, W., Liu, D., Otterbacher, J., Qi, H., Saggion, H., Teufel, S., Topper, M., Winkel, A., and Zhang, Z. (2004). *MEAD - A Platform for Multidocument Multilingual Text Summarization*. In Proceedings of the Fourth International Conference on Language Resources and Evaluation (LREC'04).
61. Rahutomo, F., Kitasuka, T., and Aritsugi, M. (2012). *Semantic cosine similarity*. In The 7th International Student Conference on Advanced Science and Technology ICAST, 4(1), 1.



Gazili olmak ayrıcalıktır