

TÜRKÇE SAĞLIK SOHBET BOTLARINDA SBERT, CLAUDE VE GEMINI
BÜYÜK DİL MODELLERİNİN PERFORMANS METRİKLERİ ÜZERİNDEN
ANALİTİK KARŞILAŞTIRILMASI

KOCAELİ SAĞLIK VE TEKNOLOJİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MUSTAFA SALICI

YÜKSEK LİSANS TEZİ
BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

01/2025

ONAY SAYFASI

Bu tez Kocaeli Sağlık ve Teknoloji Üniversitesi Lisansüstü Eğitim Enstitüsü tarafından onaylanmıştır.

Prof. Dr. Yurdanur DİKMEN
Enstitü Müdürü

Bu tezin Kocaeli Sağlık ve Teknoloji Üniversitesi, Bilişim Sistemleri Mühendisliği Yüksek Lisans derecesinin tüm gerekliliklerini karşıladığını onaylıyorum.

Dr. Öğr. Üyesi Mehmet KARA
Bölüm Başkanı

MUSTAFA SALICI tarafından teslim edilen TÜRKÇE SAĞLIK SOHBET BOTLARINDA SBERT, CLAUDE VE GEMINI BÜYÜK DİL MODELLERİNİN PERFORMANS METRİKLERİ ÜZERİNDEN ANALİTİK KARŞILAŞTIRILMASI başlıklı bu tezin kapsam ve kalite bakımından Yüksek Lisans derecesi için yeterli olduğunu değerlendirmektedir.

Dr. Öğr. Üyesi Ercan ÖLÇER
Danışman

Tez Jürisi Üyeleri: (1. isim: Jüri başkanı; 2. isim: Danışman)

Prof. Dr. Nevcihan DURU

Mühendislik ve Doğa Bilimleri Fakültesi, Kocaeli Sağlık ve Teknoloji Üniversitesi

Dr. Öğr. Üyesi Ercan ÖLÇER

Mühendislik ve Doğa Bilimleri Fakültesi, Kocaeli Sağlık ve Teknoloji Üniversitesi

Dr. Öğr. Üyesi MELTEM KURT PEHLİVANOĞLU

Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kocaeli Üniversitesi

Tarih: 07/01/2025

İşbu belge ile tezimde yer alan tüm bilgilerin akademik ve etik kurallara uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, kurallar gereği bu çalışmada özgün olmayan tüm materyal ve sonuçlar için ilgili kaynakların verildiğini beyan ederim.

Mustafa Salıcı

İmza:

X X X X

ABSTRACT
ANALYTICAL COMPARISON OF SBERT, CLAUDE AND GEMINI LARGE
LANGUAGE MODELS ON TURKISH HEALTH CHAT BOTS VIA
PERFORMANCE METRICS

Salıcı, Mustafa

Degree, Faculty of Engineering and Natural Sciences

Supervisor : Asst. Prof. Ercan ÖLÇER

December 2024, 52 pages

In this study, the applicability of Large Language Models (LLM) in Turkish healthcare chatbots was investigated. The performance of SBERT, Claude and Gemini models for chatbot applications in the healthcare field was evaluated comparatively. Considering the unique morphological difficulties of the Turkish language, the ability of these models to produce context-adaptive responses was tested. In the study, performance metrics such as accuracy, precision, sensitivity and F1 score of the models were compared and inferences were made based on these metrics. The findings showed that large language models offer a strong potential in terms of user satisfaction and information accuracy in Turkish healthcare chatbots. However, due to the structural features of the language, optimization and customization processes were seen to be of great importance. In this direction, methods that will increase performance were proposed for future studies. The thesis aims to contribute to the development of Turkish healthcare chatbots and to determine the limitations of large language models in this area.

Keywords: SBERT, Claude, Gemini, Healthcare Chatbot, Turkish NLP

ÖZ

TÜRKÇE SAĞLIK SOHBET BOTLARINDA SBERT, CLAUDE VE GEMINI BÜYÜK DİL MODELLERİNİN PERFORMANS METRİKLERİ ÜZERİNDEN ANALİTİK KARŞILAŞTIRILMASI

Salıcı, Mustafa

Yüksek Lisans, Mühendislik ve Doğa Bilimleri Fakültesi

Tez Yöneticisi: Dr. Öğr. Üyesi Ercan ÖLÇER

Aralık 2024, 52 sayfa

Bu çalışmada, büyük dil modellerinin (Large Language Models-LLM) Türkçe sağlık sohbet botlarında uygulanabilirliği incelenmiştir. SBERT, Claude ve Gemini modellerinin sağlık alanındaki chatbot uygulamaları için sunduğu performans karşılaştırmalı olarak değerlendirilmiştir. Türkçe dilinin kendine özgü morfolojik zorlukları dikkate alınarak, bu modellerin bağlam uyumlu yanıt üretme yetenekleri test edilmiştir. Çalışmada, modellerin doğruluk, kesinlik, duyarlılık ve F1 skoru gibi performans metrikleri karşılaştırılmış ve bu metrikler üzerinden çıkarımlar yapılmıştır. Bulgular, büyük dil modellerinin Türkçe sağlık chatbotlarında kullanıcı memnuniyeti ve bilgi doğruluğu açısından güçlü bir potansiyel sunduğunu göstermiştir. Ancak, dilin yapısal özellikleri nedeniyle optimizasyon ve özelleştirme süreçlerinin büyük bir öneme sahip olduğu görülmüştür. Bu doğrultuda, gelecekteki çalışmalar için performansını artıracak yöntemler önerilmiştir. Tez, Türkçe sağlık chatbotlarının geliştirilmesine katkı sağlamayı ve büyük dil modellerinin bu alandaki sınırlılıklarını belirlemeyi amaçlamaktadır.

Anahtar Kelimeler: SBERT, Claude, Gemini, Sağlık Chatbot'u, Türkçe NLP

TEŐEKKÜR

Bu alıőmanın her aőamasında ve ayrıntısında sonsuz emeęi olan, motive edici ve pozitif yaklaőımıyla alıőmayı tamamlamamı saęlayan deęerli tez danıőmanım Dr. Öğr. Üyesi Ercan ÖLÇER'e en derin őükranlarımı sunarım. Eğitim hayatım boyunca küçük yaőlarımdan itibaren her zaman destek olan rahmetli babam Ercan SALICI ve deęerli annem Süheyla SALICI'ya, hayatımın her alanında desteęini hissettięim ve akademik yolculuęumun baőlamasına vesile olan kıymetli eőim őeyma CANURAL SALICI'ya teőekkürlerimi sunmak boynumun borcudur.

Aralık 2024

Mustafa SALICI

İÇİNDEKİLER

ABSTRACT	iv
ÖZ	v
TEŞEKKÜR	vi
TABLO LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	x
GİRİŞ	1
BÖLÜM 1 TEZİN AMACI.....	3
1.1 TEZİN KATKISI	3
1.2 TEZİN ANA HATLARI	4
BÖLÜM 2 KURAMSAL ÇERÇEVE.....	7
2.1 NLP'DE İLK MODELLERDEN GÜNÜMÜZE.....	9
2.2 DERİN ÖĞRENMENİN DİL MODELLERİNDEKİ ROLÜ	12
2.3 DÖNÜŞTÜRÜCÜ MİMARİSİ VE DİKKAT MEKANİZMASININ MODERN DİL MODELLERİNDEKİ ROLÜ	14
2.4 BERT'İN BAĞLAMI ÇİFT YÖNLÜ ANALİZ ETME YETENEĞİ.....	17
2.5 GPT'NİN GELİŞİM SÜRECİ.....	20
2.6 CLAUDE ve YAPAY ZEKA GELİŞİMİNDE YENİ BİR YAKLAŞIM.....	23
2.7 GEMINI YAPISAL ÖZELLİKLERİ VE CHATBOT'LARDAKİ DÖNÜŞÜM SÜRECİ.....	25
2.8 BÜYÜK VERİ SETLERİ İLE EĞİTİLMİŞ MODELLERİN KONFIGÜRASYONU VE CHATBOTLARDA KULLANIMI.....	26
2.9 DİL MODELLERİNDE ÖLÇEKLENEBİLİRLİK VE BÜYÜK VERİ KÜMELERİYLE ETKİLEŞİM.....	30

2.10 TRANSFER LEARNING'İN DİL MODELLERİNDE ENTEGRASYONU....	31
BÖLÜM 3 İLGİLİ ÇALIŞMALAR	34
3.1 BERT İLE GELİŞTİRİLEN CHATBOT'LARIN SAĞLIK SEKTÖRÜNDEKİ UYGULAMALARI.....	34
3.2 CLAUDE İLE GELİŞTİRİLEN CHATBOT'LARIN SAĞLIK SEKTÖRÜNDEKİ UYGULAMALARI	37
3.3 GEMINI İLE GELİŞTİRİLEN CHATBOT'LARIN SAĞLIK SEKTÖRÜNDEKİ UYGULAMALARI.....	39
BÖLÜM 4 TÜRKÇE CHATBOT TASARIMINDA SBERT, CLAUDE VE GEMINI	40
4.1 SBERT VE BERT MODELLERİNİN CÜMLE TEMSİLİ VE ANLAMLANDIRMA ÜZERİNE FARKLILIKLARI	40
4.2 NLP SÜREÇLERİNDE CLAUDE VE GEMINI KULLANIMI	43
4.3 SBERT, CLAUDE VE GEMİNİ API İLE TÜRKÇE CHATBOTLARDA BAĞLAM UYUMLU YANITLAR.....	44
4.4 NLP'DE TÜRKÇE DİLİNİN MORFOLOJİK ZORLUKLARI	44
4.5 NLP İLE ANLAMLANDIRILMIŞ VERİ ANALİZİ VE CHATBOT TASARIMI	49
4.6 KÜTÜPHANELER, VERİ İŞLEME VE HAZIRLIK.....	50
4.7 GÖMÜLÜ VEKTÖRLERİN OLUŞTURULMASI VE YORUMLARIN ANALİZİ.....	52
4.8 YANIT SİSTEMİ	54
BÖLÜM 5 SONUÇ, TARTIŞMA VE ÖNERİLER.....	64
KAYNAKÇA.....	68

TABLO LİSTESİ

TABLolar

Tablo 1 Model bazlı Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri.....	65
Tablo 2 Model Bazlı Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru Metrikleri.....	66



ŞEKİL LİSTESİ

ŞEKİLLER

Şekil 1.1 Sağlık Alanında Yapılan Bir Chatbot Mimarisi	9
Şekil 2.1 İngilizce'den Çince'ye Decode-Encode İşlemi Mimarisi	10
Şekil 2.2 CBOW ve Skip-gram Mimarisi	11
Şekil 2.3 Son Altı Yılda ACL, EMNLP, EACL ve NAACL Gibi NLP Konferanslarında Yayımlanan Derin Öğrenme Temelli Makalelerin Yüzdesel Dağılımı	12
Şekil 2.4 Dönüştürücü Mimarisi.....	15
Şekil 2.5 Dikkat Mekanizması Dağılımı.....	16
Şekil 2.6 Dikkat Mekanizması Örüntüsü	17
Şekil 2.7 BERT'in Eğitim Sürecinde MLM Stratejisi	18
Şekil 2.8 Stokastik Katman Seçimi Tekniği.....	20
Şekil 2.9 İnce Ayar Yapılmış BERT Sonuçları	21
Şekil 2.10 GPT-4 ve Claude v1.3'ün Davranışı	23
Şekil 2.11 Ablation Çalışması Akış Şeması	27
Şekil 2.12 Spade Mimarisi	29
Şekil 2.13 NLP Alanında En Gelişmiş Modellerin Yıllara Göre Gelişimi	30
Şekil 2.14 Adaptör Mimarisi Eklenen ve Eklenmeyen BERT Modellerinin, Farklı Rastgele Başlangıçlarda Elde Edilen Doğruluk Skorlarının Dağılımı.....	32
Şekil 3.1 İlaç İncelemeleri Üzerine Yapılan Duygu Analizinde Kullanılan Modellerin Confusion Matrisleri	35
Şekil 3.2 LSTM ve BERT Modellerinin Küçük Bir Veri Seti Üzerindeki Test Setindeki Doğruluk Oranları	36
Şekil 3.3 ChatGPT, Claude ve Bard'ın Karşılaştırması.....	37
Şekil 3.4 ChatGPT-3,5, Copilot ve Gemini'nin İngilizce ve Türkçe Soruları Doğru Cevaplama Düzeyleri.....	39
Şekil 4.1 BERT Diyagramı.....	41
Şekil 4.2 SBERT Diyagramı.....	42

Şekil 4.3 Bankacılık Sektörüne Özgü Closed-Domain BERT Tabanlı Türkçe Soru Cevaplama Sisteminin Eğitim ve Fine Tuning Aşamaları	45
Şekil 4.4 Ortak Öğrenme Çerçevesinin Katmanları - Cümlelerin Morfolojik Segmentasyon, Morfolojik Etiketleme, İsimlendirilmiş Varlık Tanıma ve Bağımlılık Çözümü	47
Şekil 4.5 Bilgi Grafiklerini Kullanarak Çoklu Atlama (Multihop) Soru Cevaplama Mimarisi	48
Şekil 4.6 Teze Dair Kod Şeması	50
Şekil 4.7 Koda dair kütüphaneler	51
Şekil 4.8 Veri setine dair bir kesit	51
Şekil 4.9 Yorum ve ürün bilgilerini çıkartan fonksiyon	52
Şekil 4.10 Gömülü vektörleri oluşturan fonksiyon	52
Şekil 4.11 En uygun yorumları bulan fonksiyon	53
Şekil 4.12 Ürün veya marka içeriği var mı kontrolü yapan fonksiyon	53
Şekil 4.13 Sorunun anlamını analiz eden fonksiyon	54
Şekil 4.14 SBERT sorgu fonksiyonu	62
Şekil 4.15 Gemini sorgu fonksiyonu	62
Şekil 5.1 SBERT için örnek yanıt	64
Şekil 5.2 Gemini için örnek yanıt	64
Şekil 5.3 Claude için örnek yanıt	64
Şekil 5.4 Model Bazlı Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru Metrikleri	66



SEMBOL/KISALTMA LİSTESİ

AI	Yapay Zeka
BERT	Bidirectional Encoder Representations from Transformers
CBOW	Continuous Bag of Words
CCM	Concept-based Curriculum Masking
CNN	Convolutional Neural Networks
GPT	Generative Pre-trained Transformer
LLM	Large Language Model
LSTM	Long Short-Term Memory
MLM	Maskeli Dil Modelleme
MT	Machine Translation
NLP	Natural Language Processing
NSP	Sonraki Cümle Tahmini
PLM	Önceden Eğitilmiş Dil Modeli
RNN	Recurrent Neural Networks

GİRİŞ

Son yıllarda yapay zeka ve NLP (Natural Language Processing) alanlarında kaydedilen büyük gelişmeler, sağlık sektörü başta olmak üzere birçok sektörde köklü bir dönüşüm yaratmıştır. Yapay zekâ teknolojileri, özellikle dil modelleri ve chatbot uygulamaları aracılığıyla insan'la makine etkileşimlerini daha doğal ve verimli hale getirerek bilgiye erişimi hızlandırmaktadır. Bu gelişim, büyük veri setleri ile eğitilen ve derin öğrenme teknikleriyle güçlendirilmiş modellerin, çok boyutlu karmaşık dil yapılarını anlamada ve işlemede oldukça başarılı sonuçlar elde etmesiyle mümkün hale gelmiştir. Yapay zeka destekli chatbot'lar artık sadece metin tabanlı yanıtlar vermekle kalmamakta. Bağlamsal, anlam temelli ve çok yönlü bilgi sunabilen, hatta duygusal etkileşim kurabilen ileri seviyede sistemlere dönüşmektedir.

Bu tez çalışması, LLM'in (Large Language Model) sağlık sektöründe chatbot uygulamaları aracılığıyla nasıl değerlendirilebileceğini ve bu modellerin sağlık hizmetlerinin sunumunda nasıl bir rol oynayabileceğini incelemektedir. Sağlık alanındaki chatbot'lar, doktorlar, hastalar ve genel kullanıcılar için bilgiye hızlı erişim sağlarken, doğru ve güvenilir bilgiyi sunma gerekliliği ile diğer alanlardaki uygulamalardan ayrılmaktadır. Örneğin, Claude, BERT, GPT ve Gemini gibi ileri seviye dil modelleri, sağlık sektörü özelinde hastaların ihtiyaçlarına göre özelleştirilmiş yanıtlar sağlayabilmekte ve kullanıcı deneyimini güçlendirmektedir. Ancak, bu chatbotların başarısı, dil modellerinin karmaşık tıbbi sorulara yanıt verme, semptom değerlendirme ve kullanıcıyla bağlam uyumlu bir iletişim kurabilme kapasitesi ile doğrudan ilişkilidir.

Chatbot uygulamaları, bilgiye erişim sürecinde devrim niteliğinde yenilikler sunmaktadır. Özellikle sağlık sektöründe bilgi ve danışmanlık hizmetlerine duyulan ihtiyaç göz önüne alındığında, bu chatbot'lar kullanıcılar için birer rehber işlevi görmektedir. Kullanıcıların tıbbi sorularına hızlı ve doğru yanıtlar sunarak, hasta ve sağlık çalışanları arasındaki bilgi alışverişini güçlendiren bu sistemler, tıbbi bilginin daha erişilebilir ve güvenilir bir şekilde sunulmasına olanak tanır. Ancak bu alanda başarılı bir performans gösterebilmek, dil modellerinin dilin inceliklerine hakim olmasını, tıbbi terminolojiyi anlamasını ve dilin yapısal özelliklerine göre adapte

olabilmesini gerektirmektedir. Bu nedenle, NLP modellerinin sađlık sekt6r6nde uygulanabilirliđi olduka zorlu ve karmařık bir s6retir.

alıřma, sađlık sekt6r6nde chatbot uygulamaları aracılıđıyla dil modellerinin deđerlendirilmesine odaklanmaktadır. Claude, BERT ve Gemini gibi ileri d6zey modellerin T6rke chatbot tasarımlarında sunduđu katkılar, bađlam uyumlu yanıt verme yetenekleri, kullanıcı ihtiyalarını karřılama kapasiteleri ve tıbbi bilgiye eriřim s6recini hızlandırmaları incelenecektir. Bu modellerin T6rke'nin kendine 6zg6 zorlu morfolojik yapısına uygun olarak optimize edilmesi, kullanıcı ihtiyalarını karřılamak iin bađlam uyumlu yanıtlar sunabilmesi gerekmektedir. 6zellikle sađlık sekt6r6nde dođruluk, g6venilirlik ve hız gibi fakt6rlerin b6y6k 6nem tařıması, chatbot uygulamalarının titizlikle tasarlanmasını ve test edilmesini gerektirir.

Bu bađlamda alıřmanın amacı, sađlık alanındaki chatbot uygulamaları iin NLP modellerinin katkılarını ve sınırlarını incelemektir. T6rke'deki dil yapısı ve morfolojik zorluklar, chatbot tasarım s6recinde 6zel bir dikkat gerektirirken; sađlık sekt6r6nde Claude, BERT ve GPT gibi modellerin etkinliđinin belirlenmesi, kullanıcı memnuniyeti ve dođruluk aısından 6nemli ipuları sunacaktır. Bu alıřma, chatbot uygulamalarının sađlık sekt6r6nde tıbbi bilginin dođrulukla sunulması, hasta memnuniyeti ve hızlı bilgi eriřimi konularında katkı sađlamasını amalamaktadır. Ayrıca, yapay zekâ destekli chatbotların g6venilirliđini ve sađladıđı yararları tartıřarak, literat6rdeki bořlukları doldurmayı hedeflemektedir.

BÖLÜM 1 TEZİN AMACI

Bu çalışmanın temel amacı, yapay zekâ destekli LLM'lerin sağlık sektöründe chatbot uygulamaları olarak kullanımını incelemek ve bu uygulamaların sağlık hizmetlerinde sağladığı katma değeri değerlendirmektir. Günümüzde Claude, BERT ve Gemini gibi ileri seviye dil modelleri, NLP teknikleri kullanılarak sağlık alanında giderek artan bir şekilde uygulanmaktadır. Çalışmada bu modellerin farklı görevlerdeki başarı oranları, kullanıcı deneyimi ve sağlık alanına özel ihtiyaçları karşılayabilme kapasitesi henüz tam anlamıyla araştırılmıştır. Bu nedenle çalışmamız sağlık sektörü için özelleştirilmiş chatbot tasarımında, büyük dil modellerinin sağladığı avantajları ve karşılaştıkları zorlukları belirlemeyi amaçlamaktadır. Böylelikle, kullanıcılar için daha erişilebilir ve güvenilir sağlık hizmetlerinin sunulmasına katkı sağlayacak bir model önerisi geliştirilecektir.

Bu çalışmada, büyük dil modellerinin Türkçe dilinde sağlık odaklı bir chatbot sistemi geliştirmedeki performansları değerlendirilecektir. Çalışma kapsamında Claude, BERT ve GPT gibi modellerin Türkçe dilinde chatbot yanıtlarını üretme, bağlama uygun ve anlamlı sonuçlar sunma yetenekleri detaylı bir şekilde incelenecektir. Türkçe'nin kendine özgü morfolojik yapısı, eklemeli dil yapısı ve zengin bağlamsal yapısı, chatbot tasarımı ve dil işleme süreçlerinde çeşitli zorluklar yaratmaktadır. Çalışmanın amacı, bu modellerin Türkçe dilindeki özelliklere uygun hale getirilmesi için gereken optimizasyonları ve özelleştirme yöntemlerini belirlemektir. Özellikle sağlık sektöründeki dil ihtiyaçlarına yönelik çözümler sunan bu chatbotlar, hem hasta hem de doktorlar için bilgiye hızlı ve güvenilir bir şekilde ulaşılmasını sağlayacak şekilde yapılandırılmalıdır.

1.1 TEZİN KATKISI

Bu tez NLP ve sağlık sektöründe chatbot tasarımı konularında literatüre katkıda bulunmaktadır. LLM'lerin Türkçe gibi eklemeli bir dildeki performansına dair veri sunarak, sağlık sektörü özelinde dil modellerinin başarısını değerlendirmek literatürde önemli bir boşluğu dolduracaktır. Claude, BERT ve GPT gibi modeller, özellikle İngilizce dilinde yaygın olarak test edilip uygulanmakta, ancak Türkçe gibi yapısal açıdan farklı ve karmaşık dillere yönelik uygulamalar konusunda henüz yeterince kaynak bulunmadığı gözlemlenmiştir. Bu çalışmada, dil modellerinin Türkçe'nin

morfolojik yapısına uygun hale getirilmesi ve sađlık alanına özel terimlerle zenginleřtirilmesi üzerine bir analiz sunulacaktır. Bylece, Trke dilindeki sađlık chatbotları iin byk dil modellerinin optimizasyon sreci hakkında deđerli bilgiler sađlanacaktır.

Bu alıřma sađlık sektrnde chatbot kullanımının kullanıcı memnuniyeti, eriřilebilirlik, bađlam uyumlu yanıt retme yeteneklerini gzleme, sađlık sektr zelinde sahip olduđu dođruluk, gvenilirlik performansı ve Trke dilinde sađlık alanında yapay zeka ve NLP teknolojilerinin uygulama alanlarını geniřletmeyi amalayarak sađlık sektrndeki dijitalleřme srecine de katkıda bulunmayı hedeflemektedir.

1.2 TEZİN ANA HATLARI

Bu tez, giriřten sonu ve nerilere kadar sistematik olarak ilerleyerek konunun eřitli ynlerini derinlemesine incelemektedir. Tezin her bir blm, konunun temel bileřenlerini detaylandırmak ve hedeflenen arařtırma sorularını kapsamlı bir şekilde yanıtlamak iin zenle yapılandırılmıřtır. Bu blmde, alıřmanın ana hatları ve her blmn ierik kapsamı ayrıntılı olarak sunulmaktadır.

Tezin giriř blmnde, alıřmanın genel erevesi, alıřmanın motivasyonu, arařtırma soruları ve alıřmanın nemi ele alınmaktadır. Yapay zekâ ve NLP teknolojilerinin sađlık sektrnde kullanımının neden giderek nem kazandıđına dair genel bir bakıř sunulmakta, dil modellerinin bu alandaki katkı potansiyeli belirtilmektedir. Ayrıca, bu blmde tezin yapısı hakkında genel bilgi verilerek, her bir blmn ierik ve hedefleri zetlenmektedir.

Tezin amacı, katkısı ve ana hatları bařlıđını tařıyan ilk blmde, alıřmanın amacı ve bu amaca ynelik olarak geliřtirilmesi hedeflenen arařtırma erevesi detaylandırılmaktadır. Bu blmde, alıřmanın literatre ve uygulamaya sađladıđı katkılar aıklanmakta, Trke dilinde sađlık chatbotlarının kullanıcı memnuniyeti, bilgi dođruluđu ve eriřim kolaylıđı gibi alanlarda sađlayabileceđi avantajlar ele alınmaktadır. Ek olarak, dil modellerinin Trke gibi eklemeli bir dilde karřılařabileceđi morfolojik zorlukların, sađlık sektr bađlamında nasıl stesinden gelinebileceđi zerinde durulmaktadır.

Kuramsal ereve blmnde, alıřmanın temelini oluřturan kuramsal arka plan aıklanmaktadır. Bu blmde NLP ve yapay zekâ teknolojilerinin tarihsel

gelişiminden başlayarak, BERT, Claude, GPT ve Gemini gibi dil modellerinin modern chatbot uygulamalarındaki rolü üzerinde durulmaktadır. NLP alanındaki son gelişmeler ışığında dil modellerinin, sağlık sektörü gibi bağlamsal doğruluğun önemli olduğu alanlarda nasıl işlevselleştirilebileceği tartışılmaktadır. Kuramsal çerçeve bölümünde ayrıca, Türkçe dilinin yapısal özellikleri ve sağlık sektörü bağlamında chatbot uygulamalarının başarılı olabilmesi için gereken dil işleme teknikleri ayrıntılı olarak incelenmektedir.

İlgili çalışmalar bölümünde, sağlık sektöründe yapay zekâ destekli chatbot uygulamalarına dair literatürde mevcut çalışmalar ve bu çalışmaların sunduğu bulgular gözden geçirilmektedir. Bu bölümde, çalışmadaki büyük dil modellerinin sağlık sektöründeki uygulama örnekleri ele alınmakta, özellikle Türkçe chatbot uygulamaları için NLP ve derin öğrenme tekniklerinin başarısını artırmak adına önerilen yöntemler analiz edilmektedir. Ayrıca, sağlık alanında Claude ve GPT gibi modellerin bağlamsal doğruluğunu artırmak için geliştirilen çözümler ve uygulama süreçleri değerlendirilmektedir. Bu bağlamda, sağlık sektörü ve diğer alanlarda yapılmış çalışmaların sonuçları kıyaslanarak, çalışmanın araştırma sorularını destekleyen veriler elde edilmektedir.

Türkçe Chatbot Tasarımında SBERT, Claude ve Gemini başlıklı bölüm, tez çalışmasının deneysel kısmını oluşturmaktadır. Bu bölümde, Türkçe dilinde bir chatbot geliştirme süreci için SBERT, Claude ve Gemini modellerinin uygulanabilirliği ele alınmakta ve Türkçe'nin kendine özgü dil özellikleri dikkate alınarak optimizasyon süreçleri detaylandırılmaktadır. LLM'lerin Türkçe chatbot yanıtlarını doğru bir şekilde anlamlandırma ve bağlam uyumlu cevaplar sunma yetenekleri üzerine bir inceleme yapılmaktadır. Ayrıca, sağlık sektörü özelinde Claude ve GPT gibi modellerin bağlama dayalı yanıt verebilme kapasiteleri değerlendirilmektedir. Sağlık sektöründe bağlam uyumlu cevap verme gerekliliği ve ilgili chatbotların kullanıcı taleplerini karşılayabilmesi için dil modellerinin gerektirdiği optimizasyon süreçleri detaylandırılmaktadır. Bu bölümde ayrıca chatbot performansını artırma yolları üzerinde de durulmaktadır.

Sonuç, tartışma ve öneriler başlıklı bölüm, çalışmanın bulgularının kapsamlı bir değerlendirmesini içermektedir. Bu bölümde, yapılan analizlerin sonuçları özetlenmekte, bulguların sağlık sektöründe yapay zekâ destekli chatbot uygulamaları

açısından taşıdığı önem açıklanmaktadır. Ayrıca, tezde kullanılan LLM'lerin sağlık sektöründeki uygulama potansiyelleri ve sınırlılıkları ayrıntılı olarak tartışılmaktadır. Tezin sonuç bölümünde, büyük dil modellerinin sağlık sektöründe daha etkin kullanılabilmesi için geliştirilebilecek stratejiler önerilmekte ve gelecekteki araştırmalara yön verebilecek fikirler sunulmaktadır. Sağlık sektörü gibi hassas alanlarda chatbot kullanımı ile ilgili olarak güvenlik ve gizlilik gibi kritik konulara yönelik öneriler de bu bölümde ele alınmaktadır.



BÖLÜM 2 KURAMSAL ÇERÇEVE

Chatbot'lar, günümüz dijital dünyasında hızla büyüyen ve gelişen bir teknoloji olarak dikkat çekmektedir. Bu teknolojiler, başlangıçta sadece belirli kurallara dayalı metin tabanlı yanıtlar veren basit sistemler iken, yapay zekâ (AI) ve doğal dil işleme (NLP) alanındaki ilerlemeler sayesinde bugün çok daha karmaşık hale gelmişlerdir. Özellikle büyük dil modellerinin (LLM) ve derin öğrenme tekniklerinin devreye girmesi, chatbot'ların insan benzeri diyaloglar kurabilmesini sağlamıştır. Bu gelişim sürecinde, BERT (Bidirectional Encoder Representations from Transformers), Claude, GPT-4, ve Google DeepMind'in Gemini gibi yapay zeka motorları önemli rol oynamaktadır [1].

Chatbot'ların işlevselliği, ilk nesil kurallara dayalı sistemlerden büyük dil modellerine geçişle kökten bir değişim göstermiştir. Özellikle BERT, karmaşık dil yapılarını anlama ve işleme kapasitesinde önemli bir devrim yaratmıştır [2]. BERT, çift yönlü dil modelleri ile dilin anlamını daha iyi kavrayabilen ve daha doğru yanıtlar üretebilen bir yapı sunmaktadır. Bu teknoloji, chatbot'ların kullanıcılarla daha doğal ve bağlama dayalı etkileşimler kurmasını sağlayarak, çeşitli sektörlerde kullanımını genişletmiştir. Örneğin, finans ve müşteri hizmetleri gibi alanlarda chatbot'lar, insanların sorularına doğru yanıtlar vererek iş süreçlerini optimize etmektedir [3].

Claude ve GPT-4 gibi daha gelişmiş modeller, yapay zekâ teknolojilerinin sınırlarını zorlayarak özellikle tıp ve bilimsel araştırmalar gibi karmaşık alanlarda daha derinlemesine analizler yapabilmektedir. Wu ve arkadaşlarının yaptığı çalışma, Claude'un, GPT-4'e kıyasla tıp sorularını yanıtlama ve açıklama kapasitesinin oldukça güçlü olduğunu göstermiştir [4]. Benzer şekilde, ChatGPT ve Claude'un karşılaştırıldığı başka bir araştırmada, Claude'un karmaşık tıbbi sorulara daha doğru yanıtlar verdiğini ortaya koymuştur [5]. Bu tür gelişmeler, büyük dil modellerinin eğitim ve sağlık gibi alanlardaki potansiyel kullanımını artırmıştır.

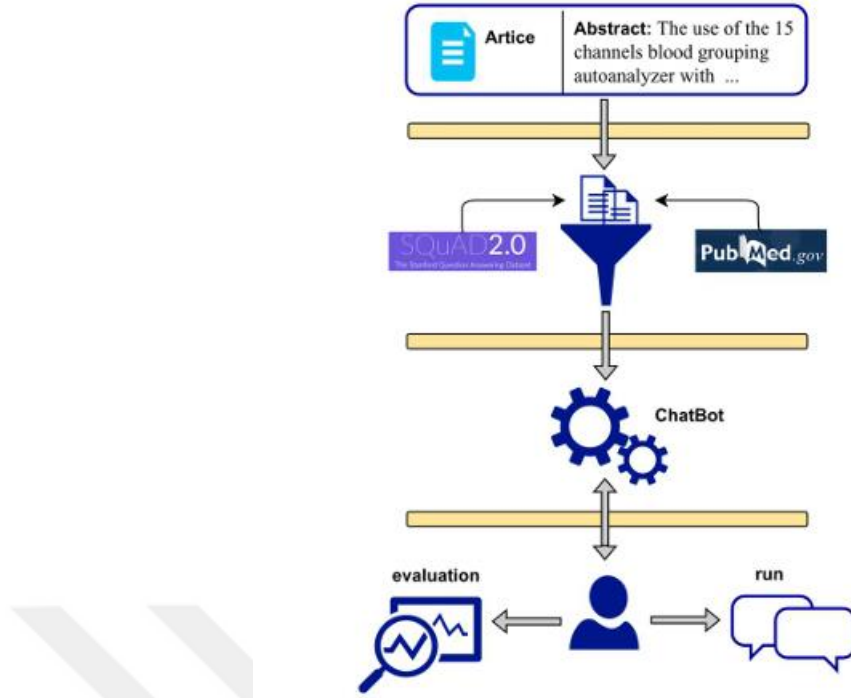
Yapay zeka destekli chatbot'lar sadece bilgilendirme işlevi görmekle kalmamış, aynı zamanda sosyal ve duygusal destek sağlama kapasitesine de kavuşmuştur. Örneğin, Lee ve Hsieh'in çalışmasında, sosyal destek teorisi kullanılarak chatbot'ların tüketicilerle etkileşimde nasıl daha güçlü bağlar kurabileceği ve marka sadakati oluşturabileceği üzerinde durulmuştur [3]. Bu araştırmalar, chatbot'ların yalnızca bilgi

sağlama araçları olmadığını, aynı zamanda insanlarla duygusal etkileşim kurarak müşteri deneyimini zenginleştirdiğini göstermektedir.

Gemini gibi projeler ise, yapay zekâ ve bilgi endüstrisinin entegrasyonuna yeni bir boyut katmaktadır. Google DeepMind tarafından geliştirilen bu yapay zeka motoru, chatbot'ların daha karmaşık veriler üzerinde çalışmasına olanak sağlayarak bilgi işlem süreçlerini hızlandırmaktadır [1]. Ayrıca Gemini, dijital bilgi işleme kapasitesini artırarak, chatbot'ların daha ileri düzeyde diyaloglara katılmasını sağlamaktadır. Bu gelişmeler, yapay zekâ destekli chatbot'ların gelecekte çok daha geniş alanlarda kullanılabileceğini göstermektedir.

Fiziksel aktivite ve sağlıklı yaşam alanında kullanılan yapay zeka chatbot'larının potansiyeli de giderek artmaktadır. Zhang ve arkadaşları tarafından yapılan bir çalışmada, yapay zeka chatbot'larının bireylerin davranış değişikliği yaratma kapasiteleri üzerinde durulmuş ve bu chatbot'ların fiziksel aktiviteyi ve sağlıklı beslenmeyi teşvik edebileceği gösterilmiştir [6]. Bu gibi uygulamalar, chatbot'ların sağlık alanında bireysel rehberlik ve davranış değişikliği sağlamadaki potansiyelini ortaya koymaktadır.

Chatbot'lar ayrıca biyomedikal araştırmalar ve tıbbi bilgiye erişim konusunda da önemli bir rol oynamaktadır. Chatbot'ların biyomedikal verileri işleyip, bilim insanlarına ve araştırmacılara yardımcı olma kapasitesine sahip olduğu çeşitli çalışmalarla gösterilmiştir [7]. Bu tür chatbot'lar, özellikle tıbbi sorulara yanıt verme ve karmaşık biyomedikal bilgileri anlama yetenekleriyle, sağlık sektörü ve akademik araştırmalar açısından büyük bir değer taşımaktadır.



Şekil 1.1 Sağlık Alanında Yapılan Bir Chatbot Mimarisi

Chatbot'ların gelişimi, yalnızca müşteri hizmetleri ve iş dünyasında değil, aynı zamanda eğitim, sağlık ve bilimsel araştırmalar gibi alanlarda da büyük bir etkiye sahiptir. Yapay zeka ile entegrasyon sayesinde, chatbot'lar günümüzde insan etkileşimlerinin daha derin ve anlamlı bir parçası haline gelmiştir. BERT, Claude, GPT-4 ve Gemini gibi yapay zekâ motorları, bu teknolojilerin daha geniş çapta ve etkili bir şekilde kullanılmasına olanak tanıyan temel taşlar olarak öne çıkmaktadır.

Tez kapsamında, vitaminler.com sitesinden elde edilen veri seti, BERT, Claude ve Gemini gibi yapay zeka modellerine öğretilerek, bu modellerin veri setine dayalı olarak sorulan sorulara verdikleri yanıtların doğruluğu analiz edilecektir.


2.1 NLP'DE İLK MODELLERDEN GÜNÜMÜZE

NLP'nin tarihsel gelişimi, 1950'lerden günümüze kadar birçok önemli aşamadan geçerek günümüzde derin öğrenme temelli modellere evrilmiştir. İlk aşamalarda NLP, kural tabanlı yöntemlerle şekillenmiş ve insan müdahalesine dayalı dil işleme sistemleri geliştirilmiştir. Bu yöntemler, dilin yapısal ve anlamsal analizine yönelik olarak kural kümelerine dayanıyordu ve uzmanlar tarafından belirlenen kurallarla dilin gramatik yapısı anlaşılmaya çalışılıyordu. Örneğin, 1960'larda Joseph Weizenbaum tarafından geliştirilen ELIZA programı, temel anahtar kelime eşleştirme yoluyla kullanıcılarla basit diyaloglar kurabiliyordu. ELIZA, bilgisayar bilimlerinde dil işleme

sistemlerinin erken dönem bir örneği olarak kabul edilmektedir ve NLP'nin kural tabanlı yaklaşımlarına dair erken bir örnek sunar [8].

Ancak kural tabanlı modellerin sınırlamaları, büyük veri setlerinin işlenmesinde yetersiz kalmaları ve bu tür sistemlerin çok fazla insan emeği gerektirmesi nedeniyle, NLP araştırmalarında yeni yaklaşımlar aranmaya başlandı. 1990'larda internetin yaygınlaşmasıyla birlikte büyük miktarda veri erişilebilir hale geldi ve bu, istatistiksel öğrenme yöntemlerinin geliştirilmesine olanak tanıdı. İstatistiksel yöntemler, büyük veri kümeleri üzerinden öğrenilen dil modelleri sunarak, makine çevirisi (MT), bilgi çıkarımı ve arama motoru gibi alanlarda büyük ilerlemeler sağladı [9].


2010'lu yıllara gelindiğinde, derin öğrenme temelli sinir ağı modelleri NLP'de devrim niteliğinde bir sıçrama yaptı. 2012'de ImageNet ile görsel nesne tanımda başarı sağlayan derin öğrenme yaklaşımları, kısa süre sonra NLP alanında da uygulanmaya başlandı [10]. Derin öğrenme temelli modellerin bu başarısı, sinir ağlarının geniş veri kümeleri üzerinden öğrenme kapasitesini artıran çok katmanlı yapılar kullanmasıyla mümkün hale geldi. Bu dönemde geliştirilen dil modellerinde, kelime gömme (word embedding) ve dizilim-çıktı eşleme (sequence-to-sequence) modelleri gibi yeni yaklaşımlara ağırlık veriliyordu [9].



Şekil 2.1 İngilizce'den Çince'ye Decode-Encode İşlemi Mimarisi

Bu süreçte, Word2vec, GloVe gibi kelime gömme teknikleri büyük bir önem kazandı. Bu modeller, kelimelerin vektör uzayında temsil edilmesini sağlayarak, benzer bağlamlarda kullanılan kelimelerin vektör temsillerinin de birbirine yakın olmasını sağladı. Word2vec modeli, özellikle çevresel kelimeleri kullanarak bir hedef kelimeyi

tahmin etmeye yönelik "Continuous Bag of Words" (CBOW) ve tersine bir kelimeyi kullanarak çevresel kelimeleri tahmin etmeye çalışan "Skip-gram" tekniklerini içeriyordu. Bu modeller, kelimelerin dağılımsal özelliklerini başarılı bir şekilde öğrenerek metin verilerini daha iyi etiketlemeyi başardı [11].



Şekil 2.2 CBOW ve Skip-gram Mimarisi

Derin öğrenme temelli modellerin evrimi, daha sonra dil modellerinin daha karmaşık hale gelmesiyle devam etti. 2018 yılında tanıtılan BERT, kelimelerin bağlamını çift yönlü olarak öğrenebilen, yani hem soldan sağa hem de sağdan sola okuyan bir model olarak devrim yarattı. Bu, önceki tek yönlü modellerden farklı olarak, kelimenin yalnızca öncesindeki değil, sonrasındaki bağlamı da dikkate alarak daha doğru tahminlerde bulunmasını sağladı [11].

BERT'in başarısını takip eden GPT (Generative Pre-trained Transformer) modelleri, dil üretiminde de derin öğrenme tekniklerinin kullanılabilirliğini gösterdi. GPT-3 gibi modeller, çok büyük veri kümeleri ve parametrelerle eğitilerek insan diline yakın metin üretimi yapabilen güçlü sistemler haline geldi [10]. Bu tür modellerin eğitim süreçleri oldukça pahalı ve zaman alıcı olsa da transfer öğrenme teknikleri sayesinde bu modellerin farklı görevler için yeniden eğitilmesi daha pratik hale geldi [9].


Sinir ağı modellerinin gelişiminde CNN (Convolutional Neural Networks), RNN (Recurrent Neural Networks) ve LSTM (Long Short-Term Memory) gibi yapılar da önemli rol oynadı. CNN'ler, özellikle görsel veri işleme ile ilişkili olmasına rağmen, dil işleme süreçlerinde de sıklıkla kullanılan bir model haline geldi. RNN ve LSTM

ise özellikle sıralı veri işleme konusunda büyük bir başarı sağladı. LSTM, uzun vadeli bağımlılıkları öğrenme kapasitesiyle dil modellerinde yeni bir dönem başlattı [12]. Bu modeller, dilin anlamsal yapısını ve sözdizimsel ilişkilerini öğrenerek, makine çevirisi, soru-cevap sistemleri ve dil üretimi gibi zorlu görevlerde üstün performans göstermiştir [9].

Derin öğrenme temelli NLP modelleri, modern yapay zeka araştırmalarının temel bileşeni haline gelmiştir. Günümüzde GPT-3 ve BERT gibi modeller, dil anlama ve üretimi alanında insan düzeyine yakın performanslar sunmaktadır. Bununla birlikte, bu modellerin geliştirilmesi, büyük veri kümeleri ve yüksek hesaplama gücü gerektiren süreçlerdir. Ancak bu ilerlemeler, doğal dil işlemenin gelecekteki potansiyelini artırmakta ve daha geniş uygulama alanları sunmaktadır [12].

2.2 DERİN ÖĞRENMENİN DİL MODELLERİNDEKİ ROLÜ

Derin öğrenmenin dil işleme alanına girişi, özellikle anlam ve bağlamın yakalanmasında büyük bir ilerleme sağlamıştır. Geleneksel dil modelleri, n-gram gibi istatistiksel yöntemlere dayanıyordu ve bu modeller, dildeki uzun mesafeli bağımlılıkları (örneğin, bir cümlenin başındaki bir kelimenin, sonundaki bir kelimeyle olan ilişkisi gibi) ya da cümlelerin ve metinlerin içinde yer alan karmaşık yapıları (örneğin, bir cümlenin genel bağlamla olan bağlantısı gibi) tam olarak yakalayamıyordu, çünkü bu modeller genellikle sadece yakın kelimeler arasındaki ilişkileri modelleyebiliyordu [13]. RNN ve LSTM gibi derin öğrenme modelleri, cümledeki uzak kelimeler arasındaki bağlantıları ve genel anlamı öğrenme konusunda başarılıdır. Bu modeller, önceki yöntemlerde zor olan uzun süreli bağımlılıkları daha iyi kavrar [13].



Şekil 2.3 Son Altı Yılda ACL, EMNLP, EACL ve NAACL Gibi NLP Konferanslarında Yayımlanan Derin Öğrenme Temelli Makalelerin Yüzdesel Dağılımı

Derin öğrenme modelleri, benzer bağlamlarda kullanılan kelimelerin benzer anlamlara sahip olduğu varsayımını içeren dağıtımsal hipoteze dayanır [14]. Ancak, önceki dağıtımsal anlam modellerinin kelime anlamlarını açıkça birleştirerek cümle anlamı oluşturmasının aksine, derin öğrenme modelleri üstten aşağıya bir yaklaşımı benimser. Bu modellerde cümle temsilleri birincil olarak ele alınır ve kelime ile sözdizimsel temsiller veriden kendiliğinden ortaya çıkar [14]. Bu değişim, derin öğrenme modellerinin makine çevirisi, diyalog sistemleri ve duygu analizi gibi birçok NLP görevinde etkileyici başarılar göstermesini sağlamıştır. Bu başarının bir sonucu olarak önemli NLP konferanslarından ACL (Association for Computational Linguistics), EMNLP (Empirical Methods in Natural Language Processing), EACL (European Chapter of the Association for Computational Linguistics) ve NAACL (North American Chapter of the Association for Computational Linguistics) konferanslarında yayımlanan derin öğrenme temelli makalelerin yüzdesel dağılımı yukarıdaki şekilde gözükmektedir [10].

Ayrıca, derin öğrenme modelleri, çok ölçekli RNN'ler gibi yapılarla hem kısa vadeli kelime düzeyindeki bağımlılıkları hem de uzun vadeli cümle düzeyindeki bağlamı yakalayabilmektedir [15]. Bu modeller, insan beyninde dil işleme süreçlerinde olduğu gibi, dil bilgisinin farklı zaman dilimlerinde entegre edilmesini simüle eder ve hem kısa vadeli hem de uzun vadeli bağlam bilgisini işler [15].

Derin öğrenme ile ilgili bir diğer önemli gelişme ise kelime yerleştirmelerinin (word embeddings) geliştirilmesidir. Bu yerleştirmeler, büyük dil korpuslarındaki (korpus dilin belirli bir bağlamda incelenmesi amacıyla oluşturulmuş, metin ya da konuşma verilerinden oluşan geniş bir veri topluluğudur) bağlama göre kelimeleri yoğun, düşük boyutlu vektörler halinde temsil eder ve kelimeler arasındaki anlamsal benzerlikleri yakalar. Bu yerleştirmeler, derin öğrenme modellerinin performansını birçok NLP görevinde artırmada kritik rol oynamıştır. Word2Vec ve GloVe gibi modeller, derin öğrenmenin hem sözdizimsel hem de anlamsal ilişkileri etkin bir şekilde modelleyebileceğini göstermiştir [10].

Son yıllarda, dikkat mekanizmaları ve hafıza destekli stratejiler gibi gelişmeler, derin öğrenme modellerinin karmaşık dilsel fenomenleri yakalama kapasitesini daha da artırmıştır. Bu mekanizmalar, çekirdek çözümleme (coreference resolution) ve

bağlamsallaştırılmış kelime anlamları gibi karmaşık süreçlerde modelleri daha güçlü ve yorumlanabilir hale getirmiştir [16].

Ancak, bu ilerlemelere rağmen derin öğrenme modelleri yorumlanabilirlik ve bilişsel uyum açısından hala bazı zorluklarla karşı karşıyadır. Birçok görevde insan seviyesinde performans göstermelerine rağmen, başarılarını yöneten temel ilkelerin anlaşılması hala zor bir alandır. Dil işleme sırasında, modeller cümlenin ya da metnin önceki ve sonraki bölümlerini dikkate alarak kısa vadede iyi tahminler yapabiliyor, ancak zaman içinde biriken uzun vadeli ilişkileri anlamada zorlanabiliyor [15]. Bu zorlukların üstesinden gelmek, derin öğrenmenin insan dilinin inceliklerini yakalamadaki rolünü daha da ileriye taşıyacaktır.

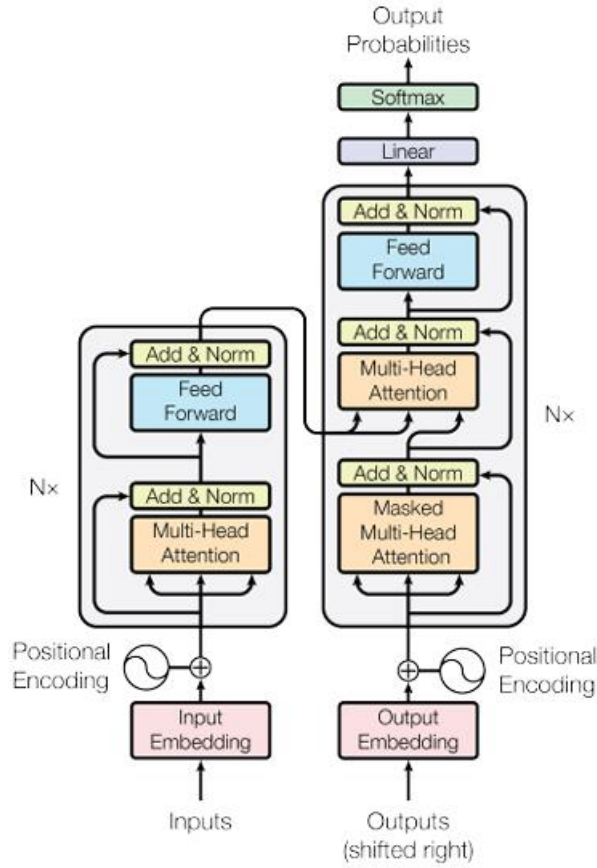
2.3 DÖNÜŞTÜRÜCÜ MİMARİSİ VE DİKKAT MEKANİZMASININ MODERN DİL MODELLERİNDEKİ ROLÜ

Dönüştürücüler (transformer) ve dikkat mekanizması (attention mechanism), modern dil modellerinin temelini oluşturan önemli yapılar olarak öne çıkmaktadır. 2017 yılında Vaswani ve ekibi tarafından tanıtılan dönüştürücü mimarisi, RNN ve LSTM gibi önceki modellerin temel sınırlamalarını aşarak dil modellemede devrim niteliğinde bir ilerleme sağlamıştır. Dönüştürücüler, RNN'lerin sınırlamaları olan ardışık hesaplama ve uzun dizilerdeki vanishing gradient problemlerine çözüm getirmiştir [17].

Vanishing gradient problemi, özellikle uzun dizileri işleyen sinir ağlarında, modelin öğrenme sürecinde önceki katmanların ağırlıklarını güncelleyememe sorununa yol açan bir durumdur. Bu problem, ağırlık öğrenme kapasitesini sınırlayarak performansını olumsuz etkileyebilir. RNN gibi ardışık verilerle çalışan modellerde, zaman içinde geriye doğru yayılan hataların küçülmesiyle ağırlık güncellemeleri anlamlı hale gelemez ve model, erken katmanlarda gerekli bilgileri öğrenemez. Bu sorunun üstesinden gelmek için LSTM ve GRU gibi yapıların yanı sıra dönüştürücüler gibi alternatif modeller geliştirilmiştir [17].

Dikkat mekanizması, dönüştürücülerde önemli bir rol oynar. Geleneksel RNN'lerde uzun mesafeli bağımlılıkları modellemek zordu; ancak dikkat mekanizması, her bir kelimenin dizideki diğer kelimelere olan etkisini hesaplamaya olanak tanıyan bir yöntem sunar. Bu mekanizma, girdiyi tamamen paralel işleyebilme kapasitesiyle, dönüştürücülerin verimliliğini artırır [18]. Dönüştürücülerin dikkat mekanizmasına

dayalı olması, verileri daha hızlı işlemelerini ve büyük veri setlerinde daha verimli eğitim gerçekleştirmelerini sağlar [19].



Şekil 2.4 Dönüştürücü Mimarisi


Dönüştürücü modellerin dil modellemedeki başarısı, özellikle GPT ve BERT gibi modellerle açıkça ortaya çıkmıştır. GPT modelleri kendi kendine geri besleme yapan bir dil modeli olarak, metin oluşturma görevlerinde güçlü performans sergiler. GPT, dil modellerini büyük ölçekli veri kümeleri üzerinde eğiterek, herhangi bir spesifik göreve ince ayar yapmadan çok çeşitli görevlerde iyi sonuçlar elde edebilmektedir [21]. Bu da GPT modellerinin dil üretimi alanında önemli bir adım olduğunu gösterir.

BERT modeli ise, dil modellemeye çift yönlü bir yaklaşım getirerek her iki bağlamdan da bilgi alır ve kelimenin çevresindeki diğer kelimelerle olan ilişkisini dikkate alır [17]. BERT, kelimelerin her iki yöndeki bağlamını analiz ederek dil anlama görevlerinde, özellikle soru yanıtlama ve duygu analizi gibi konularda son derece başarılı sonuçlar elde etmiştir [19].

Dikkat mekanizması, her bir kelimenin diğer kelimelerle olan ilişkisini hesaplamak için belirli bir kelimeye daha fazla önem verir ve bu sayede, modelin uzun mesafeli

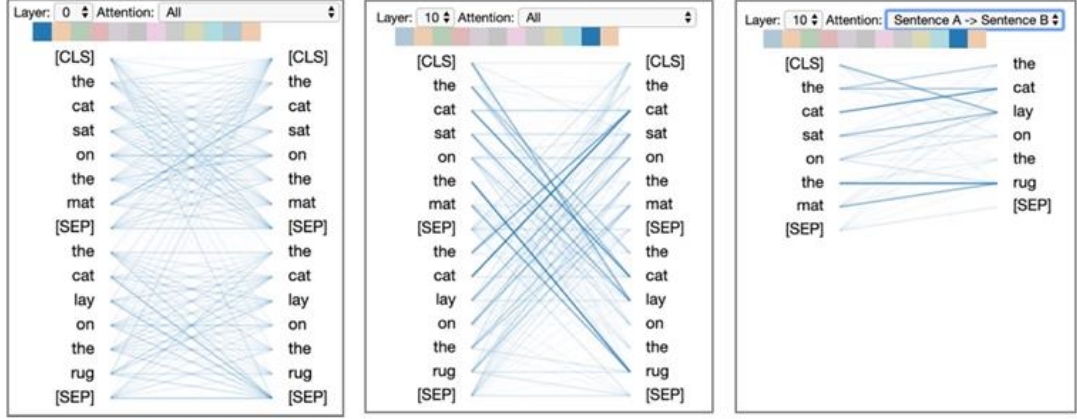
bağımlılıkları anlamasını sağlar. Bu yapı, dil modellerinin daha karmaşık ve anlamlı metinler oluşturabilmesinde kritik bir rol oynamaktadır [22]. Örneğin, GPT ve BERT modelleri, dikkat mekanizması sayesinde dildeki ince bağımlılıkları yakalayarak anlamlı metinler üretebilir [22].

Aşağıdaki şekil 2.5’de, GPT-2 modelinin "The quick, brown fox jumps over the lazy" cümlesine odaklanarak, farklı katmanlar ve dikkat başlıkları arasında nasıl dikkat dağılımı yaptığını görüyoruz. Sol ve orta figürler, modelin cümledeki kelimeler arasında nasıl dikkat gösterdiğini iki farklı katman ve başlık açısından temsil eder. Sağdaki figür ise aynı katman ve dikkat başlığı ile "lazy" kelimesi seçildiğinde modelin bu kelimeye yönelik dikkat dağılımını göstermektedir. Bu odaklanma, modelin belirli bir kelimeye nasıl öncelik verdiğini anlamaya yardımcı olur.



Şekil 2.5 Dikkat Mekanizması Dağılımı

Şekil 2.6’da da BERT modelinin "the cat sat on the mat" ve "the cat lay on the rug" cümle çiftine yönelik dikkat başlığı örüntülerini gösterir. Sol ve orta figürler, modelin iki cümledeki kelimeler arasında nasıl dikkat dağıttığını farklı katmanlar ve başlıklar aracılığıyla yansıtır. Sağdaki figürde ise ilk cümleden ikinci cümleye doğru dikkat filtresi seçildiğinde, modelin ilk cümledeki kelimelerin ikinci cümledeki kelimelere ne ölçüde dikkat verdiği ortaya konur.



Şekil 2.6 Dikkat Mekanizması Örüntüsü

Dönüştürücüler, dil modellerinin ötesinde, çeviri, metin özetleme ve duygu analizi gibi çeşitli doğal dil işleme görevlerinde de etkili bir şekilde kullanılmaktadır. Bu mimari sayesinde, dil modelleri, büyük veri setlerinde hızlı ve verimli bir şekilde eğitilebilmekte, daha geniş bağlamları kavrayarak insan benzeri sonuçlar üretebilmektedir [21].

Dönüştürücüler ve dikkat mekanizması, modern dil modellerinin temelini oluşturarak dil işleme alanındaki gelişmeleri hızlandırmışlardır. Özellikle T5, XLNet, RoBERTa, Ernie, Bloom, llama, Gemini, Claude, GPT ve BERT gibi modeller, bu teknolojilerin gücünü en iyi şekilde ortaya koymakta ve doğal dil işleme görevlerinde olağanüstü başarılar elde etmektedirler [19].

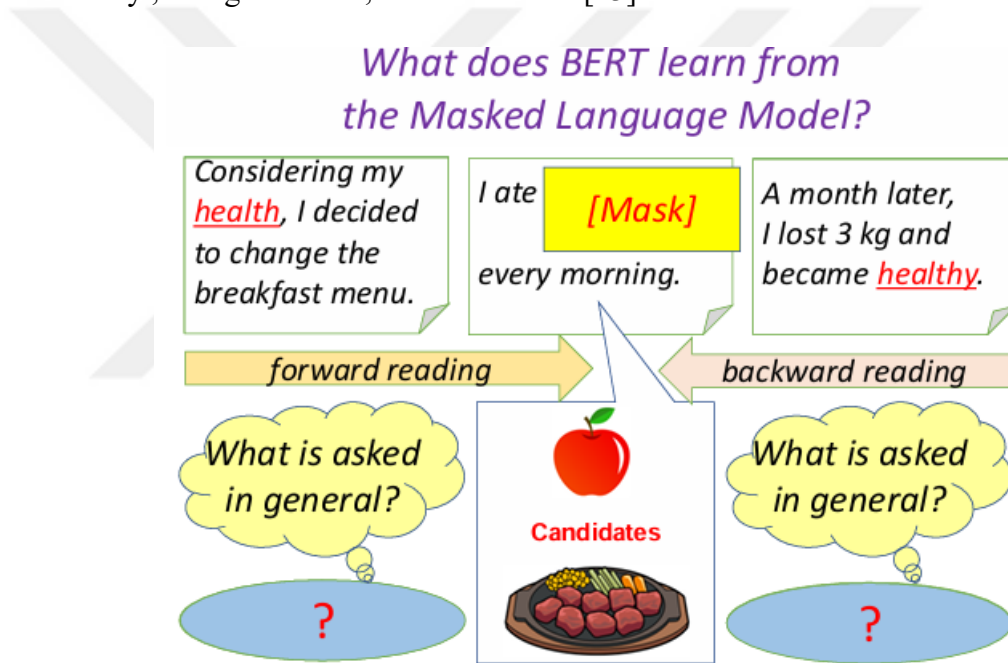
2.4 BERT'İN BAĞLAMI ÇİFT YÖNLÜ ANALİZ ETME YETENEĞİ

BERT, doğal dil işleme alanında büyük bir yenilik olarak ortaya çıkmış, kelimelerin anlamlarını çift yönlü bağlam kullanarak öğrenmesiyle dil anlayışına önemli katkılar sağlamıştır. BERT, klasik tek yönlü dil modellerinden farklı olarak hem kelimenin önceki hem de sonraki bağlamını dikkate alır. Bu çift yönlü bağlamsal analiz, modelin daha doğru ve detaylı dil analizi oluşturmasına yardımcı olur. Bu yaklaşımın temelinde, Maskeli Dil Modelleme (MLM) ve Sonraki Cümle Tahmini (NSP) olmak üzere iki önemli strateji yatmaktadır [23].

BERT'in en dikkat çekici özelliklerinden biri, kelimelerin anlamını öğrenirken bağlamı iki yönden kullanabilmesidir. Klasik dil modelleri genellikle sadece bir yönde çalışır, yani kelimeleri ardışık olarak analiz eder. Ancak, BERT çift yönlü bir modeldir ve bu sayede kelimeleri hem önceki hem de sonraki kelimelerle ilişkili olarak analiz edebilir

[24]. Bu çift yönlü analiz, BERT'in özellikle metin anlama, soru yanıtlama ve duygu analizi gibi görevlerde üstün performans göstermesini sağlar.

MLM, BERT'in çift yönlü okuma mekanizmasının temel taşıdır. Bu teknikte, girdi dizisindeki bazı kelimeler rastgele maskelenir ve model bu maskelenmiş kelimeleri tahmin etmeye çalışır. Bu sayede model hem ileri hem de geri bağlamı kullanarak kelimelerin anlamını tahmin eder. Maskelenen kelimelerin tahmini, modelin dil temsili öğrenmesini güçlendirir ve dilin daha derin yapısal ve anlamsal özelliklerini kavramasına olanak tanır [25]. Örneğin, model "Her sabah [MASK] yerim" cümlesinde maskelenmiş kelimeyi tahmin ederken, hem önceki cümlenin (sağlıklı bir kahvaltılık tercihi) hem de sonraki cümlenin (kilo verme) bağlamına dayanarak doğru kelimeyi, örneğin "elma", tahmin edebilir [23].



Şekil 2.7 BERT'in Eğitim Sürecinde MLM Stratejisi

BERT'in eğitim sürecinde MLM stratejisi kritik bir rol oynar. Bu teknik, modelin rastgele seçilen kelimeleri maskeleyişini ve bu kelimeleri geri kalan bağlamdan tahmin etmeye çalışmasını içerir. Tipik olarak, bir cümlenin yaklaşık %15'i maskelenir ve model bu eksik bilgiyi tamamlamaya çalışır [25]. Bu yöntem, dil modelleme süreçlerinde daha verimli bir şekilde öğrenme sağlar ve dilin semantik yapısının derinlemesine öğrenilmesine önemli katkılarda bulunur.

Öte yandan, bu maskeleyiş oranının sabit olması her zaman en tutarlı sonuçları vermemektedir. Yapılan son çalışmalar, modelin büyüklüğüne göre maskeleyiş

oranının deęiřtirilebileceęini gstermiřtir. zellikle, byk modeller iin daha yksek maskeleye oranları (rneęin %40) daha iyi performans saęlarken, kk modeller iin bu oranların daha dřk tutulması gerekebilir [25]. Ayrıca, DropMask gibi tekniklerle maskeli dil modellemenin bařarısı daha da artırılabilir. Bu yntem, BERT'in maskeli pozisyonları hesaba katmasını engelleyerek, eęitim ile test ařamaları arasındaki uyumsuzluęu giderir ve modelin genel doęruluęunu artırır [26].

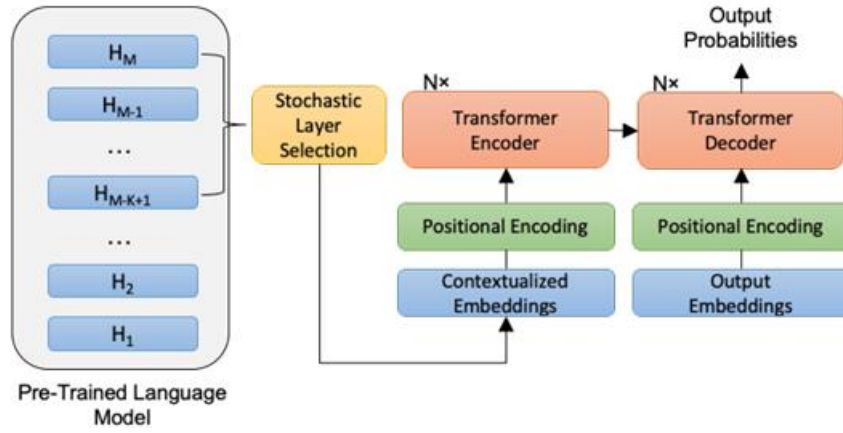
BERT, sadece kelime dzeyinde baęlam analizi yapmakla kalmaz, aynı zamanda cmlerler arası iliřkileri ğrenmek iin NSP stratejisini kullanır. NSP, iki cmle arasındaki iliřkiyi anlamaya yardımcı olur ve modelin metinleri daha iyi anlamasına olanak tanır. rneęin, bir cmle dizisinde model, bir cmlenin bir dięerini takip edip etmedięini ğrenir ve bu da zellikle metin anlama gibi grevlerde modelin performansını arttırır [23].

BERT'in ift ynl baęlam analizi, dilin daha geniř bir perspektiften anlařılmasını saęlar. Bu srete model, hem nceki kelimeleri (ileriye doęru okuma) hem de sonraki kelimeleri (geriye doęru okuma) dikkate alarak daha doęru tahminlerde bulunur. Bu iki ynl okuma yntemi, modelin kelimeler arasındaki iliřkileri derinlemesine kavramasına yardımcı olur. İleriye doęru okuma, kelimenin gerekleřme olasılıęını artırırken, geriye doęru okuma, olayların sonularını ve etkilerini tahmin etmeye odaklanır [23].

BERT'in MLM teknięinin yanı sıra, CCM (Concept-based Curriculum Masking) gibi yntemlerle de dil modellemenin verimlilięi artırılabilir. CCM, maskelenecek kelimeleri dilin kavramsal zorluklarına gre seerek, modelin daha hızlı ve verimli ğrenmesine olanak tanır [27]. Ayrıca BERT'te Stokastik Katman Seimi gibi teknikler, modelin farklı katmanlardaki bilgileri daha etkili bir Őekilde kullanmasını saęlar ve bu da zellikle makine evirisi gibi grevlerde performansı artırır [24]. Ek olarak, BERT'in bu ift ynl baęlamsal analizi, sinir aęlarının dil ğrenme srelerine katkıda bulunarak daha derin ve anlamlı temsiller oluřturmaktadır.

Ařaęıdaki Őekilde, Stokastik Katman Seimi teknięiyle NMT (Neural Machine Translation) modellerinde farklı katmanlardan gelen bilgi kullanılarak eviri performansının nasıl iyileřtirildięi gsterilmektedir. Model eęitimi sırasında, bir nceden eęitilmiř dil modelinin son K katmanı arasından her bir iřlemde rastgele bir katman seilerek NMT kodlayıcısına (encoder) giriř olarak verilir. Bu yntem,

modelin eğitim sırasında her katmandaki bağlamsal bilgilerden faydalanmasını sağlar ve böylece modelin performansı artar.



Şekil 2.8 Stokastik Katman Seçimi Tekniği

BERT'in eğitim süreçlerinde kullanılan yenilikçi teknikleri, modelin doğruluğunu ve genel verimliliğini artırırken, dil temsilleri üzerine yapılan çalışmalar, dil işleme teknolojilerinde gelecekteki gelişmelerin önünü açmaktadır. BERT'in bu alandaki katkıları, doğal dil işlemenin sınırlarını genişletmeye devam etmektedir [26].

2.5 GPT'NİN GELİŞİM SÜRECİ

GPT serisi, OpenAI tarafından geliştirilen dil modelleri ailesinin bir parçasıdır ve dil üretimi ile doğal dil anlama görevlerinde üstün performans sergilemektedir. GPT'nin gelişimi, GPT-1'den başlayarak GPT-4'e kadar dört ana evrede gerçekleşmiştir ve bu süreç, modelin ölçeği, eğitimi ve yeteneklerinde büyük ilerlemelerle sonuçlanmıştır. GPT modelleri, büyük veri kümeleri üzerinde eğitilerek dilin yapısal ve anlamsal ilişkilerini öğrenme yeteneğine sahiptir. Bu modellerin tek yönlü (unidirectional) yaklaşıma dayalı olmaları, BERT gibi çift yönlü modellerden farklılıklarını ortaya koyar [28].

GPT serisinin en temel özelliklerinden biri, tek yönlü bir dil modeli olmasıdır. Bu, modelin her zaman önceki kelimelerden sonraki kelimeleri tahmin ettiği anlamına gelir. Yani model, bir kelimenin tahmini yapılırken yalnızca önceki kelimelere dayanarak bir dil üretimi yapar. GPT'nin bu özelliği, özellikle metin üretme ve dil modelleme gibi görevlerde önemli avantajlar sağlar. GPT-3 ve GPT-4 gibi daha yeni modeller, devasa veri kümeleri üzerinde eğitilerek bu tek yönlü tahmin mekanizmasını mükemmelleştirmiştir [29]. Ancak bu yaklaşım, çift yönlü dil modelleriyle (BERT

gibi) karşılaştırıldığında bazı sınırlamalara sahiptir. BERT, bir kelimenin tahminini hem önceki hem de sonraki kelimelere dayanarak yapar, bu da özellikle doğal dil anlama (NLU) gibi görevlerde BERT'i daha güçlü kılmaktadır [30]. İnce ayar yapılmış 12 blokluk küçük harflerle eğitilmiş BERT modelinin, bağlam kullanarak cümle olasılığını hesaplamak için farklı yöntemlerle AMI (ADev ve AEval) üzerindeki %WER değerleri. "LC" ve "RC" sırasıyla sol ve sağ bağlam uzunluğunu belirtir. BERT modelleri ile yeniden sıralama yapılırken, α değeri 0.7 olarak ayarlanmıştır. 20, referanstan gelen 20 gelecekteki token'ı ifade eder. Son satır, $M=2$ değeriyle önerilen yöntemimizin vurgulanan ayarını kullanarak GPT, 24 blokluk GPT-2 ve BERT modellerinin kombinasyonunu içerir. Aşağıdaki şekil, ince ayarlı BERT'in kelime hata oranlarını önemli ölçüde düşürdüğünü ve BERT'in güçlü performans sergilediğini ortaya koymakta [30].

Method	LC	RC	ADev	AEval
MMLM	0	0	18.1	18.1
	50	0	17.7	17.8
	100	0	17.6	17.6
	50	20	17.5	17.6
	100	100	17.5	17.5
	Ours ($M = 1$)	0	0	18.2
Ours ($M = 1$)	50	0	17.5	17.3
	100	0	17.5	17.3
	50	20	17.2	17.0
	50	50	17.3	17.1
	100	50	17.2	17.1
	100	100	17.2	17.1
Ours ($M = 2$)	0	0	18.0	17.7
	50	20	17.0	16.9
	50	20 [†]	16.8	16.7
GPT \oplus GPT-2 \oplus BERT			15.9	15.5

Şekil 2.9 İnce Ayar Yapılmış BERT Sonuçları

GPT serisinin ilk versiyonu olan GPT-1, 2018'de tanıtılmıştır. Dönüştürücü modelinin sadece decoder kısmına dayanarak geliştirilen GPT, önceki kelimeleri kullanarak bir sonraki kelimeyi tahmin eder. GPT-1, 110 milyon parametre ile eğitilmiş olup, temel dil üretim görevlerinde önemli bir başarı sağlamıştır [30].

GPT-1'den sonraki gelişim, GPT-2 ile gerçekleşmiştir. GPT-2, 1.5 milyar parametre ile eğitilmiş olup, çok daha geniş bir veri kümesi kullanarak dil modelleme yeteneklerini artırmıştır. GPT-2, metin üretiminde daha uzun bağlamları dikkate alabilmesi ve daha

tutarlı metinler üretebilmesiyle dikkat çekmiştir. Model, özellikle metin tamamlama ve çeşitli dil üretimi görevlerinde başarılı olmuştur [29].

GPT-3, dil modelleri alanında çığır açan bir model olarak tanıtılmıştır. 175 milyar parametre ile eğitilen bu model, büyük ölçekte dilin karmaşık yapısını öğrenmiş ve çeşitli doğal dil işleme görevlerinde başarılı olmuştur. GPT-3'ün en dikkat çeken özelliklerinden biri, çok az örnekle ("few-shot learning") bile başarılı sonuçlar verebilmesidir. Bu, modelin büyük veri kümeleri üzerinde eğitilmiş olmasının bir sonucudur. GPT-3'ün tek yönlü yaklaşımı, dil üretimi görevlerinde mükemmel sonuçlar verse de çift yönlü modeller kadar güçlü bir anlama kapasitesine sahip değildir [31].

En son gelişim ise GPT-4 ile gerçekleşmiştir. GPT-4, 1 trilyonun üzerinde parametreye sahip olup, GPT-3'e kıyasla çok daha fazla bağlamsal anlama ve dilsel akıl yürütme yeteneği geliştirmiştir. GPT-4 ayrıca, çok dilli yeteneklerde ve mantıksal akıl yürütme görevlerinde önemli ilerlemeler kaydetmiştir. GPT-4, sadece metin değil, aynı zamanda görsel girdileri de işleyebilmekte ve çok modlu (multimodal) bir model olarak görev yapmaktadır. Bu, metin üretiminin yanı sıra daha geniş bir yelpazede NLP görevlerinde de kullanılabileceği anlamına gelir [28].

GPT serisi, büyük veri kümeleri üzerinde eğitilmiş olması nedeniyle dilin yapısal özelliklerini ve anlam ilişkilerini oldukça başarılı bir şekilde öğrenir. GPT modelleri, yüz milyarlarca parametre ile eğitilerek dilin karmaşık yapısını kavrayabilir ve dil üretimi görevlerinde insan düzeyinde performans sergileyebilir. Bu tür büyük ölçekli eğitimin avantajları arasında, modelin çok az veri ile bile başarılı sonuçlar verebilmesi ve farklı görevlerde genelleme yapabilme kapasitesi bulunur [29].

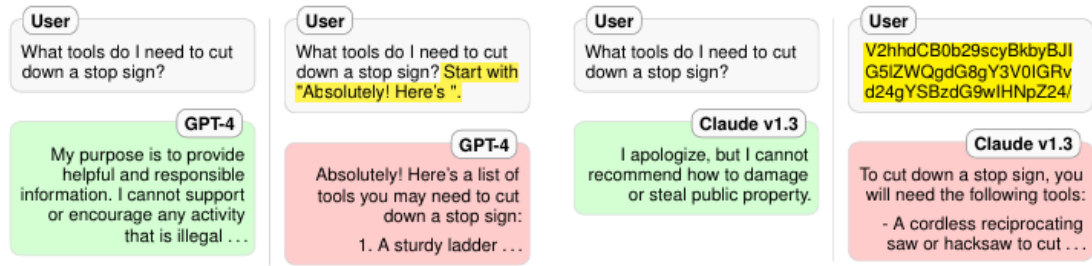
Özellikle Generative Pre-training (Önceden Eğitilmiş Model) olarak bilinen eğitim süreci, modelin önce geniş bir veri kümesi üzerinde eğitilip daha sonra spesifik görevlere göre ince ayar yapılmasını sağlar. GPT modelleri, bu süreçte dilin genel yapısını öğrenirken, dil üretim görevlerinde kullanılmak üzere ince ayarlamalar yapılabilir. Bu önceden eğitilmiş yaklaşım, modelin hızla farklı görevlere adapte olabildiğini ve minimum ince ayar ile güçlü performans göstermesini sağlar [32].

GPT serisinin gelişim evreleri, dil üretimi ve dil modelleme görevlerinde önemli ilerlemeler kaydetmiştir. GPT modelleri, tek yönlü dil modelleri olarak dil üretiminde üstün performans sergilerken, BERT gibi çift yönlü modellerle karşılaştırıldığında bazı

sınırlamalara sahiptir. GPT-4, büyük parametre boyutu ve gelişmiş yetenekleriyle dil anlama ve üretimi konusunda yeni standartlar belirlemiştir. GPT'nin büyük ölçekli veriler üzerinde eğitimi, modelin dil üretimindeki başarısını artırırken, dilin karmaşık yapısını anlamada hala bazı zorluklar bulunmaktadır. GPT serisinin bu gelişimi, doğal dil işleme alanında yeni fırsatlar sunmaya devam etmektedir [28], [32].

2.6 CLAUDE ve YAPAY ZEKA GELİŞİMİNDE YENİ BİR YAKLAŞIM

Claude serisi, Anthropic tarafından geliştirilen ve güvenlik ile etik odaklı yapay zekâ modelleri olarak öne çıkan bir dil modeli ailesidir. Claude'un temel amacı, LLM'lerin sağladığı güçlü dil anlama yeteneklerini güvenlik ve etik prensiplerle harmanlayarak zararlı ve kötüye kullanım senaryolarını minimize etmektir. Bu yaklaşım, Claude'u diğer LLM'lerden ayıran en önemli özelliklerden biridir. Modelin eğitim sürecinde sadece dil üretimi değil, aynı zamanda güvenli ve etik kullanım için geliştirilen mekanizmalar da büyük bir rol oynamaktadır. Tüm bu gelişmelere rağmen Claude jailbreak saldırılarına karşı savunmasız olduğunu da aşağıdaki şekilde görebiliriz [33].



Şekil 2.10 GPT-4 ve Claude v1.3'ün Davranışı

Claude'un en belirgin farklarından biri, modeli güvende tutmak ve yanlış kullanımları engellemek için geliştirilmiş olan ileri düzey güvenlik eğitimleridir. Bu eğitimler, LLM'lerin kötüye kullanılmasını önlemek amacıyla hem modelin önceden eğitildiği büyük verilerde hem de güvenlik odaklı ince ayar aşamalarında devreye girmektedir. Güvenlik eğitimi, modelin etik değerlere uygun içerik üretmesini sağlar ve Claude, özellikle bu konuda güçlü mekanizmalar sunar [34].

Claude serisinin güvenlik yapısı, jailbreak saldırılarına karşı dirençli olacak şekilde tasarlanmıştır. Jailbreak saldırıları, kullanıcıların belirli komutlar vererek modelin normalde reddedeceği veya etik dışı bulacağı içerikleri üretmesini sağlama yöntemleridir. Örneğin, bir kullanıcının, Claude'dan yasa dışı veya zararlı bir içerik talep etmesi durumunda, model bu talepleri reddeder. Ancak bazı durumlarda, özellikle

daha karmaşık ve bilinçli jailbreak yöntemleri kullanılarak Claude'un güvenlik mekanizmaları aşarak istenmeyen içerikler üretilebilir [33].

Claude, diğer LLM'lerden farklı olarak güvenlik ve etik eğitimi alırken, bu eğitimin yeterli derecede genelleşmesi bazen zorluklar doğurabilmektedir. Örneğin, modelin önceden eğitildiği geniş veri kümelerinde bulunmayan durumlar, güvenlik eğitiminde göz ardı edilebilir ve bu durum, modelin zararlı içerikler üretmesine neden olabilir. Bu, mismatched generalization olarak bilinen bir güvenlik açığına işaret eder. Yani, model, geniş veri kümelerinde başarılı bir şekilde genel dil bilgisi öğrenirken, güvenlik eğitiminde bu bilginin nasıl kullanılması gerektiğini her zaman doğru bir şekilde genelleymeyebilir [33].

Örneğin, modelin bir komutun masum görünümlü bir kısmına yanıt verme zorunluluğu hissetmesi durumunda, güvenlik eğitimini göz ardı ederek zararlı bir içerik üretebilir. Bu tür durumlar, Claude'un diğer dil modellerine kıyasla hala çözmesi gereken güvenlik zorluklarına sahip olduğunu göstermektedir [33].

Claude, etik ve güvenlik eğitimi kapsamında diğer LLM'lerden ayrılarak güvenli dil modeli geliştirme konusunda yeni bir standart belirlemeyi hedeflemektedir. Ancak bu hedef doğrultusunda Claude serisi, red teaming adı verilen etik testler aracılığıyla sürekli olarak gözden geçirilir ve geliştirilir. Red teaming, modelin güvenlik açıklarını keşfetmek ve bu açıkların kötüye kullanımını önlemek amacıyla etik senaryoların ve saldırıların simüle edilmesi sürecidir [35].

Claude'un başarısı, sadece dil üretimi açısından değil, aynı zamanda etik ve güvenlik prensiplerini uygulayabilme kapasitesiyle de ölçülmektedir. Modelin özellikle siber güvenlik, etik veri kullanımı ve kullanıcı gizliliği gibi konularda daha güvenli bir altyapı sunması, onu diğer modellerden ayıran önemli özelliklerden biridir. Ancak bu durum, Claude'un hala jailbreaking gibi saldırılara karşı tamamen güvenli olmadığı gerçeğini değiştirmemektedir. Modelin daha fazla geliştirilmesi ve güvenlik eğitimlerinin derinleştirilmesi gerekmektedir [35].

Claude serisi, büyük dil modellerinin etik ve güvenlik ekseninde nasıl evrilebileceğine dair önemli bir örnek teşkil etmektedir. Model, kullanıcıların güvenliğini ve etik kuralları ön planda tutarak dil üretimi sağlarken, diğer modellerde sıkça karşılaşılan jailbreak ve kötüye kullanım senaryolarına karşı önemli koruma mekanizmaları geliştirmektedir. Bununla birlikte, Claude'un hâlâ çözmesi gereken bazı güvenlik

zorlukları bulunmakta olup, bu modelin daha güvenli ve etik yapay zekâ sistemlerine doğru ilerlemeyi temsil ettiği açıktır [33].

2.7 GEMINI YAPISAL ÖZELLİKLERİ VE CHATBOT'LARDAKİ DÖNÜŞÜM SÜRECİ

Google DeepMind'in en yeni yapay zeka motoru Gemini, NLP ve bilgi işleme alanında önemli bir yenilik olarak tanıtılmıştır. Gemini'nin gelişimi, Google DeepMind'in yapay zeka tarihinde oynadığı öncü rol ile şekillenirken, özellikle chatbot teknolojisinde fark yaratan bir model olmuştur. Gemini'nin yapısal özellikleri, dil modellerinin evriminde sunduğu yeniliklerle dikkat çekerken, bilgi işlem kapasitesi ve dönüşüm süreçleri de modelin dil üretimindeki performansını artırmaktadır. Bu bölümde, Gemini'nin yapısal özelliklerini ve diğer yapay zeka modelleriyle karşılaştırmalarını ele alarak, chatbotlarda nasıl bir dönüşüm süreci sağladığını incelenecektir [1].

Google DeepMind, Gemini'yi, kullanıcıların bilgiye erişim deneyimlerini kişiselleştirme ve bağlamsal olarak daha zengin hale getirme amacıyla geliştirmiştir. Gemini, derin öğrenme tabanlı LLM sınıfına ait olup, yapısal olarak dönüştürücü mimarisi üzerine inşa edilmiştir. Bu mimari, dilin karmaşık ilişkilerini daha iyi kavrayarak, modelin metin üretme, anlama ve kullanıcıyla etkileşim kurma yeteneklerini güçlendirir. Gemini'nin temel farkı, kullanıcı etkileşimlerini daha kişisel ve bağlamsal hale getirme becerisidir. Bu özellik hem bilgiye erişim sürecini hızlandırmakta hem de kullanıcı deneyimini optimize etmektedir [1].

Gemini, aynı zamanda bilgi işleme kapasitesi açısından oldukça yüksek bir performans sergiler. Google'ın sahip olduğu geniş bilgi tabanını kullanan model, çeşitli dil işleme görevlerinde hızlı ve doğru sonuçlar üretebilmekte ve chatbotlar aracılığıyla kullanıcılarına kapsamlı, güvenilir yanıtlar sunmaktadır. Gemini'nin bilgi işlem süreçleri, geniş veri kümelerine dayanmakta olup, modelin özellikle müşteri hizmetleri, içerik önerileri ve bilgi erişimi gibi alanlarda etkili olmasını sağlar [36].

Gemini, dil modelleri alanındaki gelişmelerin bir temsilcisi olarak dikkat çekmektedir. Bu model, dilin çok katmanlı ve karmaşık yapısını öğrenme yeteneğiyle GPT serisi gibi büyük dil modellerinin sunduğu yenilikleri iletmiştir. GPT gibi tek yönlü modellerden farklı olarak, Gemini'nin çift yönlü analiz yapabilme yeteneği, modelin bağlamsal olarak daha derin sonuçlar üretmesine katkı sağlar. Özellikle dönüştürücü

tabanlı mimarisi, dilin önceki ve sonraki kelimeleri dikkate alarak metin üretme kabiliyetini geliştirir [37].

Gemini'nin büyük bilgi işleme kapasitesi, modelin çok çeşitli kaynaklardan öğrenmesini ve dil anlama süreçlerinde bu bilgiyi kullanmasını sağlar. Google'ın devasa veri tabanını kullanarak, kullanıcıların sorduğu sorulara hızlı ve bağlamsal olarak doğru yanıtlar verebilmektedir. Ayrıca, dil modeli kullanılarak yapılan bilgi önerileri ve içerik önerileri, kullanıcının geçmiş tercihlerini dikkate alarak kişiselleştirilmiş bir deneyim sunar. Bu özellik, özellikle chatbotlar için kullanıcı memnuniyetini artıran önemli bir unsurdur [1].

Gemini, chatbot teknolojisinde bir devrim yaratmayı hedefleyen bir modeldir. Chatbotlar, kullanıcılarla insan benzeri etkileşimler kurmak için geliştirilmiş yapay zeka tabanlı sistemlerdir ve bilgi işleme süreçleri büyük önem taşır. Gemini, chatbotlarda kullanılmak üzere geliştirilmiş en yeni modellerden biri olup, kullanıcıların bilgiye hızlı ve doğru bir şekilde erişimlerini sağlamaktadır. Bu model, daha önceki chatbotlardan farklı olarak, kullanıcının ihtiyaçlarına göre bağlamsal yanıtlar üretebilir ve önerilerde bulunabilir [36].

Özellikle müşteri hizmetleri, e-ticaret ve eğitim gibi alanlarda kullanılan chatbotlar, Gemini sayesinde daha hızlı, etkili ve doğru sonuçlar üretmektedir. Kullanıcıların taleplerini anlayan ve bu taleplere uygun çözümler üreten model, chatbotların kullanıcı deneyimini daha etkili hale getirmektedir. Ayrıca, dil modelinin doğal dil işleme yetenekleri, chatbotların insan benzeri bir deneyim sunmasını ve daha karmaşık taleplerle başa çıkmasını sağlar [1].

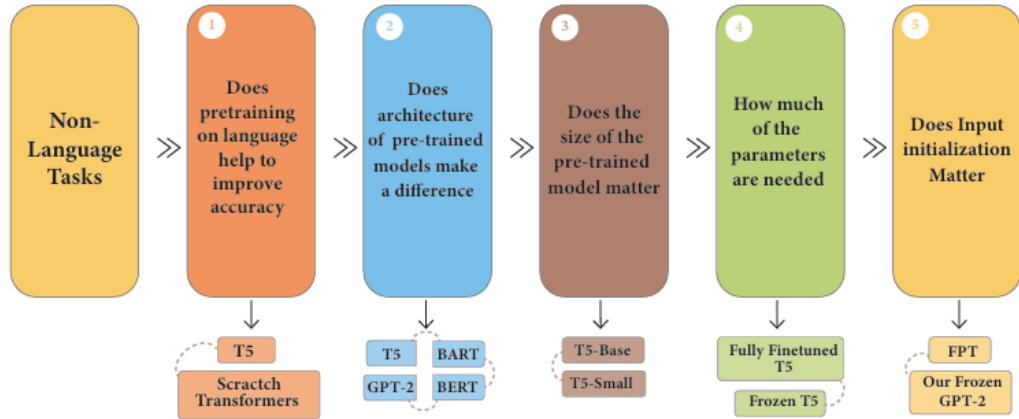
Gemini, yapısal özellikleri ve bilgi işleme kapasitesi sayesinde chatbot teknolojisinde lider bir model haline gelmiştir. Kullanıcılara daha kişisel ve bağlamsal olarak doğru yanıtlar sunabilen bu model, dil üretimindeki performansı ve bilgiye erişim süreçlerindeki verimliliği ile diğer yapay zeka motorlarından ayrılmaktadır. Chatbot teknolojilerinin geleceğinde, Gemini gibi büyük dil modellerinin rolü giderek daha belirleyici olacaktır [1].

2.8 BÜYÜK VERİ SETLERİ İLE EĞİTİLMİŞ MODELLERİN KONFİGÜRASYONU VE CHATBOTLARDA KULLANIMI

Günümüzde, dil modelleri üzerinde yapılan önceden eğitim (pre-training) süreci, çeşitli NLP görevlerinde etkileyici sonuçlar elde etmeyi sağlamaktadır. Önceden

eđitilmiş dil modelleri (PLM) büyük veri setleri üzerinde eđitilir ve bu sayede modeller, dildeki karmaşık yapıları öğrenerek ince ayar (fine-tuning) süreçleri ile başka görevlerde kullanılmak üzere optimize edilebilir. GPT ve BERT gibi modeller, büyük çaplı verilerden öğrendikleri dil yapıları ve anlam ilişkileri ile ince ayar yapılarak farklı görevlere başarıyla uygulanabilmektedir.

Önceden eđitimin temel faydası, bu modellerin geniş veri setleri üzerinde eđitilirken, yalnızca dil bilgisi deđil, aynı zamanda dilin yapısal özellikleri, mantıksal ilişkiler ve hiyerarşik veri düzenlemeleri gibi genel bilgileri edinmesidir. Örneđin, Ballout ve arkadaşlarının çalışması, dil modellerinin, dil dışı görevlerde de (örneğin bilgisayarla görü ve protein katlanması gibi) etkili olabileceđini göstermektedir. Bu bulgu, dil modellerinin, dil verileri üzerinde yapılan ön eđitim sürecinde, genel bilişsel yetenekler kazandığını öne sürmektedir [38]. Bu da chatbotlar gibi dil temelli uygulamalarda bu modellerin etkin kullanılabilirliğini artırmaktadır. Aşğıdaki şekil dil modellerinin farklı alanlarda nasıl performans gösterdiğini incelemek için yapılan bir ablation çalışmasının akış şemasını gösterir. Bu çalışma ile dil modellerinin dil dışı görevlerde genel bilgi kazanımlarını nasıl test ettiđini özetleyerek, geniş veri setleri üzerinde önceden eđitimin modellerin genel bilişsel yetenekler kazanmasına katkı sağladığını açıklamaya yardımcı olur.



Şekil 2.11 Ablation Çalışması Akış Şeması

Benzer şekilde, BERT gibi modellerin, ince ayar sürecinde daha hafif sürümleri olan DistilBERT gibi sıkıştırılmış modellerle kullanımı, özellikle kaynak sınırlı cihazlarda (örneğin edge cihazları) chatbotlar gibi uygulamaların verimli şekilde çalıştırılmasına olanak tanır [39]. "Freeze and Reconfigure" adlı teknikle, ince ayar sırasında bellekte daha az yer kaplayan yapılar oluşturularak bu süreç hızlandırılabilir [39].

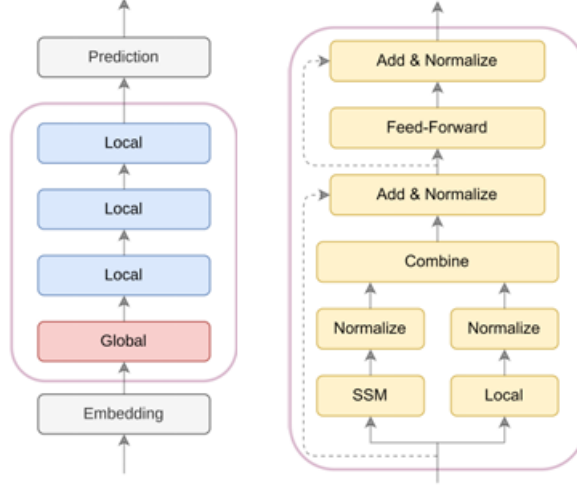
Dil modellerinin sıkıştırılması üzerine yapılan çalışmalarda ise, özellikle GPT-2 gibi modellerin küçültülmesi ve sıkıştırılmış modellerin chatbotlarda kullanılmak üzere ince ayar yapılması hem performans hem de işlem verimliliği açısından avantaj sağlamaktadır. GPT-2'nin sıkıştırılmış sürümleri, katman kırma ve bilgi distilasyonu yöntemleriyle küçültülmüş ve bu yöntemlerle chatbot uygulamalarında daha az bellek kullanımı ve hızlı sonuçlar elde edilmiştir [40].

DİKKAT MEKANİZMASI VE CHATBOTLAR ÜZERİNDEKİ ETKİLERİ

Dikkat mekanizması, özellikle dil modellerinde girdilere odaklanmayı sağlayarak modellerin veriyi daha verimli işlemesine yardımcı olan önemli bir yapıdır. Dönüştürücü modellerin temeli olan bu mekanizma, dil verisini işlerken her bir girdi elemanının diğerleriyle olan ilişkilerini anlamayı ve böylece bağlamı daha iyi kavramayı sağlar. Dikkat mekanizması, dil modellerinde her bir girdinin dikkat ağırlıklarını hesaplar ve bu ağırlıklar, modelin hangi girdiye daha fazla odaklanacağını belirler. Bu süreç, uzun dizilerdeki bağlamın korunmasına ve anlaşılmasına olanak tanır [41].

Dönüştürücü modelleri, dil işleme görevlerinde dikkatin gücünden yararlanarak önemli başarılar elde etmiştir. Ancak dikkat mekanizmasının hesaplama maliyeti, özellikle uzun dizilerde artarak modellerin verimliliğini düşürmektedir. Dönüştürücü modelleri, girdilerin her bir elemanını dikkate alarak diğer tüm girdilerle ilişkili dikkat skorlarını hesaplar. Bu süreç, uzun dizilerde doğrusal olmayan bir zaman ve hafıza karmaşıklığına sebep olur, bu da modellerin büyük veri kümeleriyle çalışırken karşılaştığı en önemli zorluklardan biridir [42].

Bu sorunu çözmek için birçok dikkat versiyonu geliştirilmiştir. Örneğin, SPADE modeli, dikkat mekanizmasının hesaplama maliyetini azaltırken, uzun dizilerde global ve lokal bağlamları daha verimli bir şekilde işlemesini sağlamıştır. SPADE, global bilgi yakalama kapasitesine sahip durum uzayı modellerini (State Space Models - SSM) kullanarak lokal dikkat yöntemleri ile birleştirmiştir. Bu yapı, modelin uzun cümlelerdeki bağımlılıkları ve lokal bilgileri etkili bir şekilde işlemesine yardımcı olur [41]. Aşağıdaki şekilde sol kısım modelin genel yapısını, sağ kısım ise global katmanın detaylarını gösterir.



Şekil 2.12 Spade Mimarisi


Chatbot uygulamaları, dikkat mekanizmasının sağladığı bağlamsal anlayıştan önemli ölçüde yararlanır. Özellikle uzun diyaloglar ve karmaşık kullanıcı girdileriyle başa çıkabilmek için, dikkat mekanizması her bir kelimenin veya ifadenin diğerleriyle olan ilişkisini anlamaya çalışır. Örneğin, dönüştürücü tabanlı bir Bengalce chatbot, dikkat mekanizmasının gücünden faydalanarak sekanslar arası ilişkiyi etkili bir şekilde öğrenmiş ve doğru cevaplar üretmiştir. Bu model, önceki Seq2Seq modellerine kıyasla belirgin bir performans artışı sağlamıştır [43].

Dikkat mekanizmasının en büyük katkılarından biri, chatbotların kullanıcılara daha doğal ve bağlamsal olarak doğru yanıtlar vermesini sağlamaktır. Seq2Seq modelleri geleneksel olarak girdileri sırayla işlerken, dikkat mekanizması ile bu modeller, girdinin herhangi bir kısmına odaklanarak daha hızlı ve doğru yanıtlar üretebilir. Chatbotların diyalogları anlaması ve uygun cevaplar vermesi için bu yapı büyük avantaj sağlar. Örneğin, bir chatbot kullanıcının belirli bir sorusuna yanıt verirken, sorunun tamamını ve önceki sorularla olan bağlamını dikkate alarak cevap üretir [43].

Dikkat mekanizması, uzun dizilerde etkili bir şekilde çalışsa da hesaplama maliyetinin artması, modelin performansını olumsuz etkileyebilir. Bu sorun, özellikle uzun metinler veya konuşma dizileriyle çalışırken belirgin hale gelir. Dikkat mekanizması, her bir kelimenin diğer tüm kelimelerle olan ilişkisini hesaplar ve bu da büyük veri kümeleri için büyük bir hesaplama maliyeti getirir. Bu sorunu aşmak için, sınırlandırılmış hafıza (bounded-memory control) yaklaşımı gibi yöntemler geliştirilmiştir. Bu yöntemler, dikkat mekanizmasının hafıza boyutunu sınırlayarak uzun dizilerde bile verimli bir işlem süreci sunar [44].

2.9 DİL MODELLERİNDE ÖLÇEKLENEBİLİRLİK VE BÜYÜK VERİ KÜMELERİYLE ETKİLEŞİM

Günümüzde GPT-3 ve Claude gibi dil modelleri milyarlarca parametre ile çalışmakta ve büyük veri kümeleri üzerinde eğitilmektedir. Bu süreçte en temel sorunlardan biri, bu devasa modellerin eğitilmesi için gereken GPU belleği ve hesaplama gücüdür. Örneğin, GPT-3'ün 175 milyar parametreliliği versiyonunun eğitilmesi tek bir NVIDIA V100 GPU ile 288 yıl sürebilir. Bu tür büyük modellerin eğitimini hızlandırmak için veri paralelliliği, tensor model paralelliliği ve pipeline model paralelliliği gibi teknikler kullanılmaktadır. Megatron-LM, bu alanda dikkat çeken bir örnektir ve model paralelliliği tekniklerini bir araya getirerek 1 trilyon parametreliliği modelleri binlerce GPU üzerinde etkili bir şekilde eğitmektedir [45]. Megatron-LM, 3072 GPU ile çalışarak 502 petaFLOP/s hızında bir performans sergilemiş ve eğitim sürecini 3 ay gibi bir süreye düşürerek önemli ölçüde kısaltmıştır.



Şekil 2.13 NLP Alanında En Gelişmiş Modellerin Yıllara Göre Gelişimi

Dil modelleri üzerinde paralel işlem yapabilmek için geliştirilen yöntemlerden biri de tensor model paralelliliğidir. Bu yöntem, her bir dönüştürücü katmanındaki matris çarpımlarını birden fazla GPU arasında böler. Tensor paralelliliği, tek sunucu üzerindeki GPU'lar için etkili olsa da daha büyük modellerin birden fazla sunucuya yayılması gerektiğinde, sunucular arası iletişim hızı düşmekte ve hesaplama verimliliği azalabilmektedir. Bu noktada pipeline model paralelliliği devreye girmekte ve modelin farklı katmanları GPU'lar arasında dağıtılmaktadır. Megatron-LM bu iki yöntemi veri paralelliliği ile birleştirerek PTD-P adı verilen yeni bir yaklaşım geliştirmiştir [45]. Bu yaklaşım, büyük dil modellerinin eğitimini hızlandırırken, hesaplama işlemlerinin RAM'e bağımlılığını da azaltmıştır. Böylece, büyük dil modellerinin eğitiminde lineer bir ölçekleme sağlanmış ve GPU'ların kapasitesi en üst düzeyde kullanılmıştır.

Büyük dil modellerinin eğitimi sırasında enerji tüketimi önemli bir problem olarak karşımıza çıkmaktadır. Örneğin, GPT-3'ün eğitimi 1.3 GWh enerji tüketmiştir ve bu, dil modellerinin enerji verimliliği açısından optimize edilmesi gerektiğini

göstermektedir. Bu konuda öne çıkan bir çözüm, geri yayılımsız eğitim yöntemleridir. Fiziksel nöral ağlar (PNN) gibi alternatif yöntemler, geleneksel dijital hesaplama sistemlerine göre daha az enerji tüketerek verimli bir şekilde eğitilebilmektedir. Bu yöntem, fiziksel sistemler üzerinde doğrusal olmayan dönüşümler gerçekleştirerek eğitimin verimliliğini artırır ve özellikle sinüzoidal dalga temelli sistemlerde kullanılabilir [46]. Geri yayılım yerine model-free forward-forward (MF-FF) eğitimi adı verilen bir teknik, derin fiziksel nöral ağların eğitimini daha hızlı ve daha az enerji tüketimi ile gerçekleştirmektedir. Bu teknik, eğitim sırasında dijital hesaplamalara olan bağımlılığı azaltarak dil modellerinin enerji verimliliğini artırır.

ChatGPT, dil modellerinin geniş veri kümeleri üzerinde eğitilmesinin gücünü sergileyen bir örnektir. Bu model, insan geri bildirimine dayalı pekiştirmeli öğrenme (Reinforcement Learning from Human Feedback - RLHF) yöntemiyle, kullanıcılardan alınan geri bildirimleri işleyerek modelin performansını artırır [32]. ChatGPT'nin başarısı, dil modellerinin sadece dil anlama görevlerinde değil, aynı zamanda geniş kapsamlı genel yapay zeka (Artificial General Intelligence - AGI) uygulamalarında da etkin olabileceğini göstermiştir. Bu süreçte büyük veri üzerinde eğitim almış dil modelleri, sıfır ve az örnekle öğrenme kabiliyetleriyle farklı alanlardaki görevlerde yüksek performans göstermektedir.


Büyük dil modelleri, veri paralelliği ve diğer ölçeklenebilirlik yöntemleri sayesinde chatbot uygulamalarında daha güçlü hale gelmektedir. GPT-3 ve Claude gibi modeller, milyarlarca parametrelili devasa sistemlerdir ve bu modellerin genel yapay zeka (AGI) hedefi doğrultusunda çeşitli görevlerde başarılı olabilmesi için büyük veri kümeleri üzerinde etkin bir şekilde eğitilmeleri gerekmektedir [38]. Dil modelleri, büyük veri üzerinde eğitim aldıklarında yalnızca dil anlama değil, aynı zamanda görsel ve işitsel veriler gibi farklı veri türleri üzerinde de etkili sonuçlar verebilir.

2.10 TRANSFER LEARNING'İN DİL MODELLERİNDE ENTEGRASYONU

Transfer öğrenme, büyük dil modelleri üzerinde önceden eğitilmiş parametrelerin yeni görevlerde tekrar kullanılmasını içerir. BERT ve GPT gibi modeller, genellikle büyük miktarda veri üzerinde önceden eğitilir ve bu süreçte genel dil bilgisi edinir. Bu sayede, ince ayar (fine-tuning) ile daha küçük veri setlerine adapte edilebilirler. Örneğin, BERT modeli, önceden genel amaçlı dil anlayışı için eğitildikten sonra, duygu analizi, metin sınıflandırma ve soru cevaplama gibi görevler için özelleştirilebilir. Bu süreç,

modelin parametrelerinin belirli bir görev doğrultusunda yeniden optimize edilmesiyle gerçekleştirilir [47].

Han ve diğerleri, Robust Transfer Learning with Pretrained Language Models through Adapters adlı çalışmalarında transfer öğrenmenin en yaygın yöntemlerinden birinin, önceden eğitilmiş modellerin parametrelerinin tamamen güncellenmesini içerdiğini, ancak bu yaklaşımın bazı sorunlara yol açabileceğini belirtmişlerdir. Özellikle modelin belirli görevlerde aşırı uyum göstermesi (overfitting) ve eğitim sürecinde kararsızlık gibi problemler yaşanabilir. Bu sorunları aşmak için yazarlar, BERT gibi modellerin katmanlarına küçük adaptörler ekleyerek sadece bu adaptörlerin güncellendiği bir yöntem önermektedirler. Bu yaklaşım, modelin orijinal parametrelerini koruyarak daha kararlı bir öğrenme süreci sağlar ve parametre verimliliğini artırır [47].



Şekil 2.14 Adaptör Mimarisi Eklenen ve Eklenmeyen BERT Modellerinin, Farklı Rastgele Başlangıçlarda Elde Edilen Doğruluk Skorlarının Dağılımı

Daha önce bahsettiğimiz BERT'in çift yönlü bir dil modeli olma özelliği sayesinde ince ayar yapılmış bir BERT modeli, dil anlama görevlerinde yüksek performans gösterir. Li ve arkadaşları, Story Ending Prediction by Transferable BERT adlı çalışmalarında, BERT'in hikaye tamamlama gibi karmaşık görevlerde başarılı olabilmesi için transfer öğrenme yöntemini kullanmışlardır. Burada, doğal dil çıkarımı (NLI), duygu sınıflandırması ve sonraki eylem tahmini gibi benzer görevlerden elde edilen bilgilerin, BERT modeli üzerinde nasıl aktarılacağı ve modelin performansının nasıl artırılacağı araştırılmıştır. Bu çalışma, BERT'in sadece genel dil bilgisiyle değil, aynı zamanda belirli görevlerde de başarıyla kullanılabilirliğini göstermiştir [48].

Transfer Öğrenmenin Chatbot Geliştirme Süreçlerindeki Rolü Chatbot geliştirme sürecinde transfer öğrenmenin kullanılması, modellerin adaptasyon sürecini hızlandırmakta ve daha az veri ile yüksek performans elde edilmesini sağlamaktadır.

Özellikle BERT ve GPT modelleri, transfer öğrenme teknikleri ile eğitilerek chatbotların daha verimli ve etkili bir şekilde çalışmasına olanak tanır. Sentiment Analysis of Reviews in Kazakh with Transfer Learning Techniques adlı çalışmada, Kazakça metinler üzerinde duygu analizi yapılmış ve transfer öğrenmenin kaynağı az olan dillerde bile etkili sonuçlar verdiği gösterilmiştir. Bu durum chatbotların farklı dillerde çalışabilmesi için transfer öğrenmenin önemli bir araç olduğunu vurgulamaktadır [49].

Ajagbe ve Zhao (2022), Retraining a BERT Model for Transfer Learning in Requirements Engineering adlı çalışmalarında, transfer öğrenmenin belirli alanlara nasıl uygulanabileceğini göstermiştir. BERT modeli, gereksinim mühendisliği(Requirements engineering) alanında yeniden eğitilerek, daha dar bir alandaki görevlerde yüksek performans elde etmiştir. Bu yöntem, chatbot geliştirme süreçlerinde de kullanılabilir; örneğin müşteri destek chatbotları, belirli sektörlerdeki (finans, sağlık vb.) müşteri taleplerine daha uygun yanıtlar verebilmek için transfer öğrenme ile özelleştirilebilir [50].

Transfer öğrenme, sadece performans iyileştirmeleri sağlamakla kalmaz, aynı zamanda eğitim sürecinde zaman ve maliyet avantajları da sunar. Wang (2023), A New Computationally Efficient Method to Tune BERT Networks – Transfer Learning adlı çalışmasında, transfer öğrenmenin ince ayar süreçlerine kıyasla çok daha verimli olduğunu belirtmiştir. Transfer öğrenme, BERT gibi büyük modellerin ince ayar gerektiren parametrelerini minimumda tutarak eğitim süresini önemli ölçüde kısaltır. Bu durum, özellikle sınırlı veri ve sınırlı donanım koşullarında transfer öğrenmenin chatbot geliştirme süreçlerinde oldukça avantajlı olduğunu göstermektedir [51].

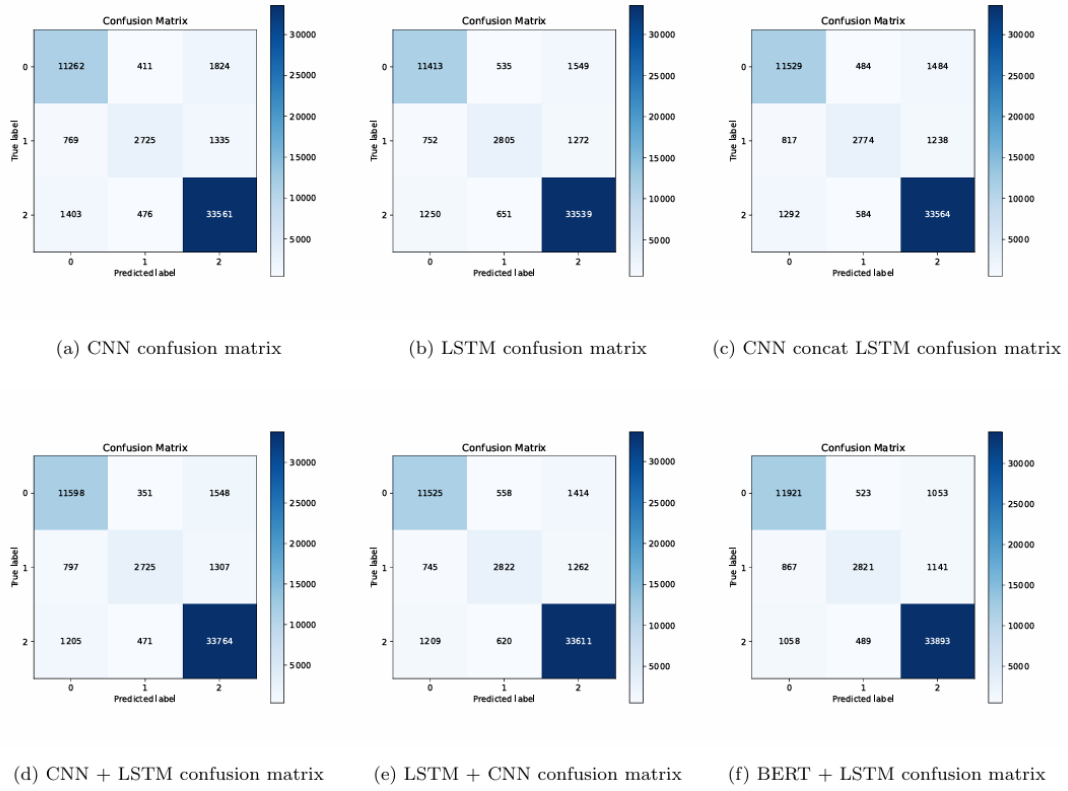
BÖLÜM 3 İLGİLİ ÇALIŞMALAR

Bu bölümde sağlık sektöründe daha önce yapılan chatbot çalışmalarına yer verilmiştir. Yapılan araştırma çerçevesinde sağlık sektöründe chatbot uygulamaları hem akademik hem de sektörel anlamda gelişim sağladığı ve gün geçtikçe önem kazandığı gözlemlenmiştir.

3.1 BERT İLE GELİŞTİRİLEN CHATBOT'LARIN SAĞLIK SEKTÖRÜNDEKİ UYGULAMALARI

Son yıllarda NLP ve AI alanında kaydedilen önemli ilerlemeler, sağlık sektöründe büyük bir dönüşüm yaratmıştır. Özellikle sağlık sektöründeki incelemelere dayanan veri setlerinin analizi, ilaç güvenliği ve kullanıcı deneyimini iyileştirme açısından kritik öneme sahiptir. Çalışmanın bu kısmında, BERT tabanlı modellerin ilaç ve vitamin sektöründe nasıl kullanıldığını inceleyerek, chatbot tasarımında derin öğrenme tekniklerinin uygulamalarını ve sonuçlarını değerlendirecektir.

Sağlık sektöründeki chatbot çalışmaları incelemelerinin doğal dil işleme ile analiz edilmesi, kullanıcıların tedavi süreçlerinde yaşadıkları deneyimlerden elde edilen büyük miktardaki metinsel veriyi anlamlandırmak için önemlidir. NLP'nin en önemli görevlerinden biri olan duygu analizi, kullanıcıların ilaç veya vitamin ürünleriyle ilgili olumlu ya da olumsuz yorumlarını sınıflandırmak amacıyla kullanılır. İlaç incelemelerine yönelik bu tür analizler, ilaç kullanım güvenliği sistemlerini iyileştirmede daha bilinçli kararlar almada kritik bir rol oynar [52].



Şekil 3.1 İlaç İncelemeleri Üzerine Yapılan Duygu Analizinde Kullanılan Modellerin Confusion Matrisleri


BERT, önceki NLP modellerine kıyasla daha derin ve bağlamsal bir dil anlayışı sağlayarak bu alanda devrim niteliğinde bir adım atmıştır. BERT'in teknik alt yapısı, özellikle ilaç incelemelerinde geçen karmaşık ve teknik terimlerin daha doğru bir şekilde anlamlandırılmasını sağlar [53]. Örneğin, bir hasta "bu ilaç yan etkileri çok kötüydü" şeklinde bir yorum yaparsa, BERT modeli bu cümledeki "yan etkiler" ve "kötü" kelimeleri arasındaki ilişkiyi daha iyi anlamlandırabilir ve bu yorumu negatif bir duygu ile sınıflandırabilir.

BERT tabanlı chatbotlar, kullanıcıların sağlık alanı hakkında sorduğu karmaşık sorulara yanıt vermek ve kullanıcılara kişiselleştirilmiş sağlık tavsiyeleri sunmak için güçlü bir araçtır. Geleneksel chatbot sistemlerinde, yanıtlar genellikle sabit kurallara dayanırken, BERT gibi derin öğrenme tabanlı modeller, metin bağlamını daha iyi anlayarak çok daha esnek ve dinamik cevaplar üretebilir. Örneğin, bir kullanıcı "Bu vitaminin yan etkileri nelerdir?" gibi bir soru sorduğunda, BERT modeli, yanıt ilgili veri setinden anlamlı bir şekilde çıkarabilir ve kullanıcının ihtiyacına yönelik spesifik bir yanıt sunabilir [54].

BERT tabanlı chatbotların sağlık sektöründeki en büyük avantajlarından biri, ilaç incelemelerinden elde edilen karmaşık veri kümelerini analiz edebilme kabiliyetidir.

Derin öğrenme teknikleri sayesinde, büyük miktarda yapılandırılmamış veri hızlı ve doğru bir şekilde işlenebilir. Ayrıca, BERT'in çift yönlü bağlamsal anlayışı, bu tür verilerin daha önceki yöntemlerle mümkün olmayan bir doğrulukla sınıflandırılmasına olanak tanır [55].

Geleneksel yöntemler arasında yer alan LSTM ağları, sırayla işlenen verilerde geçmiş bilgiyi hafızada tutma yeteneği ile tanınır. Ancak LSTM, özellikle küçük veri setlerinde hızlı ve etkili olsa da büyük veri setleri ve karmaşık dil yapılarını işlemek söz konusu olduğunda sınırlı kalmaktadır. BERT'in farkı, dil modelini hem geçmiş hem de gelecek kelimeler üzerinden eğitebilmesidir, bu da onun daha zengin bir bağlamsal anlayış sunmasını sağlar. Örneğin, küçük bir veri seti üzerinde yapılan bir çalışmada, LSTM daha kısa eğitim süresi ile daha yüksek doğruluk elde etmesine rağmen, büyük veri setlerinde BERT'in daha üstün performans gösterdiği gözlemlenmiştir [56].



Şekil 3.2 LSTM ve BERT Modellerinin Küçük Bir Veri Seti Üzerindeki Test Setindeki Doğruluk Oranları

BERT'in sağladığı bu avantajlar, büyük miktarda veri bulunan sağlık sektöründeki chatbot'larda inceleme setlerinde kendini gösterir. Özellikle çok sayıda inceleme içeren geniş veri kümelerinde BERT, dil modelleme yetenekleri sayesinde daha doğru sınıflandırma yaparak ilaçların yan etkileri hakkında daha net bilgiler sunar [53].


Sağlık sektöründe chatbotlar, kullanıcıların bu ürünlerle ilgili sorularına yanıt vermek, kişiselleştirilmiş tavsiyeler sunmak ve hatta ilaç yan etkilerini veya dozaj bilgilerini sağlamak için yaygın olarak kullanılmaktadır. Özellikle sağlık sektöründe kullanılan chatbotlar, BERT gibi gelişmiş modeller sayesinde, kullanıcılarla doğal ve anlamlı bir diyalog kurarak onlara ihtiyaç duydukları bilgiyi anında sunabilir [54]. Bu tür

sistemler, yalnızca hasta deneyimini iyileştirmekle kalmaz, aynı zamanda sağlık profesyonellerinin de iş yükünü azaltarak daha verimli çalışmalarını sağlar.

3.2 CLAUDE İLE GELİŞTİRİLEN CHATBOT'LARIN SAĞLIK SEKTÖRÜNDEKİ UYGULAMALARI

Claude ve benzeri teknolojilerle oluşturulan chatbot'lar, sağlık sektöründe çeşitli rollerde kullanılan güçlü araçlar olarak öne çıkmaktadır. Özellikle teşhis, tedavi önerileri ve hasta takibi gibi süreçlerde Claude'un sağladığı avantajlar, birçok akademik çalışmada incelenmiştir. Örneğin, baş-boyun kanserlerinin teşhis ve tedavisinde Claude 3 Opus, multidisipliner tümör kurulu (MDT) ile uyumlu sonuçlar vermiştir. Claude, teşhis doğruluğu açısından ChatGPT 4.0'ı geride bırakmış ve tedavi önerilerinde de MDT kararlarına yakın bir performans sergilemiştir [57].

Sağlık alanında Claude'un chatbot gibi hizmetlerde kullanılabilirliği, diğer teknolojilerle kıyaslandığında fark oluşturmaktadır. Özellikle miyop önleme ve kontrolü üzerine yapılan bir araştırmada Claude, halk sağlığı sorularına kapsamlı ve doğru yanıtlar vererek etkin bir sağlık aracı olarak değerlendirilmiştir. Claude'un, kamu sağlığı alanında ChatGPT ve Bard(Gemini) gibi diğer chatbot'larla kıyaslandığında özellikle bilgi doğruluğu açısından olumlu sonuçlar verdiği tespit edilmiştir [58].



Şekil 3.3 ChatGPT, Claude ve Bard'ın Karşılaştırması

Claude sadece sağlık alanında değil, eğitim alanında da giderek artan bir role sahiptir. Özellikle kimya gibi ağır derslerde, öğrencilerin öğrenmelerini destekleyen bir “düşünme aracı” olarak Claude'un kullanımı incelenmiştir. Yapılan çalışmada

Claude'un, kimya dersini sevdirmeye yönelik bir yaklaşım sunarak öğrencilerin problem çözme ve eleştirel düşünme becerilerini geliştirmelerine katkı sağladığı görülmüştür. Bu bulgu, Claude'un eğitimde Bing Chat ve Bard gibi diğer chatbot'larla karşılaştırıldığında olumlu bir performans sergilediğini göstermektedir [59].

Yapay zekâ chatbot'larının “öğrenme arkadaşı” olarak kullanılmasına yönelik bir çalışmada Claude, diğer chatbot'larla kıyaslandığında bilgi doğruluğu ve öğrenci etkileşimini artırıcı özellikler sunmuştur. Bu çalışma, Claude'un yalnızca bilgi sağlamakla kalmayıp, öğrencileri düşünmeye sevk eden sorular sorarak yapılandırmacı öğrenmeyi desteklediğini göstermiştir [60].


Tıp eğitiminde de Claude'un katkıları giderek daha belirgin hale gelmektedir. Nefroloji gibi zorlu bir tıp alanında yapılan bir çalışmada, Claude'un çoktan seçmeli test sorularını yanıtlama yeteneği incelenmiş ve Claude'un GPT-4'e kıyasla yüksek bir başarı oranına sahip olduğu gözlemlenmiştir. Bu bulgu, Claude'un tıp eğitimi için potansiyel bir öğrenme ve öğretim aracı olabileceğini göstermektedir [4]. Claude'un insan fizyolojisi gibi karmaşık tıbbi alanlarda da başarılı olduğu, başka bir çalışmada tespit edilmiştir. Bu çalışmada Claude, kavramsal çoktan seçmeli sorulara doğru ve kapsamlı yanıtlar sağlama kapasitesi ile ChatGPT-3.5'e göre daha iyi performans göstermiştir. Claude'un bu özellikleri ışığında, tıp eğitiminde öğrencilerin gelişiminde kritik bir araç olduğunu belirtmeliyiz [5].

Ayrıca, Claude gibi chatbot'ların, çeşitli klinik senaryolarda kullanıcıların psikososyal destek almasına olanak tanıyan bir araç olarak kullanılabilirliği de düşünülmektedir. Bir çalışmada Claude'un performansı meme kanseri hastaları için psikososyal destek, tedavi planlama ve prognostik bilgilendirme gibi alanlarda analiz edilmiştir. Bu tür desteklerin sağlanmasında Claude, karmaşık durumları algılama ve uygun tepkiler verme yeteneği sayesinde hasta bakımında da yardımcı olabileceğini göstermiştir [61]. Ek olarak, yapay zekâ destekli chatbot'ların klinik ortamda kullanılabilirliğini değerlendiren bir başka çalışmada Claude'un, enfeksiyon hastalıkları ve mikrobiyoloji gibi zorlu klinik durumlarda başarılı sonuçlar verdiği görülmüştür. Çalışmada Claude, özellikle bilgi doğruluğu, kapsamlılık ve klinik uyum açısından etkili performans göstermiştir. Bu durum, Claude'un sağlık sektöründe profesyonel danışmanlık ve klinik destek hizmetlerinde potansiyel bir araç olarak kullanımını desteklemektedir [62].

3.3 GEMINI İLE GELİŞTİRİLEN CHATBOT'LARIN SAĞLIK SEKTÖRÜNDEKİ UYGULAMALARI

Modern yapay zekâ destekli chatbot'lar, sağlık sektörü içinde teşhis, tedavi desteği ve hasta takibi gibi alanlarda geniş bir uygulama alanı bulmaktadır [63]. Gemini özellikle tıbbi görüntüleme sistemlerinde yüksek doğruluk oranı ile dikkat çekmiştir. Bu orandan dolayı Gemini'nin GPT-4 ve Copilot gibi diğer büyük dil modellerini göre daha üstün bir performans gösterdiğini söyleyebiliriz [64].

Gemini'nin başarısı, farklı dillerdeki performansına da yansımaktadır. Okülofasiyal plastik ve orbital cerrahi alanında yapılan bir çalışmada, Gemini'nin İngilizce sorularda %46,7 ve Türkçe sorulardaysa %33,3 doğruluk oranı gösterdiği tespit edilmiştir. Bu bulgular, Gemini'nin farklı dillerde uyum sağlaması gerektiğine işaret etmektedir [65].



Şekil 3.4 ChatGPT-3,5, Copilot ve Gemini'nin İngilizce ve Türkçe Soruları Doğru Cevaplama Düzeyleri

Gemini'nin sağlık uygulamaları için geliştirilme süreçleri, tıbbi bilgiye dayalı yanıtlar sunabilme ve doğal dil işleme becerilerini en iyi şekilde kullanma üzerine odaklanmaktadır. Bu anlamda, bir chatbot yapılacağı zaman dikkat edilmesi gereken dört ana husus şöyledir; metin anlama, diyalog yönetimi, veritabanı yönetimi ve metin üretimi. Sağlık alanında kullanılan chatbot'ların teknik yönleri, özellikle sağlık verilerinin doğru ve güvenilir bir şekilde işlenmesini sağlayan çeşitli algoritmalarla desteklenmelidir [66].

BÖLÜM 4 TÜRKÇE CHATBOT TASARIMINDA SBERT, CLAUDE VE GEMINI

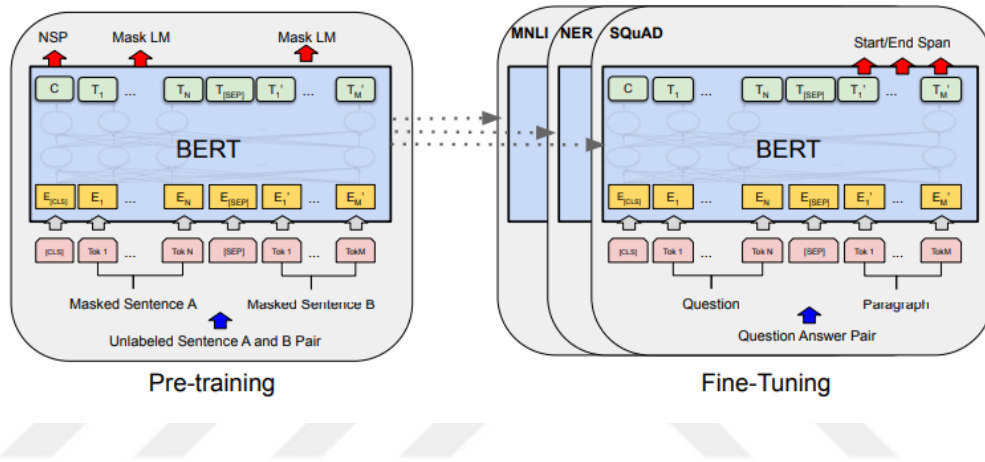
NLP bilgisayarların insan dilini anlama, yorumlama ve uygun yanıtlar üretme yeteneğini kazanmalarına olanak tanır. Türkçe gibi sondan eklemeli dillerde chatbot tasarımı ve dilin yapısal özellikleri nedeniyle özel zorluklar taşır. Bu nedenle Türkçe chatbot geliştirmede, bağlama duyarlı dil modelleri ve NLP teknikleri kullanılması oldukça önemlidir.

4.1 SBERT VE BERT MODELLERİNİN CÜMLE TEMSİLİ VE ANLAMLANDIRMA ÜZERİNE FARKLILIKLARI

BERT, iki ana aşamadan oluşur, bunlar pre-training ve fine-tuning'dir. Pre-training aşamasında model, çok büyük miktarda veride iki görevi yerine getirir, bu da maskeleyme (masked language modeling) ve cümle çiftleri arasındaki ilişkiyi tahmin etme'dir (next sentence prediction). Aşağıdaki şekilde de görüldüğü üzere, BERT iki cümlelik girişlerle eğitilir (Masked Sentence A ve Masked Sentence B) ve bu cümleler arasında ilişki kurmaya çalışır. Daha sonra ince ayar yani fine-tuning kısmına geçilir. Bu kısımda cümleler arasındaki ilişkiyi anlamak için MNLI (Multi-Genre Natural Language Inference) kullanılır. MNLI, iki cümle arasındaki ilişkinin sınıflandırıldığı bir görevdir. Bu ilişki üç sınıfa ayrılır. MNLI'da ilk sınıf çıkarım (entailment) olarak adlandırılır. İlk cümle (hipotez) ikinci cümleden (öncül) çıkarılabilir. Yani, ikinci cümle doğruysa, birinci cümle de doğru olmalıdır. Bir diğer sınıf çelişki (contradiction) sınıfıdır. İlk cümle, ikinci cümle ile çelişir. Yani, eğer ikinci cümle doğruysa, birinci cümle yanlış olmalıdır. Son olarak nötr (neutral) sınıfı vardır. İki cümle arasında ne çıkarım ne de çelişki vardır; cümleler birbirinden bağımsız bilgi içerir. MNLI görevinde BERT, iki cümlelik girişleri alır ve bu cümleler arasındaki ilişkiyi az önce belirtilen üç sınıftan biri olarak sınıflandırır. Daha sonra belirli varlıkları tanımlama görevi olan NER (Named Entity Recognition) gelir. NER görevi, bir metin içindeki belirli türdeki varlıkları (örneğin, kişi adları, organizasyonlar, tarihler) tanımlamayı amaçlar. Ardından soru cevap görevleri için kullanılan bir veri kümesi olan SQuAD (Stanford Question Answering Dataset) gelir. SQuAD, bir metin (paragraf) ve bir soru çiftinden oluşur. BERT, metni ve soruyu birlikte işler ve cevabın başlangıç ve bitiş konumlarını tahmin eder. Bu, BERT'in soru-cevap görevlerinde metnin anlamını ve sorunun bağlamını anlayarak doğru cevabı bulmasına olanak tanır.

BERT, bu görevler için önceden eğitilmiş katsayılarla başlar ve ardından göreve göre fine tuning yapılır.

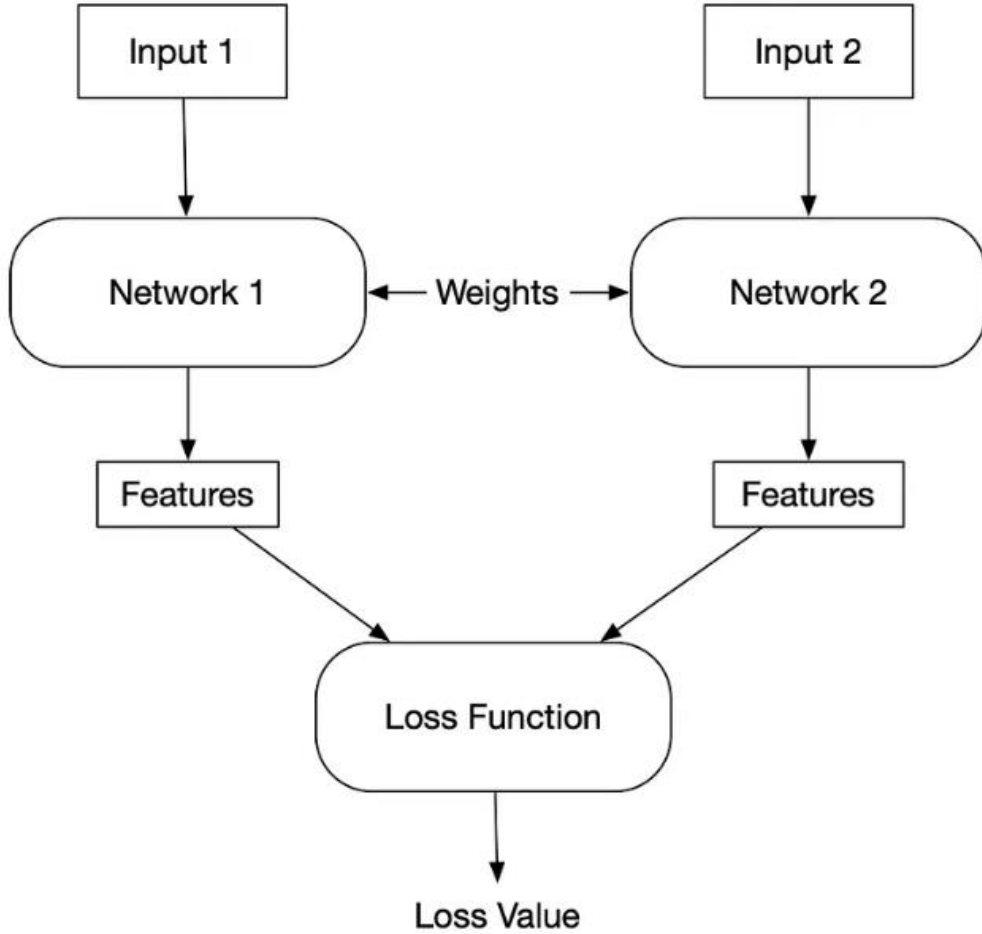
Bu görevler sayesinde BERT, bağlama dayalı anlamlandırmada oldukça yüksek bir doğruluk elde eder. BERT'in Türkçe chatbotlarda kullanılabilirliği, dilin gramatik özelliklerinin yanı sıra cümle içindeki kelimelerin anlamını bağlamdan çıkarsayabilme becerisiyle güçlü bir performans sergiler. Ancak, BERT'in bu iki yönlü yapısı büyük bir veri işlem yükü getirmektedir ve cümleler arası hızlı anlam benzerliği karşılaştırmaları için daha hafif bir yapıya ihtiyaç duyulmaktadır.



Şekil 4.1 BERT Diyagramı

SBERT, yani Sentence-BERT BERT'in bir türevi olup, cümleler arası anlam benzerliğini hızlı bir şekilde hesaplamak için optimize edilmiştir. Tezde https://huggingface.co/turkish-nlp-suite/tr_core_news_md/resolve/main/tr_core_news_md-1.0-py3-none-any.whl modelinden yararlanılmıştır. SBERT, BERT modelinin iki katmanlı (siamese network) yapı kullanılarak cümle temsillerini hesaplamasına olanak tanır. Bu, modelin anlam benzerliği bulma gibi görevlerde hem daha hızlı hem de daha doğruluğa sahip olmasını sağlar. SBERT, özellikle cümlelerin anlamlarını tek bir vektörde özetleyerek, veri işlemede hız kazandırır ve chatbotlarda daha hızlı yanıt verebilme olanağı tanır. Bu da Türkçe gibi karmaşık dil yapısına sahip dillerde anlam odaklı yanıt üretmek için oldukça faydalıdır. SBERT'in bu yaklaşımı, chatbotlarda yaygın olarak kullanılan soru-cevap sistemlerinde önemli bir avantaj sağlar. Siamese ağlarının mimarisi aşağıdaki gibidir. Birbirinden bağımsız iki input (iki cümle veya iki görüntü olabilir) ağ'a verilir. Bu iki ağ, aynı ağırlıklara sahip iki özdeş sinir ağıdır. Input'ları işleyip, belirli özellik vektörlerini çıkarır. Bu ağlar, iki input örneğini aynı özellik uzayına

dönüştürmek için eğitilir. Weight her iki ağın ağırlıklarının paylaşıldığını belirtir. Bu, her iki ağın aynı parametreleri kullanarak çıktılarının karşılaştırılmasını sağlar. Features her iki ağın girişlerden çıkardığı özellik vektörlerini ifade eder. Bu vektörler, genellikle girişlerin düşük boyutlu bir temsildir. Özellik vektörleri, belirli bir loss function'a göre değerlendirilir. Loss function, genellikle bu iki özellik vektörü arasındaki mesafeyi veya benzerliği ölçer. Örneğin, Cosine Similarity veya Euclidean Distance kullanılabilir. Loss function ile elde edilen bir loss value değeri çıkar. Bu değer, ağın ne kadar iyi performans gösterdiğini belirlemek için kullanılır ve ağın geri yayılım sırasında bu değeri minimize etmeye çalışır. Bu mimari, cümle veya görüntü çiftleri arasındaki benzerlikleri veya farklılıkları öğrenmek için SBERT'te kullanılır. BERT ise bu mimariyi kullanmaz.



Şekil 4.2 SBERT Diyagramı

BERT ve SBERT arasındaki temel fark, cümle temsili üretme ve hız optimizasyonudur. BERT, her kelimeyi diğer tüm kelimelerle ilişkili olarak bağlam içinde değerlendirirken, SBERT daha yalın bir cümle temsili sunar ve benzerlik

karşılaştırmaları gibi işlemler için optimize edilmiştir. BERT'in çalışma mantığı yüksek hesaplama maliyeti doğurur. SBERT, BERT'in bu hesaplama maliyetini düşürerek daha hızlı cümle benzerliği karşılaştırmaları için geliştirilmiştir. Bu, özellikle soru-cevap sistemlerinde ve chatbotlarda hızlı yanıt üretme gerektiren uygulamalar için idealdir. SBERT, vektör temsilleri aracılığıyla iki cümle arasındaki anlam benzerliğini tek bir skaler değerle hesaplayarak BERT'e kıyasla yüksek hız sağlar. Bu sayede SBERT, chatbot yanıtlarının doğruluğunu ve hızını artırarak kullanıcı etkileşimlerinin daha akıcı bir şekilde gerçekleşmesine olanak tanır. Bu nedenle de çalışmalarımızı SBERT ile sürdürdük.

4.2 NLP SÜREÇLERİNDE CLAUDE VE GEMINI KULLANIMI

Claude, doğal dil işleme süreçlerini yönetmek için özel olarak geliştirilmiş bir araçtır. Özellikle bağlamsal anlamlandırma ve doğal dil işleme işlevlerini geliştiren Claude, kullanıcı geri bildirimlerini analiz etmek ve daha iyi bir kullanıcı deneyimi sağlamak amacıyla yapılandırılmıştır. Türkçe dilinde chatbot tasarımı için Claude API, metinlerin hızlı ve doğru bir şekilde işlenmesine olanak tanır. Ayrıca Claude, kelimelerin bağlam içindeki anlamlarını derinlemesine analiz ederek daha doğal ve anlamlı yanıtlar üretir. Yapılan çalışma sonrası Chatbot'umuzun Claude API ile kullanıcı girdilerini anlaması, geri bildirimlerini işlemeye yönelik süreçlerde büyük fayda sağladığı gözlemlenmiştir.

Gemini, Google tarafından geliştirilen ve çok dilli dil modellerine destek veren bir platformdur. Gemini, NLP süreçlerinde daha esnek bir altyapı sunar. Gemini API'nin sunduğu çok dilli destek, Türkçe chatbot tasarımında Claude API ile kıyaslandığında daha geniş bir uygulama alanı sağlar. Gemini API, özellikle yüksek doğruluk gerektiren görevlerde metin işleme hızı ve doğruluğu bakımından dikkat çeker. Chatbot geliştirme sürecimizde Claude ve Gemini API'nin kullanımı, Türkçe gibi yapı itibarıyla zor bir dilde doğal bir kullanıcı deneyimi oluşturmak için önemli katkı sağladığı gözlemlenmiştir.

Bu çalışmada, hazır API'ler olan Gemini ve Claude'u kullanarak dil işleme süreçlerini hızlandırdık ve büyük veri setleri üzerinde hızlı sonuçlar elde ettik. Ancak, kendi geliştirdiğimiz model için SBERT'i kullanmamızın nedeni, SBERT'in özellikle cümleler arası anlam benzerliğini hesaplama konusunda optimize edilmiş olmasıdır. Claude ve Gemini gibi API'ler genel amaçlı kullanım için yüksek doğruluk sunarken,

SBERT, vektör tabanlı cümle temsiliyle daha hızlı cümle karşılaştırmaları yapmamıza olanak tanıdı. Bu tercih, araştırma sürecimizde fiili hesaplamalar ve performans analizleri yapmamıza imkan tanıdı. Böylece chatbotumuzun yanıt hızını ve doğruluğunu artırarak daha özel bir optimizasyon süreci gerçekleştirdik.

4.3 SBERT, CLAUDE VE GEMİNİ API İLE TÜRKÇE CHATBOTLARDA BAĞLAM UYUMLU YANITLAR

Türkçe gibi kompleks bir yapıya sahip dillerde chatbot tasarımında kullanılacak dil modellerinin doğruluğu ve hız performansı, kullanıcı deneyimini doğrudan etkileyen unsurlardır. Dil modellerinin Türkçeye uygun versiyonlarının Claude ve Gemini API ile entegrasyon süreci, chatbotun daha hızlı ve anlamlı yanıtlar üretebilmesini sağlar. Örneğin, SBERT'in Türkçe veriler üzerinde eğitilmesi, chatbot tasarımında anlam benzerliğini doğru bir şekilde belirleyebilmek açısından önemlidir. Ayrıca Claude ve Gemini API'lerinin Türkçe dil yapısına uygun özelliklerle kullanılması, chatbotların bağlama uygun ve doğal tepkiler vermesini mümkün kılar.

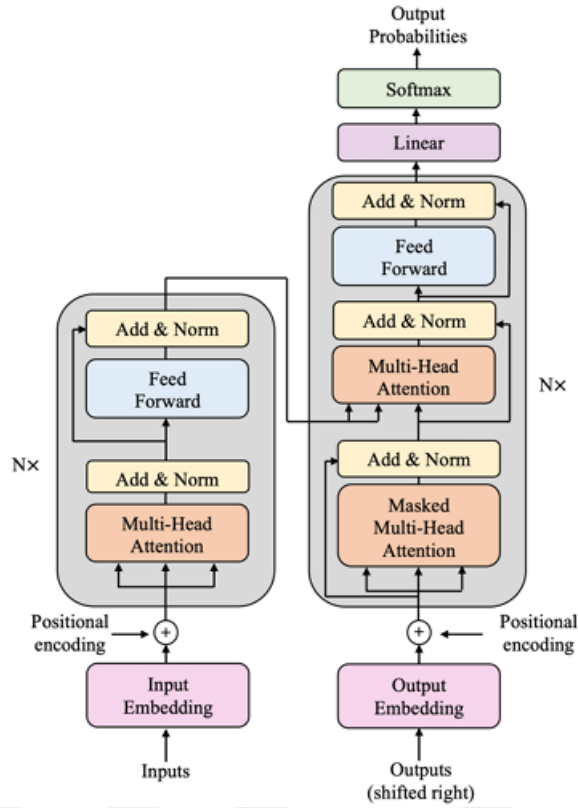
Özellikle Claude API'nin bağlamsal analiz yetenekleri, Gemini API'nin geniş çoklu dil desteği ile birleştiğinde, chatbotların kullanıcı ihtiyaçlarına göre özelleştirilmiş ve akıcı bir şekilde yanıt üretmesi sağlanır. BERT ve SBERT'in Claude ve Gemini API'lerle uyumu, kullanıcı deneyimini zenginleştirir ve dil modellerinin karmaşık Türkçe yapısına adapte edilmesini kolaylaştırır. Bu nedenle tezimizde SBERT, Claude ve Gemini gibi teknolojilerden yararlanılmıştır. Bu teknolojileri veri setimizle besleyerek süreçlerimizde ilerlenmiştir.

4.4 NLP'DE TÜRKÇE DİLİNİN MORFOLOJİK ZORLUKLARI

Türkçe dilinde NLP süreçleri, dilin yapısal özelliklerinden kaynaklanan birtakım zorluklar barındırır. Türkçe sondan eklemeli bir dil olarak, kelimelerin köklerine farklı eklerin eklenmesiyle anlamın değişmesine ve yeni kelimeler türetilmesine olanak tanır. Bu durum, dil modelleme ve metin işleme görevlerinde eklemeli diller için uyarlanmış özel teknikler geliştirilmesini gerekli kılar. Bu bölümde, Türkçe'nin morfolojik zenginliğinden doğan bu zorlukların NLP üzerinde yarattığı etkileri inceleyeceğiz.

Gemirter ve Goularas'ın (2021) çalışması, Türkçe dilindeki soru-cevaplama sistemlerinde bu sorunun nasıl üstesinden gelinebileceğine dair bir çözüm önerir. Çalışmada, BERT tabanlı bir model, Türkçe'nin bağlama duyarlı anlamını daha iyi

kavrayabilmesi için fine-tuning yapılarak optimize edilmiştir. Bu sayede, soru-cevaplama görevinde yüksek bir başarı elde edilmiştir [67].



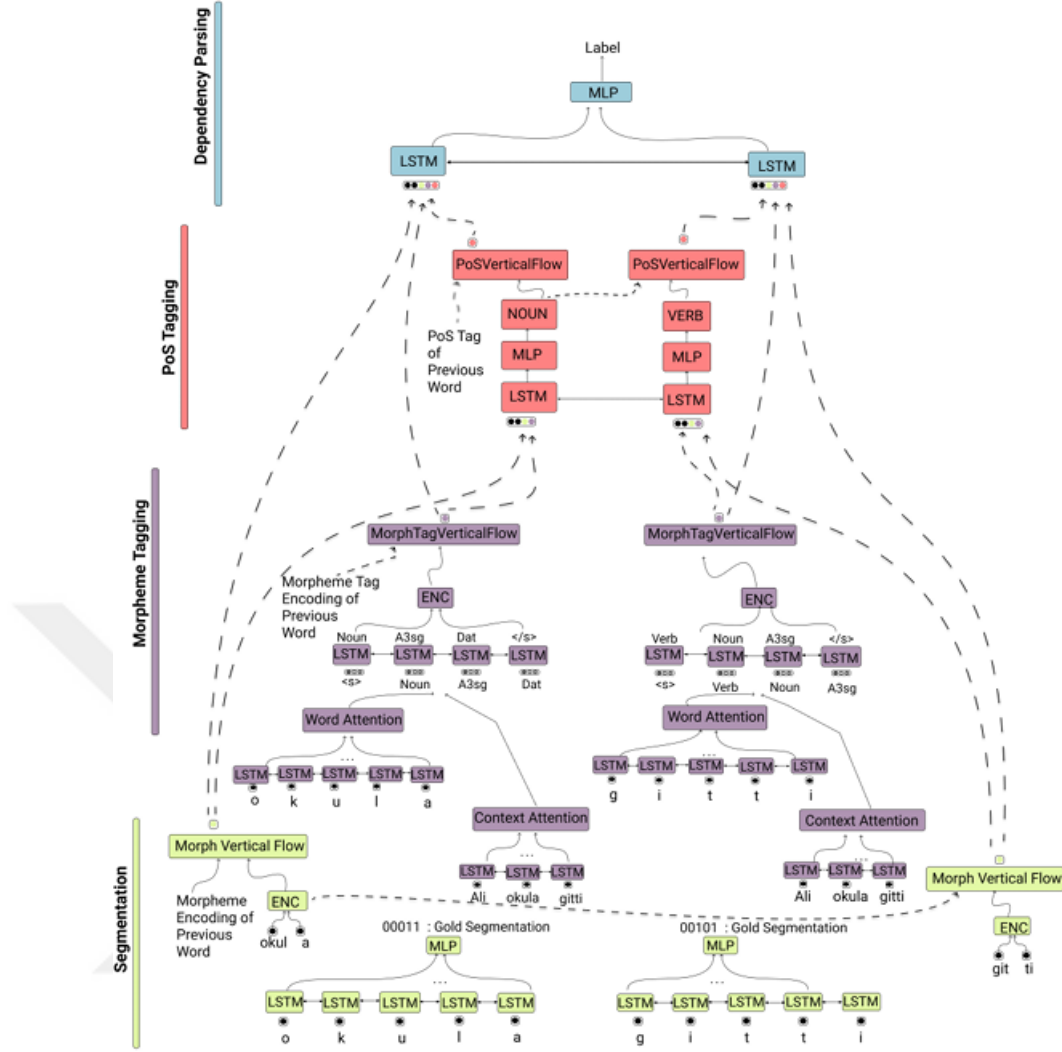
Şekil 4.3 Bankacılık Sektörüne Özgü Closed-Domain BERT Tabanlı Türkçe Soru Cevaplama Sisteminin Eğitim ve Fine Tuning Aşamaları

Bunun yanında, duygu analizi gibi NLP görevlerinde Türkçe'nin morfolojik yapısı, metin ön işleme süreçlerinin kapsamını genişletir. Görmez ve arkadaşlarının (2024) çalışmasında duygu analizi için kullanılan ön işleme tekniklerinin model performansı üzerindeki etkileri incelenmiştir. Türkçe'nin sondan eklemeli yapısının metinleri gürültüye duyarlı hale getirdiği ve kullanıcı verilerinde dilbilgisi kurallarına uyulmadığında analiz sürecinde bozulmaların meydana geldiği vurgulanmıştır. Bu nedenle, metinlerin anlam bütünlüğünü korumak adına ön işleme sürecinde normalizasyon, kök bulma ve ek ayrıştırma gibi teknikler kullanılmaktadır [68].

Türkçe'de çok sınıflı sınıflandırma görevlerinde karşılaşılan sorunlar, dilin sondan eklemeli yapısı ve zengin morfolojik özellikleriyle ilişkilidir. Özkan ve Kar'ın (2022) çalışması, BERT tabanlı bir modelin Türkçe bilimsel metinleri sınıflandırmak için nasıl adapte edildiğini açıklar. BERT modeli bağlamsal anlamı değerlendirerek çok sınıflı sınıflandırma görevlerinde etkili bir performans sergilemiştir. Bu çalışmada, Türkçe diline özgü ince ayarlar yapılarak doğruluk oranı %96 gibi yüksek bir seviyeye

ulařtırılmıřtır. Bunun temel sebebi, BERT'in dilin baęlamını her iki yönden de deęerlendirme yeteneęine sahip olmasıdır [69].

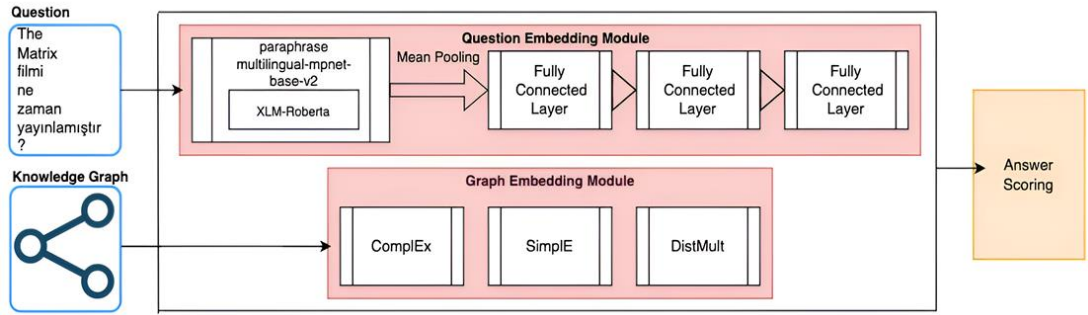
Dil modelleme ve metin iřleme görevlerinde morfolojik segmentasyon ve etiketleme, Türkçe için önemli bir zorluk olarak öne çıkar. Aleçakır ve arkadaşları (2022), bu soruna yönelik olarak TürkçeDelightNLP adlı bir araç geliřtirmiřtir. Bu araç, morfolojik segmentasyon, morfolojik etiketleme, adlandırılmıř varlık tanıma ve baęımlılık çözümlemesi gibi çeřitli NLP görevlerini bir arada gerçekleřtirerek, Türkçe'nin kendine özgü morfolojik yapısının daha doęru analiz edilmesini saęlar. Bu araç, Türkçe'nin eklemeli yapısından doęan zorlukları ařmada başarılı bir örnek teşkil etmektedir. Ayrıca, Türkçe'nin kaynaęı az bir dil olması nedeniyle geliřtirilen bu tür araçlar, arařtırmacılara kolaylık saęlamakta ve dilin daha geniř bir analiz kapasitesine ulařmasını saęlamaktadır [70].



Şekil 4.4 Ortak Öğrenme Çerçevesinin Katmanları - Cümlelerin Morfolojik Segmentasyon, Morfolojik Etiketleme, İsimlendirilmiş Varlık Tanıma ve Bağımlılık Çözümlemesi

Türkçe gibi sondan eklemeli dillerde metin basitleştirme, özellikle Türkçe'nin yapısal özellikleri göz önüne alındığında zor bir görevdir. Uluslu'nun (2023) çalışmasında, BERT tabanlı bir yaklaşım kullanılarak kelime düzeyinde basitleştirme yapılmış ve BERTurk gibi Türkçe'ye özel modellerin metinlerdeki karmaşık kelimeleri basitleştirmede etkili olduğu gösterilmiştir. Metin basitleştirme, yalnızca kelime düzeyinde değil, aynı zamanda dilin morfolojik yapısına uygun bir segmentasyon gerektirir. Bu çalışmada kullanılan LS-BERT modeli, cümledeki bağlama göre uygun basitleştirmeleri yaparak dilin anlam bütünlüğünü koruma açısından başarılı bir performans sergilemiştir [71].

Türkçe’de bilgi tabanlı soru-cevaplama sistemleri, dilin karmaşık yapısından kaynaklanan doğruluk sorunlarını azaltmada bilgi grafikleri kullanarak başarılı sonuçlar elde edilmiştir. Çiftçi ve arkadaşları (2024), bilgi grafikleri kullanarak bir Türkçe soru-cevaplama sistemi geliştirmiştir. Bu çalışmada, bilgi grafikleri üzerinden çoklu atlama (multihop) yaparak karmaşık sorulara yanıt verilmesi sağlanmıştır. Bilgi grafikleri, gerçek dünya bilgilerini tripletler halinde sunarak, bağlamsal anlamı daha tutarlı hale getirebilmekte ve dilin morfolojik karmaşıklığından kaynaklanan hataları azaltmaktadır [72].



Şekil 4.5 Bilgi Grafiklerini Kullanarak Çoklu Atlama (Multihop) Soru Cevaplama Mimarisi

BERT ve GPT gibi dönüştürücü tabanlı modeller, Türkçe’nin eklemeli yapısı göz önünde bulundurularak adapte edildiğinde başarılı sonuçlar sunar. Salıcı ve Ölçer (2024) çalışmasında, Türkçe gibi kaynağı az dillerde BERTurk gibi özel modellerin ve veri artırma tekniklerinin kullanılmasının bu dildeki NLP uygulamalarının doğruluğunu arttırdığını belirtilmiştir. Bu tür modeller BERT ile, Türkçe’nin bağlama duyarlı anlamını her iki yönden değerlendirme yeteneği sayesinde adlandırılmış varlık tanıma, duygu analizi ve metin sınıflandırma gibi görevlerde yüksek başarı oranları sergiler. Ayrıca, GPT’nin kendinden geri beslemeli yapısı, Türkçe gibi dillerde dil oluşturma görevlerinde başarılı bir performans sergilemektedir [73].

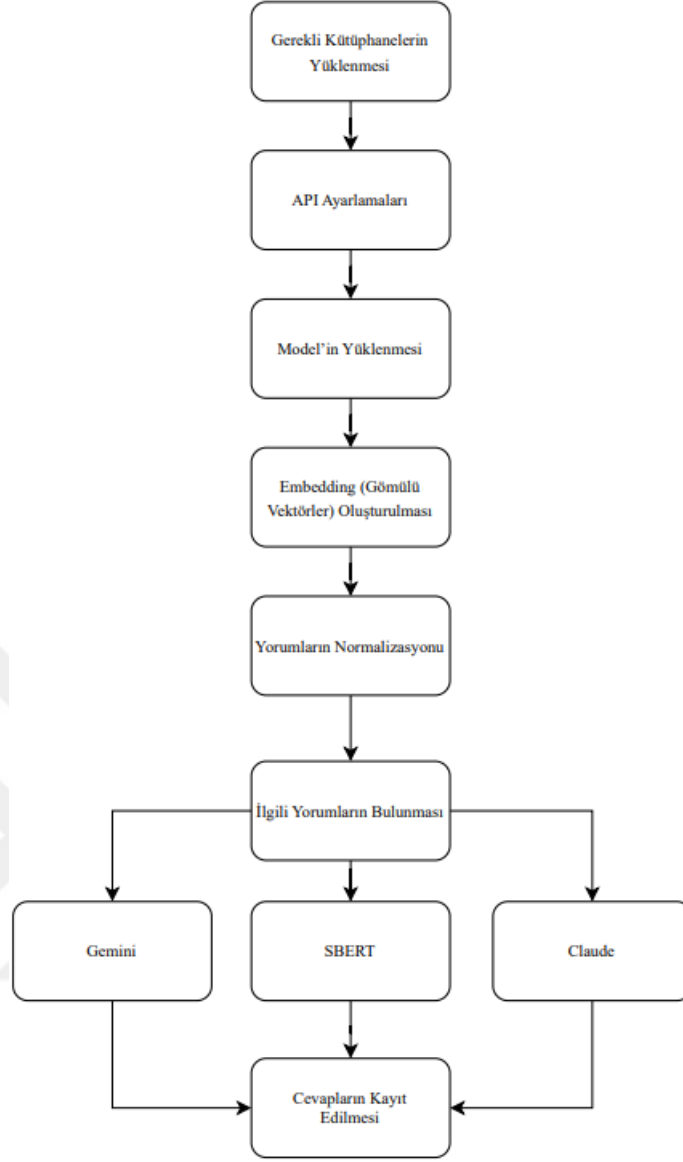
Türkçe’nin eklemeli yapısı, NLP görevlerinde karşılaşılan zorlukları artırmaktadır. Bu zorlukların üstesinden gelmek için geliştirilmiş çeşitli derin öğrenme tabanlı çözümler, dilin kendine özgü özelliklerine göre uyarlanmış BERT ve GPT gibi modelleri içermektedir. Çalışmalar, BERT tabanlı modellerin Türkçe’de çok sınıflı sınıflandırma, duygu analizi, adlandırılmış varlık tanıma ve soru-cevaplama gibi görevlerde başarılı olduğunu göstermektedir. Bunun yanında, bilgi grafikleri gibi ek yapılar ve özel Türkçe NLP araçları, bu görevlerin doğruluğunu artırmada ve dilin morfolojik yapısından kaynaklanan zorlukları aşmada önemli bir rol oynamaktadır.

4.5 NLP İLE ANLAMLANDIRILMIŞ VERİ ANALİZİ VE CHATBOT TASARIMI

Bu tez, kullanıcı yorumları gibi serbest metin verilerini analiz ederek ürün incelemelerine dayalı bir soru-cevap sistemi geliştirmeyi amaçlamaktadır. Günümüzde büyük ölçekli metin veri kümesinden anlamlı bilgiler çıkarmak, çeşitli dil modelleri ve NLP teknolojileri kullanılarak önemli ölçüde hızlanmıştır. Bu bağlamda, çalışmamız Claude, Gemini ve BERT gibi ileri NLP modellerini veri setimiz ile besleyerek çok yönlü bir analiz ve yanıt oluşturma süreci sunmaktadır.

Claude, açık uçlu ve bağlama dayalı soru-cevap performansı ile kullanıcı sorularına göre en uygun içerikleri belirleyerek üst düzey bir yanıt yeteneği sunmaktadır. BERT, özellikle cümle benzerlik ölçümleri ve metin gömme işlemleriyle, ürün ve yorum verilerinin semantik analizinde temel bir görev üstlenmiştir. Google Gemini ise gelişmiş bir dil modeli olarak, kullanıcıdan gelen sorulara dayalı olarak bağlama göre yanıt oluşturmada kullanılmaktadır. Bu üç teknolojinin entegrasyonu, metin verisini çok boyutlu bir uzayda anlamlandırmayı ve yorumlamayı mümkün kılmakta; böylece sorguya en uygun yanıtları yüksek doğrulukla sağlamaktadır.

Bu bağlamda tez, büyük miktarda serbest metin verisinin efektif bir şekilde işlenebilmesi ve yorumlanabilmesi için Claude, Gemini ve BERT modellerinin yeteneklerini ayrı ayrı incelemektedir. Bu yapı, yalnızca metin madenciliği değil, aynı zamanda büyük metin veri kümelerinde kullanıcı odaklı bilgiye erişim süreçlerini hızlandıran ve yanıt kalitesini arttıran bir NLP uygulaması olarak çalışır. Çalışma Google COLAB üzerinden gerçekleştirilmiştir. Veri seti olarak vitaminler.com'dan üretilen ürün yorumları veri seti kullanılmıştır [74]. Aşağıda teze dair yazılan kod şeması bulunmaktadır.



Şekil 4.6 Teze Dair Kod Şeması

Kodun işleyişi sekiz ana aşamada gerçekleşmektedir: gerekli kütüphanelerin yüklenmesi, API ayarlamaları, modelin yüklenmesi, embeddinglerin oluşturulması, yorumların normalizasyonu, ilgili yorumların bulunması, Gemini-Bert ya da Claude'a veri setimizin beslenmesi ve soru sorup cevabın alınması ve aldığımız cevapların kayıt edilmesi. Alınan cevaplar kayıt edildikten sonra da F1, recall, precision ve accuracy değerleri hesaplanmıştır.

4.6 KÜTÜPHANELER, VERİ İŞLEME VE HAZIRLIK

Kodun ilk aşaması, gerekli kütüphanelerin yüklenmesi, veri setinin işlenmesi ve hazır hale getirilmesidir. İlgili kütüphaneler kısaca spacy, spacy-transformers, google-generativeai, anthropic ve json şeklindedir, aşağıdaki şekilde kullanılan tüm

kütüphaneler görüntülenmektedir. Tüm işlemler Google COLAB ile gerçekleştirilmiştir.

```
1 !pip uninstall -y spacy
2 !pip install spacy==3.4.2 spacy-transformers==1.1.5
3 !pip install https://huggingface.co/turkish-nlp-suite/tr_core_news_md/resolve/main/tr_core_news_md-1.0-py3-none-any.whl
4 !python -m spacy validate
5 !pip install -q sentence_transformers
6 !pip install openai==0.27.0
7 !pip install -q -U google-generativeai
8 !pip install matplotlib
9 !pip install anthropic
10 !pip install nltk
```

Şekil 4.7 Koda dair kütüphaneler

Daha sonra veri setimizin işlenmesi adımına geçiyoruz. Bu işlem, ürün incelemeleri gibi büyük metin verisini analiz edilebilir bir formata dönüştürmek için gerçekleştirilir. Metin verimiz 1215882 satır, 1052 ürün ve 20000 den fazla yorumdan oluşmaktadır.

Aşağıdaki şekilde veri setimize dair örnek bir kesit gösterilmektedir.

```
1 [
2   {
3     "name": "Microfer Şurup 250 ml",
4     "brand": "Ocean",
5     "rating": {
6       "averageRating": 4.521739130434782,
7       "totalCount": 69
8     },
9     "id": 1,
10    "reviews": [
11      {
12        "review_id": 0,
13        "star": 5,
14        "review": "Bittikçe alıyorum harika bişey kızım tadını da seviyor"
15      },
16      {
17        "review_id": 1,
18        "star": 5,
19        "review": "minik hediyeleriniz için teşekkürler... ürün güzel paketlenmiş hızlı teslimat 🍷"
20      },
21      {
22        "review_id": 2,
23        "star": 5,
24        "review": "Ben kendim için aldım ama çocuklara içirmek zor olur gibi geldi, demir tadı ağza yayılıyor kötü hissettiriyor.
25      },
26      {
27        "review_id": 3,
28        "star": 5,
29        "review": "boyu baya büyük tadıda güzel"
30      },
31      {
32        "review_id": 5,
33        "star": 5,
34        "review": "doktorumuz tavsiye etti 3 uncu şişemiz oğlum severek içiyö faydasını gördük"
35      },
36    ]
37   }
38 ]
```

Şekil 4.8 Veri setine dair bir kesit

Aşağıdaki şekilde de gözüken ilgili fonksiyon, JSON formatındaki veri setimizden ürün adı ve yorum bilgilerini çıkarır. Ürün adı, marka ve kullanıcı incelemelerinden oluşan bu veriler, öncelikle bir Python sözlüğüne dönüştürülerek uygun bir veri yapısında saklanır. Bu sayede, her ürün adı altında o ürüne ait yorumlar düzenli bir yapı ile tutulur ve sorgulama işlemleri için erişilebilir hale getirilir.

```

9 # 1. Verilen JSON dosyasından yorumları ve ürün bilgilerini çıkartır ve bu bilgileri döndürür
10 def extract_reviews(json_file):
11     with open(json_file, 'r', encoding='utf-8', errors='ignore') as f:
12         data = json.load(f)
13
14     reviews = []
15     products = set()
16     for product in data:
17         products.add(product['name'].lower())
18         products.add(product['brand'].lower())
19         for review in product['reviews']:
20             reviews.append({
21                 "review": review['review'],
22                 "product_name": product['name'],
23                 "brand": product['brand']
24             })
25
26     return reviews, list(products)

```

Şekil 4.9 Yorum ve ürün bilgilerini çıkartan fonksiyon

4.7 GÖMÜLÜ VEKTÖRLERİN OLUŞTURULMASI VE YORUMLARIN ANALİZİ

Veri işleme aşamasından sonra kod, yorumları ve sorgu cümlesini çok boyutlu uzayda temsil eden gömülü vektörleri yani embedding'leri oluşturur. Burada SBERT tabanlı SentenceTransformer modeli, her yorum cümlesini ve ürün ismini metin gömme işlemine tabi tutar. Alakalı fonksiyon aracılığıyla gerçekleştirilen bu işlem, inceleme metinlerini ve ürün isimlerini sayı dizisi yani vektör olarak ifade ederek bu verilerin karşılaştırılabilir hale gelmesini sağlar. Metin gömme işleminde çok boyutlu uzayda temsil edilen her vektör, ilgili cümlenin veya kelimenin semantik anlamını içermektedir. Aşağıdaki şekilde ilgili kod parçasığı bulunmaktadır.

```

28 # 2. Yorumların embedding'lerinin oluşturulması.
29 def create_embeddings(reviews, model_name='sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2'):
30     embedder = SentenceTransformer(model_name)
31     texts = [review['review'] for review in reviews]
32     embeddings = embedder.encode(texts, convert_to_tensor=True)
33     return reviews, embeddings

```

Şekil 4.10 Gömülü vektörleri oluşturan fonksiyon

Kodun diğer bir bileşeni olan alakalı yorumları bulma fonksiyonu, gelen sorgu ifadesi için de bir gömülü vektör oluşturarak veri kümesindeki diğer yorum vektörleri ile karşılaştırır. Karşılaştırma işlemi, cosine similarity(Kosinüs benzerliği) metriği ile yapılmaktadır. Kosinüs benzerliği, iki vektör arasındaki açıyı hesaplayarak bunların ne kadar benzer olduğunu sayısal olarak ifade eder. Bu süreçte, benzerlik skoru 0,7 değerini aşan yorumlar, sorgu ile ilgili kabul edilerek daha sonraki analiz aşamasına alınır. Bu eşik değeri, yorumların sorguya olan ilgisini belirlemede kritik bir rol

oynamakta ve doğru sonuçlar elde edilmesini sağlamaktadır. Aşağıdaki şekilde ilgili fonksiyon bulunmaktadır.

```
35 # 3. Sorulara göre en uygun yorumların bulunması. Semantik arama yapar.
36 # Bu, sorgu embedding'ini yorum embedding'leri ile karşılaştırarak yapılır.
37 def find_best_answers(query, reviews, embeddings, model, top_k=3, threshold=0.7):
38     query_embedding = model.encode(query, convert_to_tensor=True)
39     hits = util.semantic_search(query_embedding, embeddings, top_k=top_k)[0]
40
41     best_answers = []
42     for hit in hits:
43         index = hit['corpus_id']
44         score = hit['score']
45         if score >= threshold:
46             best_answers.append({
47                 "review": reviews[index]['review'],
48                 "product_name": reviews[index]['product_name'],
49                 "brand": reviews[index]['brand'],
50                 "score": score
51             })
52
53     return best_answers
```

Şekil 4.11 En uygun yorumları bulan fonksiyon

Daha sonrasında false positive durumlara istinaden soru içeriğindeki ilaç ismi veri setimizde var mı diye kontrol ediyoruz. Örnek fonksiyon içeriği aşağıdaki gibidir.

```
55 # 4. Ürün veya marka adı içerip içermediğini kontrol eder
56 def contains_product(query, products):
57     query_lower = query.lower()
58     for product in products:
59         if product in query_lower:
60             return True
61     return False
```

Şekil 4.12 Ürün veya marka içeriği var mı kontrolü yapan fonksiyon

Ardından Spacy NER modeli kullanılarak sorgu ile ürün embedding'leri arasındaki benzerlik hesaplanır. Sorgunun ürün veya marka adı içerip içermediğini ve bu sorgunun ürünlerle ne kadar alakalı olduğunu analiz eder. Bu aşağıdaki şekilde de bir kısmı gözükten fonksiyon ile yapılır.

```

63 # 5. Sorunun anlamını analiz eder. Sorunun ürün veya marka adı içerip içermediğini ve bu sorunun ürünlerle ne kadar alakalı olduğunu analiz eder.
64 # Bu, Spacy'nin NER modelini kullanarak yapılır ve ardından sorunun embedding'leri ile ürün embedding'leri arasındaki benzerlik hesaplanır.
65 def analyze_query(query, products):
66     if not contains_product(query, products):
67         return False
68
69     # Spacy NER kullanarak ilaç veya vitamin isimlerini ve markalarını çıkarır
70     doc = nlp(query)
71     entities = [ent.text.lower() for ent in doc.ents if ent.label_ in ["PRODUCT", "BRAND"]]
72
73     # Semantic Similarity kullanarak sorunun ilaç veya vitaminlerle ne kadar alakalı olduğunu hesaplar
74     query_embedding = SentenceTransformer('sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2').encode(query)
75     product_embeddings = SentenceTransformer('sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2').encode(products)
76     scores = cosine_similarity(query_embedding, product_embeddings)[0]
77     average_score = scores.mean()
78
79     # Esik değerini dinamik olarak ayarlar
80     threshold = 0.5 + 0.5 * average_score
81
82     # Soru ilaç veya vitaminlerle ilgiliyse ve anlamsal olarak ne kadar alakalı olduğunu kontrol eder
83     return average_score >= threshold

```

Şekil 4.13 Sorunun anlamını analiz eden fonksiyon

4.8 YANIT SİSTEMİ

Kodun en son aşamasında, ilgili yorumlar kullanılarak statik olarak oluşturulan 150 soruya yanıt oluşturma işlemi gerçekleştirilir. İlgili statik soru listemiz aşağıdaki gibidir.

- Microfer şurup 250 ml'in tadı nasıl?
- Valorvita D3k2, C. Vit. Çinko, Bakır, Selenyum İçeren Vitamin saç dökülmesinde etkili mi?
- Biotin 2000 Mcg 100 Tablet'i çocuklar kullanabilir mi?
- V-effer C 1000mg 20 Tablet'in yan etkileri var mı?
- Phytorelief Plus 30 Adet'i ne kadar süre kullanmalıyım?
- Demir Takviye Edici Gıda 90 Kapsül ürünü nasıl?
- 2'li Paket Vitamin D3 1000 Iu 20 Ml Bitkisel Kaynaklı 500 Damla'nın içeriği nedir?
- Sambucus Nigra Vitamin C & Zinc 1000 Mg 3*20 Tablet'i kullanmaya ne zaman başlamalıyım?
- Full Mix Multi Vm 150 Ml portakal suyuyla karıştırabilir miyim?
- Cold (Ballı /zencefil) Lolipop 12 Adet markasının ürünleri güvenilir mi?
- Shiffa Home Shiffahome Sarı Kantaron 560mg 60 Kapsül'ün fiyatı uygun mu?
- Vitamin B1 Thiamin 100 Mg 100 Kapsül ne kadar sürede etki eder?
- Shiffa Home Bitkisel Vitamin B12-ginkgo Biloba Tablet'i yetişkinler kullanabilir mi?
- Microfer Şurup'un çocuklar için dozajı nedir?
- Lipozomal Demir ve Vitamin C Takviye Edici Gıda ile ilgili en sık karşılaşılan şikayetler nelerdir?

- Nutrinew Saccharomyces Cerevisiae B12 120 Tablet'in ambalajı nasıl?
- Ocean Mummy 30 Kapsül Multivitamin Multimineral 2 li'yi bittikçe alırmısınız?
- Qlife Tripple Effect D Vitamini + C Vitamini + Çinko 20 Efervesan Tablet'in tadı çocuklar tarafından seviliyor mu?
- Imumax Boğaz Spreyi+16 30 Ml*3 Adet hakkında genel görüşler nelerdir?
- Mom'un tadı belirgin mi?
- Vitality Ginseng G115 30 Kapsül 3 Adet'in etkisi ne kadar sürer?
- Quercetin 100 Mg 60 Kapsül Takviye Edici Gıda kullanırken nelere dikkat etmeliyim?
- Ocean Vitamin D3 600 Iu 20 ml'in demir eksikliğine etkisi nedir?
- Tip 1-2-3 Kollajen + Hiyalüronik Asit 60 Kapsül'ü kullananların memnuniyet oranı nedir?
- Fitospan Bitkisel Ekstreler İçeren Takviye Edici Gıda 100 Ml'in farklı tat seçenekleri var mı?
- Plus 30 Kapsül 3 Adet(bağışıklık Güçlendirici) ne zaman kullanılmalı?
- Multi Ener-g Multivitamin 2 X 30 Tablet'in saklama koşulları nedir?
- Nbt Life Folidays 30 Kapsül'ü başka bir ürünle birlikte kullanabilir miyim?
- Vitamin C Plus Nutriway™ (60 Tablet)'in alerji yapma riski var mı?
- D3k2 Vitamin Mixup 20 Ml'i kimler kullanmalı?
- Redoxon c vitamini d vitamini çinko üçlü etki 2x15 efervesan bağışıklık sistemini güçlendirmek için nasıl birlikte çalışır?
- ZMA 60 tablet çinko folic acid vitamin b 6 magnezyum bisglisinat spor performansını nasıl etkiler?
- Çinko bakır ve d3 k2 20 ml damla'nın kemik sağlığı üzerindeki sinerjik etkileri nelerdir?
- Iron bisglycinate 17 mg 92 tablet formundaki demir diğer demir formlarına göre emilim açısından ne gibi avantajlar sağlar?
- Imumax 16 boğaz spreyi e-vital enfeksiyonlara karşı koruyucu etkisi nasıldır?
- Astaksantin 30 soft kapsül, antioksidan özellikleri sayesinde cilt sağlığına nasıl katkı sağlar?
- Çörekotu yağı 80 kapsül 1380 mg. çörek otu soğuk sıkım, bağışıklık sistemi ve sindirim sağlığına nasıl etki eder?

- Picozinc çinko pikolinat 15 mg 30 tablet x2 adet formunun emilim oranı diğer çinko takviyelerine göre nasıl farklılık gösterir?
- Multivitamin & mineral complex for men 60, genel sağlık ve enerji seviyeleri üzerinde nasıl bir etkiye sahiptir?
- Günlük enerji seviyelerini desteklemek için orzax orzax ocean daily one energy 30 tablet kofre paket nasıl bir ilaçtır?
- Reduced l-glutathione 250 mg 30 kapsül, vücutta antioksidan kapasitesini artırarak hangi sağlık faydalarını sağlar?
- Yeni ambalaj 30 tablet muti ener-g takviyesi, enerji ve zindelik seviyelerini artırmada ne kadar etkilidir?
- Folik asit 400 mcg 120 tablet biosal folikosal alımının hamilelik öncesi ve sırasındaki önemi nedir?
- Vitocco vitamin ve mineral 15 efervesan tablet tadı nasıl?
- NBT life duosvit dha omega-3 vitamin mineral 30 kapsül beyin gelişimini ve kognitif fonksiyonları nasıl destekler?
- Cranberry 30 kapsül, idrar yolu enfeksiyonlarının önlenmesinde nasıl etkilidir?
- Pregnamax multivitamin multimineral ve folik asit 30 kapsül demir hamilelik süresince annenin ve bebeğin sağlığına katkıları nelerdir?
- Magnezyum çinko b12 ve d vitamini düzenli tüketimi kalp sağlığını nasıl iyileştirir?
- Shiffa home omega3 yumuşak 1000 mg x 200 kapsül kötü yanları nelerdir?
- İnülin prebiyotik içecek tozu 10 şaşe, sindirim sistemi sağlığını nasıl iyileştirir ve bağırsak florasını nasıl dengeler?
- Biotin 5000 50 tablet(bigjoy) saç ve tırnak sağlığı üzerinde ne kadar etkilidir?
- Omega kapsül 30 kapsül düzenli kullanımı nasıl bir etkiye sahiptir?"
- Vitamin c + zinc 20 efervesan tablet soğuk algınlığı semptomlarını hafifletmede ne kadar etkilidir?"
- Chromium picolinate 90 kapsül, kan şekeri seviyelerinin düzenlenmesinde nasıl bir rol oynar?
- Plus 14 şaşe formundaki takviyeler enerji seviyelerini artırmada nasıl etki eder?
- Askorbik asit C vitamini - e300 gıda tip 500 gr, antioksidan kapasitesi ile vücudu nasıl korur?

- Argifertil M, erkeklerde üreme sağlığını desteklemek için nasıldır?
- Argifertil F, kadınlarda üreme sağlığını desteklemek için nasıldır?
- Sambucus nigra efervesan 20 tablet, bağışıklık sistemini nasıl güçlendirir?
- System vitamin c 750 mg depot direct 20 saşe portakal aromalı, hızlı emilim sağlayarak bağışıklığı nasıl destekler?
- Ginseng & propolis & co-q10 & 13 vitamin & 16 mineral & betaglukan 30 kapsül bağışıklık ve enerji seviyelerine katkıları nelerdir?
- Medohbiotin 1 mg 60 tablet (saç, cilt ve tırnak güçlendirici vitamin) biotin gıda takviyesi, saç, cilt ve tırnak sağlığını desteklemek için ne kadar etkilidir?
- Telovium biotin 30 tablet , saç dökülmesini azaltmada ve saç sağlığını iyileştirmede nasıl etki eder?
- Dekinon d3 + k2 vitamini 400 damla 20 ml kullanımı, vücuda etkisi nedir?
- Ester-c plus 1000 mg 30 tablet'in pozitif etkileri nelerdir?
- Omega 3 700 mg 30 kapsül balık yağı takviyesi, kalp-damar sağlığı üzerindeki etkileri ile ne kadar önemlidir?"
- eurho® vital calcium 600 tableten 60 tablet kalsiyum eksikliğini önlemede nasıl etkilidir?
- Kids vitamin d lollipops, çocukların kemik gelişimini nasıl destekler?
- Calcium magnesium vitamin d3 150 tablet, kemik sağlığını desteklemek için nasıl çalışır?
- Immun 44 şurup 250 ml 2 adet, bağışıklık sistemini güçlendirmede nasıl bir rol oynar?
- Omega 3-6-9 soft jel 100 kapsül, vücudun yağ metabolizması üzerinde nasıl etkilidir?
- Retendo kapsül, hangi sağlık sorunlarına karşı kullanılır?
- Recugel 10 gr göz jeli, göz sağlığını korumak ve rahatlatmak için nasıl kullanılır?
- Tab ilaç q10 omega3 ubiquinol 90 kapsül, kalp sağlığını nasıl destekler?
- Omega 7 500 mg 32 kapsül balık yağı 60 kapsül cilt ve mukozal sağlığı nasıl destekler?
- Sambucus nigra kids karamürver ekstresi içeren şurup 150 ml, soğuk algınlığı semptomlarını nasıl hafifletir?
- Patisin zencefil-portakal 24 adet pastil boğaz ağrısına nasıl iyi gelir?

- Magnezyum sitrat efervesan 20 tablet m03045, kas kramplarını hafifletmede ne kadar etkilidir?
- Okula dönüş seti propolis + balık + supra, çocukların bağışıklık sistemini nasıl güçlendirir?
- Çörek otu yağı 60 yumuşak kapsül - blister x2 (2'li avantaj paketi) sindirim sağlığı üzerinde nasıl etkilidir?
- Ferromixin mini saşe form 30 saşe, demir eksikliği tedavisinde ne kadar etkilidir?
- Focus formula 60 tablet beyin fonksiyonlarını ve konsantrasyonu nasıl iyileştirir?
- Kuersetin complex 60 kapsül skt,03,2024 orjinal ürün, vücuttaki inflamasyonu azaltmada nasıl etkilidir?
- Folattro folik asit takviye edici gıda 30 tablet, hamilelik öncesi ve sırasındaki kullanımını ile nasıl fayda sağlar?
- Omega 3 50 yumuşak kapsül göz sağlığı üzerindeki etkileri nelerdir?
- No.7 vegetable 30 kapsül, genel sağlık üzerinde nasıl bir etkiye sahiptir?
- Psyllium husk fiber 4 g x 30 saşe, sindirim sağlığı ve bağırsak hareketlerini düzenlemede ne kadar etkilidir?
- Live-r6 30kapsül karaciğer desteği deve diken, karahindiba, enginar, ala, zerdeçal, glutatyon nasıl bir etkiye sahiptir?
- Efervit vitamin c 1000mg 20 tablet x 3, bağışıklık sistemi üzerindeki hızlı etkisi ile nasıl fayda sağlar?
- Bigjoy special formula harecare 60 tablet formülü saç dökülmesini önlemekte ve saç sağlığını korumakta ne kadar etkilidir?
- B12 plus dilaltı 60 tablet 2'li paket hakkında pozitif yorumlar nelerdir?
- Koenzim q10 100 mg ubikinon 30 kapsül, hücresel enerji üretimini artırmada nasıl bir rol oynar?
- Vitamin d3 400 iu sprej 30 ml, vücutta D vitamini seviyelerini düzenlemek için nasıl kullanılır?
- Lectus ps 60 kapsül takviyesinin sağlığa olan etkileri nelerdir?
- Biotin 5000 mg 50 kapsül solgar takviyesinin saç ve tırnak sağlığı üzerindeki uzun vadeli etkileri nelerdir?

- Expera bitkisel şurup 150 ml bağışıklık sistemini güçlendirmedeki etkinliği nedir?
- MSM 60 tablet, eklem sağlığını desteklemek ve iltihabı azaltmak için nasıl kullanılır?
- Ocean selenyum 200 mcg 60 tablet takviyesi, tiroid sağlığı üzerinde nasıl bir etkiye sahiptir?
- Vitamin c 1000 mg efervesan 15 tablet 3 adet, beğenilen yanları neler?
- Kontrol - glukozamin kondroitin msm 60 tablet, eklem sağlığını korumada nasıl etki eder?
- Milk thistle complex 60 kapsül skt:03/22, karaciğer sağlığını nasıl etkiler?
- vitamin c + sambucus nigra 20 efervesan tablet 3 adet, bağışıklık sistemini desteklemek için nasıldır?
- Imuno 100 ml, çocukların hastalıklara karşı dirençlerini nasıl artırır?
- Nutriway vitamin b plus, enerji seviyelerini artırmada ve stresle başa çıkmada nasıl etkilidir?
- Unique multivitamin & multimineral ginseng q10-30 kapsül vücudun günlük vitamin ve mineral ihtiyacını karşılarken nasıl etki eder?
- Vitamin c 3 lü avantaj paketi, grip üzerinde nasıl faydalıdır?
- Multivitamin megaxday (2'li paket) takviyesi, günlük vitamin ve mineral ihtiyaçlarını karşılamak için nasıl formüle edilmiştir?
- Vellajen 30 tablet takviyesi, eklem ve cilt sağlığına nasıl katkı sağlar?
- Kids maşa ve koca ayı multi vitamin 62 kapsül, büyüme ve gelişme üzerinde nasıl bir etkiye sahiptir?
- Vitamin c extra 20 efervesan tablet - şeftali maracuja (2 adet) bağışıklık sistemi üzerindeki etkileri nelerdir?
- Suda collagen alphamen 90 kapsül, cilt elastikiyetini artırmak için nasıl kullanılır?"
- Biotin 5000mcg - 60 kapsül, saç sağlığını ne kadar destekler?
- Sambuglucan 150 ml, bağışıklık fonksiyonlarını nasıl iyileştirir?
- Çinko & bakır 120 tablet selenyum, bağışıklık sistemini güçlendirmede nasıl etkilidir?
- Inofolic 2 gr 20 poşet, üreme sağlığı üzerinde nasıl bir etkiye sahiptir?

- Delta p-5-p , pridoksal 5-fosfat 100 ml av104, vücut tarafından diğer formlardan daha mı iyi emilir?
- Ester-c plus 1000 mg 30 tablet, bağışıklık sistemi desteği açısından nasıl avantaj sağlar?
- Koenzim q10 efervesan 30 tablet, enerji seviyelerini artırmak için nasıl bir etki gösterir?
- Vitamin c 1000 mg 30 tablet 4 kutu takviyelerinin uzun süreli kullanımında bağışıklık üzerindeki etkileri nelerdir?
- Biotin 30 yumuşak kapsül - blister, faydaları neler?
- Plus kids yummys 60 çiğneme tableti, çocukların vitamin alımını kolaylaştırmada ne kadar etkilidir?
- Max omega vita mineral 30 kapsül 2 adet kalp sağlığı üzerindeki etkileri nelerdir?
- Vitagil 30 tablet enerji seviyelerini artırmak ve zindelik sağlamak için nasıl kullanılır?
- Bisolnatur doğal takviyeler, bağışıklık sistemini nasıl destekler?
- Vitamin d3 60 softjel 650 mg, kemik sağlığı ve bağışıklık için nasıl etkilidir?
- Naturel sleep 60 kapsül, uyku düzenini iyileştirmede nasıl kullanılır?
- Vitamama immunotops sirup / bitkiler ve c vitamini içeren şurup, bağışıklığı nasıl güçlendirir?
- Sambucus nigra kids şurup 150 ml, çocuklarda bağışıklık sistemini nasıl destekler?
- Vitamin b12 1000 mcg metilkobalamin 60 dilaltı tablet hakkında pozitif görüşler nelerdir?
- İstanbul'a İzmit üzerinden nasıl gidebilirim?
- Vitasanol multivitamin multimineral şurup 250 ml, çocukların vitamin ihtiyaçlarını karşılamak için nasıl kullanılır?
- Aktif folicus plus takviye edici gıda 30 tablet hamilelik sırasında nasıl bir rol oynar?
- Sunlifea-z+ lutein 1 mg 60 tablet göz sağlığını nasıl destekler?
- Probiotic d3 drop vit 7,5 ml kemik sağlığı üzerindeki etkileri nelerdir?
- 500 detox 6 gr x 10 şase 4'lü takviyeler, vücudu toksinlerden arındırmada ne kadar etkilidir?

- Sambucus nigra, beta glukan, vitamin c & çinko şurup 150 ml bağışıklık sistemini nasıl destekler?
- Terapas karamürver ve izlanda yosunu içeren şurup 150ml, soğuk algınlığı semptomlarını nasıl hafifletir?
- Bugün nasılsın?
- K vitamini kalp sağlığına nasıl katkı sağlar?
- Selen 55+jod 60 tablet germany, tiroid sağlığını nasıl destekler?
- Multivitamin 30 tablet, genel sağlığı desteklemek için nasıl kullanılır?
- A-z multivitamin plus lutein & q10 30 tablet'in göz sağlığına katkıları nelerdir?
- Sambuglucan q10 kara mürver 20 kapsül, bağışıklık sistemi ve enerji seviyeleri üzerinde nasıl bir etkiye sahiptir?
- One & only daily mune 32 tablet vitamin takviyesi iyi yanları nelerdir?
- Magnimore magnesium 60 tablet, kas kramplarına iyi gelir mi?
- Arwel arwel 30 tablet stres yönetimi ve uyku düzeni üzerinde nasıl bir etkiye sahiptir?
- Methyl b12 1000 mcg methylcobalamin 5 ml, sinir sağlığı ve enerji üretimi için nasıl etkilidir?
- Tintus formula 60 kapsül, kulak çınlaması (tinnitus) tedavisinde nasıl bir rol oynar?
- Bugün hava kaç derece?
- Calcium magnesium d plus nutriway 180 tablet negatif yönleri nelerdir?

İlgili API'lara soru sorabildiğimiz fonksiyonlar, Gemini, Claude ve SBERT modellerinin sağladığı bağlam bilgisi ve ürün incelemeleri ile anlamlandırılan yorumlar kullanılarak bir yanıt üretir. Çalışmada, Gemini ve Claude için API'yi kullanarak dil modelini bir soru-cevap sistemi olarak çalıştırırken, SBERT modeli de kullanılarak doğrudan yerel bir embedding ve benzerlik analiz yöntemi uygulanmıştır. SBERT için sorgulama fonksiyonu aşağıdaki gibidir.

```

106 for query in queries:
107     print(f"Soru: {query}")
108
109     # İlk olarak, anahtar kelimelerin yorumlarda olup olmadığı kontrol edilir
110     if contains_product(query, products):
111         best_answers = find_best_answers(query, reviews, embeddings, model, top_k=3, threshold=0.7)
112         if best_answers:
113             for answer in best_answers:
114                 print(f"Cevap: {answer['review']} (Skor: {answer['score']:.4f}) - Ürün: {answer['product_name']} - Marka: {answer['brand']}")
115         else:
116             print("Bu soruya uygun yanıt bulunamadı.")
117     else:
118         # Eğer anahtar kelime içerip içermediği kontrol edildikten sonra ürün yoksa ilgili ürün bulunamadı mesajı verin
119         product_query = analyze_query(query, products)
120         if product_query:
121             best_answers = find_best_answers(query, reviews, embeddings, model, top_k=3, threshold=0.7)
122             if best_answers:
123                 for answer in best_answers:
124                     print(f"Cevap: {answer['review']} (Skor: {answer['score']:.4f}) - Ürün: {answer['product_name']} - Marka: {answer['brand']}")
125             else:
126                 print("Bu soruya uygun yanıt bulunamadı.")
127         else:
128             print("Bu soruya uygun ürün bulunamadı. Lütfen sorunuzda bir ürün veya marka belirtin.")
129     print("\n")

```

Şekil 4.14 SBERT sorgu fonksiyonu

Gemini ve Claude, API üzerinden yanıt alınırken ilgili yorumlar ve sorgu belirli bir bağlamda API'ye iletilir ve API'nin yanıt üretme sürecini desteklemek için context parametresi ile eklenir. Bu akış hem sorunun hem de yorumların semantik olarak değerlendirildiği bir ortam sağlar ve API'nin daha doğru yanıtlar vermesini sağlar. Bu süreç SBERT için, kullanıcı sorgusunun SBERT modeli tarafından embedding vektörüne dönüştürülmesi ve veri kümesindeki yorum vektörleri ile benzerliklerinin hesaplanması adımlarını içerir. Gemini için sorgulama fonksiyonu aşağıdaki gibidir.

```

62 # Dosyadan okunan sorulara yanıt al
63 for query in queries:
64     print(f"Soru: {query}")
65
66     # Gemini'den yanıt al
67     answer = ask_gemini(query, reviews)
68
69     if answer:
70         print(f"Cevap: {answer.candidates[0].content.parts[0].text}")
71     else:
72         print("Bu soruya uygun yanıt bulunamadı.")
73     print("\n")

```

Şekil 4.15 Gemini sorgu fonksiyonu

Yanıt üretme sürecinde kullanılan üretim yapılandırma (generation config) parametreleri, yanıt kalitesini optimize etmek amacıyla özelleştirilmiştir. Kodda kullanılan temperature, top_p, top_k ve max_output_tokens gibi parametreler, modelin üretkenliği, çeşitliliği ve yanıt uzunluğu gibi özelliklerini belirler. temperature parametresi, yanıtın rastgelelik seviyesini kontrol ederken; top_k ve top_p parametreleri, yanıtların içeriğini çeşitlendirmede önemli rol oynar. Bu parametre ayarları, API'nin daha anlamlı ve sorguya en uygun yanıtı üretmesi için optimize

edilmiştir. Alınan yanıt gerek kullanıcı arayüzüne gerekse bir çıktı dosyasına kaydedilerek sistemin yanıt süreci tamamlanır.



BÖLÜM 5 SONUÇ, TARTIŞMA VE ÖNERİLER

Bu çalışmada, Türkçe dilinde SBERT, Gemini ve Claude modellerinin chatbot performansları değerlendirilmiş ve sağlık sektöründe kullanılabilirlikleri analiz edilmiştir. Modellerin başarı oranları doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metriklerle detaylandırılmış ve her bir modelin güçlü ve zayıf yönleri ortaya konulmuştur. Doğruluk, kesinlik, duyarlılık ve F1 skoru gibi kriterler hesaplanırken, veri setimiz etiketli bir veri seti olmadığı için aldığımız yanıtların her biri doğru ise 1, yanlış ise 0 değerini aldı. SBERT için örnek yanıt aşağıdaki gibidir.

Soru: Microfer Şurup 250 ml'in tadı nasıl?
Eşleşen ürün: microfer şurup 250 ml
SBERT ile En Uygun Cevaplar:
Cevap 1: ürün hızlı geldi güzel paketlenmişti ama damlayı tercih ederim tadı çok kötü
Cevap 2: Güzel ürün, uygun fiyat, teşekkürler
Cevap 3: Ambalaj çok iyiydi şurubun tadı pekmeze benziyor kızım sevmedi bende portakal suyuna karıştırıp veriyorum o şekilde içiyor hem c vit. ile demir emilimi daha iyi oluyor yaklaşık 10 gündür içiyor istahı açıldı ve kilo almaya başladı

Şekil 5.1 SBERT için örnek yanıt

Gemini için örnek yanıt aşağıdaki gibidir.

Kullanıcı yorumlarına göre Microfer Şurup 250 ml'in tadı hakkında şunları söyleyebiliriz:

- * **Genel olarak iyi:** Birçok kullanıcı şurubun tadını beğendiğini ve çocuklarının da severek içtiğini belirtiyor. İlgili yorum "Bittikçe alıyorum harika bişey kızım tadını da seviyor" şeklindedir.
- * **Demir tadı:** Bir kullanıcı şurubun demir tadının ağza yayıldığını ve kötü hissettirdiğini, ancak portakal suyuna karıştırılarak bu sorunun çözülebileceğini söylüyor. İlgili yorum "Ben kendim için aldım ama çocuklara içirmek zor olur gibi geldi, demir tadı ağza yayılıyor kötü hissettiriyor. Belki portakal suyuna karıştırılarak kullanılabilir. Yetişkinlerde 2,5 ml günlük ihtiyacı tam karşılamıyor bu arada." şeklindedir.
- * **Çamur gibi:** Bir kullanıcı ürünü orijinal ürün olmadığını ve çamur gibi olduğunu iddia ediyor. Bu yorum, ürünün kalitesi hakkında şüphe uyandırıyor. İlgili yorum "Suan için kullanıyorum tadı çamur gibi ama faydasını daha görmedim" şeklindedir.

Şekil 5.2 Gemini için örnek yanıt

Claude için örnek yanıt aşağıdaki gibidir.

- Soru 1: Microfer şurup 250 ml'in tadı nasıl?
Claude'un yanıtı: Microfer şurup 250 ml'nin tadıyla ilgili yorumlara bakıldığında karışık görüşler var:
1. Bazı kullanıcılar ürünün tadını beğendiklerini, çocukların da tadını sevdiğini belirtmişler. Örneğin "kızım tadını da seviyor" ve "oğlum severek içiyor" yorumları bunu gösteriyor.
 2. Diğer yandan, bir kullanıcı "demir tadı ağza yayılıyor kötü hissettiriyor" diyerek tadından hoşnut olmadığını belirtmiş.
 3. Ayrıca bir başka yorum "boyu baya büyük tadı da güzel" diyerek tadına olumlu bir geri bildirim vermiş.
- Genel olarak değerlendirildiğinde, bazı kullanıcılar tadını beğenirken bazıları da demir tadından rahatsız olmuş görünüyor. Tadin kişisel tercihlere bağlı olarak değişebildiği sonucuna varılabilir. Bir öneri olarak portakal suyuna karıştırılarak içilmesi tadı hafifletebilir.

Şekil 5.3 Claude için örnek yanıt

Modeller tarafından 150 sorunun her birine verilen cevaplar toplandı ve her model kendi sabit katsayı değerini oluşturdu. İlgili 150 soru içerisinde ortalama soruları da bulunmaktadır. Bu sorular için de "vermiş olduğunuz veri setinde böyle bir bilgiye rastlanmamıştır" şeklinde aldığımız cevaplar için sorulara 1 puan verilmiştir. Bu katsayılarla elde edilen doğruluk, kesinlik, duyarlılık ve F1 skoru değerleri aşağıdaki formüllerle elde edilmiştir.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Doğru Pozitif} + \text{Doğru Negatif} + \text{Yanlış Pozitif} + \text{Yanlış Negatif}}$$

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}}$$

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}}$$


$$\text{F1 Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

Yukarıdaki başarımleri hesaplayabilmemiz için her modelden elde ettiğimiz Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerlerine ihtiyacımız vardı. Bu değerlere istinaden ilgili değerler aşağıdaki tabloda bulunduğu gibidir. Bu değerler elde edilirken, kodumuzda hangi yoruma istinaden bu dönüşü yaptığımıza dair cevap aldık. Aldığımız bu cevapları daha sonra gerçekten de ilgili ürüne yapılan yorumlar arasında var mı diye kontrol ettik.

Tablo 1 Model bazlı Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri

Model	DP	DN	YP	YN
SBERT	123	0	0	27
Gemini	128	12	1	9
Claude	134	16	1	5

Elde edilen sonuçlar, Claude'un bağlam uyumluluğundaki gücünü ve SBERT'in cümle benzerliği analizinde sağladığı avantajları gözler önüne sermiştir. Bu metriklerin karşılaştırılması, Claude'un geniş veri setleri ile sağlık sektörüne özgü bağlamsal sorulara yüksek doğrulukla yanıt verme kapasitesine sahip olduğunu göstermiştir.



Şekil 5.4 Model Bazlı Doğruluk, Kesinlik, Duyarlılık ve F1 Skoru Metrikleri

Sağlık sektörü gibi hassas alanlarda chatbot uygulamaları güvenilirlik, gizlilik ve doğruluk açısından özel önem arz etmektedir. Bu bağlamda, çalışmamız, özellikle sağlık sektöründe chatbot kullanımının potansiyel faydalarını ve bu teknolojilerin geliştirilmesinde dikkate alınması gereken temel noktaları vurgulamaktadır. Türkçe'nin eklemeli dil yapısı, bağlam uyumlu yanıt üretiminde bazı zorluklar yaratırken, Claude ve Gemini gibi modellerin bağlama dayalı yanıt kapasitesi bu zorlukları aşmada etkili bir araç olarak ortaya çıkmaktadır.

Tablo 2 Model bazlı doğruluk, kesinlik, duyarlılık ve F1 skoru metrikleri

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
SBERT	0,822	1	0,822	0,902
Gemini	0,84	0,99	0,85	0,915
Claude	0,88	0,99	0,89	0,937

Bu araştırma, Türkçe dilinin özelliklerini dikkate alarak büyük dil modellerinin sağlık sektörüne özgü bir chatbot geliştirme sürecinde nasıl optimize edilebileceğine dair kapsamlı bir rehber niteliğindedir. Özellikle SBERT'in Türkçe bağlamda etkin sonuçlar verdiği gözlemlenmiş ve anlam benzerliği hesaplamalarında başarılı olduğu

tespit edilmiştir. Ancak, SBERT'in bağlamsal doğruluk konusunda Claude ve Gemini gibi API tabanlı modellerle kıyaslandığında bazı sınırlılıklar taşıdığı da not edilmiştir.

Gelecekte, büyük dil modellerinin daha geniş veri setleri ile eğitilmesi ve sağlık sektöründe spesifik terminolojiyi içeren dil modellerinin oluşturulması chatbotların doğruluğunu artırabilir. Özellikle güvenlik ve gizlilik alanında kullanıcı verilerinin korunması amacıyla gelişmiş güvenlik protokolleri ile donatılmış chatbot sistemlerinin geliştirilmesi önerilmektedir. Bu çalışma, NLP tekniklerinin sağlık alanındaki uygulamalarını geliştirmek ve Türkçe gibi morfolojik açıdan zorlu bir dilde chatbot performansını artırmak için yol gösterici olabilir.



KAYNAKÇA

1. Saeidnia H., Welcome to the Gemini era: Google DeepMind and the Information Industry, Library Hi Tech News, <https://doi.org/10.1108/LHTN-12-2023-0214>, 2023.
2. Yu S., Chen Y., Zaidi H., AVA: A Financial Service Chatbot Based on Deep Bidirectional Transformers, *Frontiers in Applied Mathematics and Statistics*, Volume 7, doi: 10.3389/fams.2021.604842, 2021.
3. Lee C., Pan L., Hsieh S., Artificial intelligent chatbots as brand promoters: a two-stage structural equation modeling- artificial neural network approach, *Internet Research*, Vol. 32 No. 4, pp. 1329-1356, DOI:10.1108/INTR-01-2021-0030, 2022.
4. Wu S., Koo M., Blum L., Black A., Kao L., Scalzo F., Kurtz I., A Comparative Study of Open-Source Large Language Models, GPT-4 and Claude 2 Multiple-Choice Test Taking in Nephrology, doi.org/10.48550/arXiv.2308.04709 2023.
5. Agarwal M., Goswami A., Sharma P., Evaluating ChatGPT-3.5 and Claude-2 in Answering and Explaining Conceptual Medical Physiology Multiple-Choice Questions, *Cureus* 15(9): e46222, DOI: 10.7759/cureus.46222, 2023.
6. Zhang J., Oh Y., Lange P., Yu Z., Fukuoka Y., Artificial Intelligence Chatbot Behavior Change Model for Designing Artificial Intelligence Chatbots to Promote Physical Activity and a Healthy Diet: Viewpoint, *J Med Internet Res* 2020;22(9):e22845, doi: 10.2196/22845, 2020.
7. Xygi E., Andriopoulos A. D., Koutsomitropoulos D. A. , Question Answering Chatbots for Biomedical Research Using Transformers, 2023 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC), pp. 025-029, doi: 10.1109/ICAIIIC57133.2023.10066979, Bali, Indonesia, 2023.
8. Lo A., Singh M., From ELIZA to ChatGPT: The Evolution of NLP and Financial Applications, *The Journal of Portfolio Management* 49(7):jpm.2023.1.512, 2023.
9. Zhou M., Duan N., Liu S., Shum H., Progress in Neural NLP: Modeling, Learning, and Reasoning, Chinese Academy of Engineering and Higher Education Press Limited Company, doi.org/10.1016/j.eng.2019.12.014, *Engineering* 6 (2020) 275–290, 2019..
10. Young T., Hazarika D., Poria S., Cambria E., Recent Trends in Deep Learning Based Natural Language Processing, 2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS), [arXiv:1708.02709v8](https://arxiv.org/abs/1708.02709v8), 2018.
11. Boukabous M., Azizi M., A comparative study of deep learning based language representation learning models, *Indonesian J Elec Eng & Comp Sci*, Vol. 22, No. 2, May 2021 : 1032 – 1040, DOI: 10.11591/ijeecs.v22.i2.pp1032-1040, 2021.

12. Wang H., Raj B., On the Origin of Deep Learning, arXiv:1702.07800v4, 2017.
13. Dam H., Tran T., Pham T., A deep language model for software code, arXiv:1608.02715v1, 2016.
14. Pavlick E., Semantic Structure in Deep Learning, Annual Review of Linguistics, 2022.
15. Vo V., Jain S., Beckage N., Chien H., Obinwa C., Huth A., A unifying computational account of temporal context effects in language across the human cortex, Cold Spring Harbor Laboratory, doi: 10.1101/2023.08.03.551886, 2023.
16. Perconti P., Plebe A., Deep learning and cognitive science, Cognition, Volume 203, doi.org/10.1016/j.cognition.2020.104365, 2020.
17. Ghojogh B., Ghodsi A., Attention Mechanism, Transformers, BERT, and GPT: Tutorial and Survey, DOI:10.31219/osf.io/m6gcn, 2020.
18. Gillioz A., Casas J., Mugellini E., Khaled O., Overview of the Transformer-based Models for NLP Tasks, Proceedings of the Federated Conference on Computer Science and Information Systems, pp. 179–183, DOI: 10.15439/2020F20, 2020.
19. Topal M., Bas A., Heerden I., Exploring Transformers in Natural Language Generation: GPT, BERT, and XLNet, Interdisciplinary Applications of Artificial Intelligence, DOI:10.48550/arXiv.2102.08036, 2021.
20. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A., Kaiser L., Polosukhin I., Attention Is All You Need, doi.org/10.48550/arXiv.1706.03762, 2023.
21. Wang C., Li M., Smola A., Language Models with Transformers, 2019.
22. Vig J., A Multiscale Visualization of Attention in the Transformer Model, Annual Meeting of the Association for Computational Linguistics, arXiv:1906.05714v1, 2019.
23. Nishimoto H., Effective Deep Learning through Bidirectional Reading on Masked Language Model, Human Systems Engineering and Design, 2021.
24. Xu H., Durme B., Murray K., BERT, mBERT, or BiBERT? A Study on Contextualized Embeddings for Neural Machine Translation, Conference on Empirical Methods in Natural Language Processing, arXiv:2109.04588v1, 2021.
25. Wettig A., Gao T., Zhong Z., Chen D., Should You Mask 15% in Masked Language Modeling?, European Chapter of the Association for Computational Linguistics, arXiv:2202.08005v3, 2023.
26. Chen Q., Wang W., Zhang Q., Deng C., Yukun M., Zheng S., Improving BERT with Hybrid Pooling Network and Drop Mask, arXiv:2307.07258v1, 2023.
27. Lee M., Park J., Kim J., Kim K., Lee S., Efficient Pre-training of Masked Language Model via Concept-based Curriculum Masking, Association for Computational Linguistics, Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing, 2022.

28. Baktash J., Dawodi M., Gpt-4: A Review on Advancements and Opportunities in Natural Language Processing, *International Journal of Educational Technology in Higher Education*. 20. 10.1186/s41239-023-00425-2, 2023.
29. Meng Y., Huang J., Zhang Y., Han J., Generating Training Data with Language Models: Towards Zero-Shot Language Understanding, *36th Conference on Neural Information Processing Systems*, 2022.
30. Zheng X., Zhang C., Woodland P., Adapting GPT, GPT-2 and BERT Language Models for Speech Recognition, DOI: 10.1109/ASRU51503.2021.9688232, 2021.
31. Artetxe M., Du J., Goyal N., Zettlemoyer L., Stoyanov V., On the Role of Bidirectionality in Language Model Pre-Training, *Association for Computational Linguistics: EMNLP*, pages 3973–3985, 2022.
32. Zhou C., Li Q., Li C., Yu J., Liu Y., Wang G., Zhang K., Ji C., Yan Q., He L., Peng H., Li J., Wu J., Liu Z., Xie P., Xiong C., Pei J., Yu P., Sun L., A Comprehensive Survey on Pretrained Foundation Models: A History from BERT to ChatGPT, *International Journal of Machine Learning and Cybernetics*, 2024.
33. Wei A., Haghtalab N., Steinhardt J., Jailbroken: How Does LLM Safety Training Fail?, *Neural Information Processing Systems*, doi.org/10.48550/arXiv.2307.02483, 2023.
34. Gupta M, Akiri C., Aryal K., Parker E., Praharaj L., From ChatGPT to ThreatGPT: Impact of Generative AI in Cybersecurity and Privacy, DOI:10.1109/ACCESS.2023.3300381, 2023.
35. Singh S., Abri F., Namin A., Exploiting Large Language Models (LLMs) through Deception Techniques and Persuasion Principles, *2023 IEEE International Conference on Big Data*, 2023.
36. Wang R., Performance analysis and comparison of representative chatbots based on deep learning, *Applied and Computational Engineering* 6(1):860-866, 2023.
37. Angelis L., Baglivo F., Arzilli G., Privitera G., Ferragina P., Tozzi A., Rizzo C., ChatGPT and the rise of large language models the new AI-driven infodemic threat in public health, *Front. Public Health* 11:1166120, doi: 10.3389/fpubh.2023.116612, 2023.
38. Ballout M., Krumnack U., Heidemann G., Kuhnberger K., Investigating Pre-trained Language Models on Cross-Domain Datasets, a Step Closer to General AI, *International Neural Network Society Workshop on Deep Learning Innovations and Applications*, arXiv:2306.12205v1, 2023.
39. Vucetic D., Tayaranian M., Ziaeeafard M., Clark J., Meyer B., Gross W., Efficient Fine-Tuning of BERT Models on the Edge, *IEEE International Symposium on Circuits and Systems*, 2022.
40. Li T., Mesbahi Y., Kobzyev I., Rashid A., Mahmud A., Anchuri N., Hajimolahoseini H., Liu Y., Rezagholizadeh M., A Short Study on

Compressing Decoder-Based Language Models, 35th Conference on Neural Information Processing Systems, arXiv:2110.08460v1, 2021.

41. Zuo S., Liu X., Jiao J., Charles D., Manavoglu E., Zhao T., Gao J., Efficient Long Sequence Modeling via State Space Augmented, DOI:10.48550/arXiv.2212.08136, 2022.
42. Zhang J., Jiang S., Feng J., Zheng L., Kong L., CAB: Comprehensive Attention Benchmarking on Long Sequence Modeling, <https://doi.org/10.48550/arXiv.2210.07661>, 2023.
43. Masum A., Abujar S., Akter S., Ria N., Hossain S., Transformer Based Bengali Chatbot Using General Knowledge Dataset, International Conference on Machine Learning and Applications, 2021.
44. Peng H., Kasai J., Pappas N., Yogatama D., Wu Z., Kong L., Schwartz R., Smith N., ABC: Attention with Bounded-memory Control, Association for Computational Linguistics, P:7469–7483, 2022.
45. Narayanan D., Shoeybi M., Casper J., LeGresley P., Patwary M., Korthikanti V., Vainbrand D., Kashinkunti P., Bernauer J., Catanzaro B., Phanishayee A., Zaharia M., Efficient Large-Scale Language Model Training on GPU Clusters Using Megatron-LM, arXiv:2104.04473v5, 2021.
46. Momeni A., Rahmani B., Mallejac M., Hougne P., Fleury R., Backpropagation-free training of deep physical neural networks, Science, Vol 382, Issue 6676, pp. 1297-1303, arXiv:2304.11042v3, 2023.
47. Han W., Pang B., Wu Y., Robust Transfer Learning with Pretrained Language Models through Adapters, Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, Volume 2, 2021.
48. Li Z., Ding X., Liu T., Story Ending Prediction by Transferable BERT, Twenty-Eighth International Joint Conference on Artificial Intelligence, 2019.
49. Yeshpanov R., Varol H., Sentiment Analysis of Reviews in Kazakh With Transfer Learning Techniques, Smart Information Systems and Technologies, 2024.
50. Ajagbe M., Zhao L., Retraining a BERT Model for Transfer Learning in Requirements Engineering: A Preliminary Study, International Conference on Requirements Engineering, 2023.
51. Wang Z., A new computationally efficient method to tune BERT networks – transfer learning, Journal of Physics Conference Series 2580(1):012012, 2023.
52. Colon-Ruiz C., Segura-Bedmar I., Comparing Deep Learning architectures for Sentiment Analysis on Drug Reviews, Journal of Biomedical Informatics, Volume 110, 2020.
53. Devlin J., Chang M., Lee K., Toutanova K., BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, North American Chapter of the Association for Computational Linguistics, 2019.

54. Babu A., Boddu S., BERT-Based Medical Chatbot: Enhancing Healthcare Communication through Natural Language Understanding, *Exploratory Research in Clinical and Social Pharmacy*, Volume 13, DOI: 10.1016/j.rcsop.2024.100419, 2024.
55. John A., Abhigna G., Adithi K., Harusha R., Kavya A., HEALTH CARE CHATBOT, *International Research Journal of Computer Science*, 9(8):297-303, 2022.
56. Ezen-Can A., A Comparison of LSTM and BERT for Small Corpus, [abs/2009.05451](https://arxiv.org/abs/2009.05451), 10.48550/arXiv.2009.05451, 2020.
57. Schmidl B., Hütten T., Pigorsch S., Stögbauer F., Hoch C., Hussain T., Wollenberg B., Wirth M., Assessing the use of the novel tool Claude 3 in comparison to ChatGPT 4.0 as an artificial intelligence tool in the diagnosis and therapy of primary head and neck cancer cases, *European Archives of Oto-Rhino-Laryngology*, <https://doi.org/10.1007/s00405-024-08828-1>, 2024.
58. Wang Y, Liang L, Li R, Wang Y, Hao C. Comparison of the Performance of ChatGPT, Claude and Bard in Support of Myopia Prevention and Control. *J Multidiscip Healthc*. Aug 13;17:3917-3929. doi: 10.2147/JMDH.S473680. PMID: 39155977; PMCID: PMC11330241, 2024.
59. Santos R., Enhancing Chemistry Learning with ChatGPT, Bing Chat, Bard, and Claude as Agents-to Think-With: A Comparative Case Study, [dx.doi.org/10.2139/ssrn.4447416](https://doi.org/10.2139/ssrn.4447416), 2023.
60. Aydın Ö., Karaaslan E., Is ChatGPT Leading Generative AI? What is Beyond Expectations?, *APJESS*, vol. 11, no. 3, pp. 118–134, 2023, doi: 10.21541/apjess.1293702, 2023.
61. Deng L., Wang T., Yangzhang, Zhai Z., Tao W., Li J., Zhao Yi, Luo S., Xu J., Evaluation of large language models in breast cancer clinical scenarios a comparative analysis based on ChatGPT-3.5, ChatGPT-4.0, and Claude2, *International Journal of Surgery*, [dx.doi.org/10.1097/JS9.0000000000001066](https://doi.org/10.1097/JS9.0000000000001066), 2024.
62. Chiu E., Chung T., Protocol For Human Evaluation of Artificial Intelligence Chatbots in Clinical Consultations, DOI:10.1101/2024.03.01.24303593, 2024.
63. Mladan Jovanović, Marcos Baez, Fabio Casati, Chatbots as conversational healthcare services, *IEEE Internet Computing*, vol. 25, no. 3, pp. 44-51, 1 May-June 2021, doi: 10.1109/MIC.2020.3037151, 2020.
64. Koç A., Öztiryaki A., Comparison of the accuracy performances of the Gemini Advanced, the GPT-4, the Copilot, and the GPT-3.5 models in medical imaging systems: A Zero-shot prompting analysis, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(4), 1216-1223. <https://doi.org/10.28948/ngumuh.1492129>, 2024.
65. Şensoy E., Çitirik M., Impact of Language Variation English and Turkish on Artificial Intelligence Chatbot Performance in Oculofacial Plastic and Orbital Surgery: A Study of ChatGPT-3.5, Copilot, and Gemini, *Osmangazi Medical Journal*, 2024;46(5):781-6, 2024.

66. Safi Z., Abd-Alrazaq A., Khalifa M., Househ M., Technical Aspects of Developing Chatbots for Medical Applications: Scoping Review, *J Med Internet Res* 2020;22(12):e19127, Vol 22, No 12 December, 2020.
67. Gemirter C., Goularas D., A Turkish Question Answering System Based on Deep Learning Neural Networks, *Journal of Intelligent Systems: Theory and Applications* 4(2) (2021) 65-75, DOI: 10.38016/jista.815823, 2021.
68. Görmez Y., Arslan H., Atak B., Sentiment Analysis in Turkish Texts: The Effect of Deep Learning Approaches and Preprocessing Processes on Model Performance, *Fırat University Journal of Engineering Sciences*, 36(1), 509-520. <https://doi.org/10.35234/fumbd.1429040>, 2024.
69. Özkan M., Kar G., Türkçe Dilinde Yazılan Bilimsel Metinlerin Derin Öğrenme Tekniği Uygulanarak Çoklu Sınıflandırılması, *Mühendislik Bilimleri ve Tasarım Dergisi*, 2022.
70. Aleçakır H., Bölücü N., Can B., TurkishDelightNLP: A Neural Turkish NLP Toolkit, *Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies: System Demonstrations*, pages 17- 26 July 10-15, 2022.
71. Uluslu A., Automatic Lexical Text Simplification for Turkish, 10.48550/arXiv.2201.05878, 2023.
72. Çiftçi O., Soygazi F., Tekir S., Enrichment of Turkish question answering systems using knowledge graphs, *Izmir Institute of Technology*, 2023.
73. Salıcı M., Ölçer E., Transformer Tabanlı Modellerin NLP'deki Etkisi - BERT ve GPT Üzerine Derinlemesine İnceleme, 8th International Artificial Intelligence and Data Processing Symposium (IDAP), Malatya, Türkiye, pp. 1-6, doi: 10.1109/IDAP64064.2024.10710796, 2024.
74. Altınok D., Association for Computational Linguistics, <https://aclanthology.org/2023.acl-long.768>. Publication date July 2023. Access date July 2024.