T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DESTEK TALEP SİSTEMLERİNDE CHATGPT'NİN İNTERAKTİF ÇÖZÜM ÜRETİMİ İÇİN İNCELENMESİ VE HASSAS AYAR UYGULAMASI

BİLAL ÖRÜCÜ

YÜKSEK LİSANS TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Tez Danışmanı: Dr. Öğr. Üyesi Özlem UÇAR

EDİRNE-2025

Bilal Örücü'nün hazırladığı **"Destek Talep Sistemlerinde ChatGPT'nin İnteraktif Çözüm Üretimi İçin İncelenmesi ve Hassas Ayar Uygulaması"** başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından **Bilgisayar Mühendisliği** Anabilim Dalında bir **Yüksek lisans tezi** olarak kabul edilmiştir.

Jüri Üyeleri	İmza
Dr. Öğr. Üyesi Özlem UÇAR	……
Dr. Öğr. Üyesi Emir ÖZTÜRK	……
Dr. Öğr. Üyesi Edip Serdar GÜNER	……

Tez Savunma Tarihi: 10/01/2025

Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Dr. Öğr. Üyesi Özlem UÇAR

Tez Danışmanı ……

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

……

Doç. Dr. Filiz UMAROĞULLARI

Fen Bilimleri Enstitüsü Müdürü

T. Ü. FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI YÜKSEK LİSANS PROGRAMI

DOĞRULUK BEYANI

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

10 / 01 / 2025

Bilal ÖRÜCÜ

İmza

Yüksek Lisans Tezi

Destek Talep Sistemlerinde ChatGPT'nin İnteraktif Çözüm Üretimi İçin İncelenmesi ve Hassas Ayar Uygulaması

T.Ü. Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

ÖZET

Bu tez çalışması, IT birimleri tarafından sıklıkla kullanılan Destek Talep Sistemlerinin, ChatGPT gibi büyük dil modelleri ile nasıl daha interaktif ve etkili hale getirilebileceğini incelemektedir. Çalışma kapsamında, bir Destek Talep Sistemini simüle etmek amacıyla ChatGPT modeli hassas ayar uygulanarak test edilmiş ve modelin performansı analiz edilmiştir.

Hassas ayar uygulanmış modelin, destek taleplerini anlamada, sınıflandırmada ve doğru çözümler sunmada başarılı olduğu gözlemlenmiştir. Elde edilen bulgular, büyük dil modellerinin dil anlama ve kullanıcı taleplerine uygun yanıt üretme konularında yüksek bir potansiyele sahip olduğunu ortaya koymaktadır. Ayrıca, modelin doğal dil işleme yetenekleri sayesinde operasyonel süreçleri hızlandırabileceği ve kullanıcı deneyimini iyileştirebileceği görülmüştür.

Çalışma, ChatGPT'nin yalnızca IT birimlerinde değil, müşteri destek sistemleri ve diğer iş süreçlerinde de etkin bir şekilde kullanılabileceğini göstermektedir. Bu bağlamda, dil modellerinin esnekliği ve çeşitli alanlara uygulanabilirliği, gelecekteki uygulamalar için umut verici bir yaklaşım sunmaktadır.

Sonuç olarak, bu tez, büyük dil modellerinin destek sistemleri üzerindeki etkisini değerlendirerek, ChatGPT'nin interaktif çözüm üretme becerileri ile geleneksel yöntemlere kıyasla önemli avantajlar sağladığını kanıtlamaktadır.

Yıl : 2025

Sayfa Sayısı : 79

Anahtar Kelimeler : ChatGPT, Doğal Dil İşleme, Hassas Ayar, Önceden Eğitilmiş Üretken Dönüştürücüler, Büyük Dil Modelleri, Destek Talep Sistemleri

Master’s Thesis

An Examination and Fine-Tuning of ChatGPT for Interactive Problem Solving in Support Request Systems

Trakya University Institute of Natural and Applied Sciences

Department of Computer Engineering

ABSTRACT

This thesis examines how Support Request Systems, frequently used by IT departments, can be made more interactive and efficient through the use of large language models like ChatGPT. Within the scope of this study, the ChatGPT model was fine-tuned and tested to simulate a Support Request System, and its performance was analyzed.

The fine-tuned model demonstrated success in understanding support requests, classifying them, and providing accurate solutions. The findings reveal that large language models possess significant potential in understanding language and generating responses aligned with user requests. Moreover, it was observed that the model's natural language processing capabilities can accelerate operational processes and enhance user experience.

The study also shows that ChatGPT can be effectively utilized not only in IT departments but also in customer support systems and other business processes. In this context, the flexibility of language models and their applicability to various domains offer a promising approach for future implementations.

In conclusion, this thesis evaluates the impact of large language models on support systems, proving that ChatGPT's interactive problem-solving capabilities provide significant advantages compared to traditional methods.

Year : 2025

Number of Pages : 79

Keywords : ChatGPT, Natural Language Processing, Fine-Tuning, GPT, Large Language Models, Support Request Systems

TEŞEKKÜR

Bu tezin hazırlanmasında bana danışmanlık yapan ve değerli katkılar sunan Sayın Dr. Öğr. Üyesi Özlem UÇAR'a teşekkürü bir borç bilirim.

Tez süresince destekleri ile yolumu aydınlatan değerli hocam Sayın Dr. Öğr. Üyesi Edip Serdar GÜNER'e en içten teşekkürlerimi sunarım.

Tez çalışmasında kullanılan verilerle katkıda bulunan çalıştığım kurum Kırklareli Üniversitesi'ne ve onun özelinde Bilgi İşlem Daire Başkanlığı'na teşekkür ederim.

Tez çalışmasının bütün süreçlerinde yanımda olan ve her zaman destek veren kıymetli eşim Ayfer ÖRÜCÜ'ye ve abim Mustafa ÖRÜCÜ'ye çok teşekkür ederim.

Ayrıca hayatımın tüm evrelerinde bana destek olan annem Ayni Zeliha ÖRÜCÜ'ye, babam Mehmet Bahattin ÖRÜCÜ'ye ve kardeşlerime minnet ve şükranlarımı sunarım.

İÇİNDEKİLER

ÖZET iv
ABSTRACT vi
TEŞEKKÜR viii
İÇİNDEKİLER ix
SİMGELER VE KISALTMALAR DİZİNİ xi
ŞEKİLLER DİZİNİ xii
ÇİZELGELER DİZİNİ xiv
BÖLÜM 1 1
GİRİŞ 1
BÖLÜM 2 3
KURAMSAL BİLGİLER 3
2.1. Doğal Dil İşleme (DDİ) 3
2.2. Metin Ön İşleme 4
2.2.1. Metin Temsili 5
2.2.2. Modelleme 5
2.2.3. Doğal Dil İşleme Zorlukları 6
2.3. Dil Modelleri (DM) 6
2.3.1. İstatistiksel Dil Modelleri (İDM) 7
2.3.2. Sinir Ağı Tabanlı Dil Modelleri (SATDM) 8
2.3.3. Önceden Eğitilmiş Dil Modelleri (ÖEDM) 11
2.3.4. Büyük Dil Modelleri (BDM) 19

2.4. Hassas Ayar (Fine-Tuning) 21
2.4.1. Hassas Ayar Yöntemleri 22
BÖLÜM 3 24
LİTERATÜR TARAMASI 24
BÖLÜM 4 26
MATERYAL VE METODLAR 26
4.1. MySQL ve phpMyAdmin 26
4.2. Microsoft Excel 27
4.3. PyCharm IDE 28
4.4. Python Dili, Pandas ve JSON kütüphaneleri 29
4.5. OpenAI Test Ortamı 30
BÖLÜM 5 31
DENEYLER VE SONUÇLAR 31
5.1. Veri Seti 31
5.1.1. Veri Seti Önişlem 35
5.1.2. Taleplere Cevap Üretme 36
5.1.3. İstemleri Oluşturma 39
5.2. Modelin Yeniden Eğitilmesi 42
5.2.1. Hassas Ayar ve Parametreler 43
BÖLÜM 6 58
SONUÇLAR VE TARTIŞMA 58
KAYNAKLAR 60

SİMGELER VE KISALTMALAR DİZİNİ

BİDB:	Bilgi İşlem Daire Başkanlığı
BDM:	Büyük Dil Modelleri (Large Language Models)
BGO:	Bütünleşmiş Geliştirme Ortamı
ÇKA:	Çok katmanlı algılayıcı
DDA:	Doğal Dil Anlama
DDİ:	Doğal Dil İşleme(Natural Language Proccesing)
DTS:	Destek Talep Sistemleri
DDÜ:	Doğal Dil Üretimi
ESA:	Evrişimli Sinir Ağları
İDM:	İstatistiksel Dil Modelleri
KLU:	Kırklareli Üniversitesi
MÇ:	Makine Çevirisi
ÖEDM:	Önceden Eğitilmiş Dil Modelleri
ÖEÜD:	Önceden Eğitilmiş Üretken Dönüştürücüler (Generative Pre-trained Transformer)
PVHA:	Parametre Verimli Hassas Ayar
SC:	Soru-Cevap
SATDM:	Sinir Ağı Tabanlı Dil Modelleri
TSA:	Tekrarlayan Sinir Ağları
TL:	Training Loss
VL:	Validation Loss
YZ:	Yapay Zeka (Artificial Intelligence)

ŞEKİLLER DİZİNİ

Şekil 2.1. DDİ akış şeması 3

Şekil 2.2. Yıllara göre dil modelleri ve türleri 7

Şekil 2.3. Sinir ağlarının sınıflandırılması 8

Şekil 2.4. İki gizli katmanlı bir ÇKA örneği 9

Şekil 2.5. Basit bir TSA örneği 10

Şekil 2.6. Örnekleriyle ÖEDM sınıflandırması 12

Şekil 2.7. Dönüştürücü (Transformer) Mimarisi 14

Şekil 2.8. Dönüştürücü ve ÖEÜD mimarileri 16

Şekil 2.9. ÖEÜD çalışma yolu 17

Şekil 2.10. Görev bazlı hassas ayar için Dönüştürücü ve girdi dönüşümleri. 18

Şekil 2.11. ÖEÜD Modellerinin çeşitli uygulamalar üzerindeki etkisi 19

Şekil 2.12. BDM örnekleri 20

Şekil 2.13. Dönüştürücü tabanlı temel modelde parametre verimli hassas ayar 22

Şekil 4.1. phpMyAdmin ekran görüntüsü 27

Şekil 4.2. Microsoft Excel ile talep ve cevap sütunlarını tablosu 28

Şekil 4.3. PyCharm IDE görünümü 29

Şekil 4.4. OpenAI test ortamı 30

Şekil 5.1. Veri tabanından taleplerin dışa aktarılması 32

Şekil 5.2. E-postadan gelen destek talep 1 33

Şekil 5.3. E-postadan gelen destek talep 2 33

Şekil 5.4. E-postadan gelen destek talep 3 34
Şekil 5.5. Veri setinden istem oluşturma akış şeması 35
Şekil 5.6. Kişisel verinin maskelenmesine örnek 36
Şekil 5.7. Örnek JSONL formatı (OpenAI, 2024) 39
Şekil 5.8. İstem örneği 1 41
Şekil 5.9. İstem Örneği 2 41
Şekil 5.10. Yeniden eğitilme akış şeması 43
Şekil 5.11. Hassas ayar işlemi için model oluşturma 1 44
Şekil 5.12. Hassas ayar işlemi için model oluşturma 2 45
Şekil 5.13. İlk eğitim TL ve VL grafiği 47
Şekil 5.14. İkinci eğitim TL ve VL grafiği 47
Şekil 5.15. Üçüncü eğitim TL ve VL grafiği 49
Şekil 5.16. Dördüncü eğitim TL ve VL grafiği 50
Şekil 5.17. İlk eğitim sonrası soru-cevap 1 51
Şekil 5.18. İlk eğitim sonrası soru-cevap 2 52
Şekil 5.19. İkinci eğitim sonrası soru-cevap 1 53
Şekil 5.20. İkinci eğitim sonrası soru-cevap 2 53
Şekil 5.21. Üçüncü eğitim sonrası soru-cevap 1 54
Şekil 5.22. Üçüncü eğitim sonrası soru-cevap 2 55
Şekil 5.23. Dördüncü eğitim sonrası soru-cevap 1 56
Şekil 5.24. Dördüncü eğitim sonrası soru-cevap 2 56
Şekil 5.25. Eğitimde olmayan soru-cevap 57

ÇİZELGELER DİZİNİ

Çizelge 2.1. Popüler BDM'lerin karşılaştırması 21

Çizelge 5.1. Talepler ve Cevaplar 36

Çizelge 5.2. İlk Eğitim Metrikleri 47

Çizelge 5.3. İkinci Eğitim Metrikleri 48

Çizelge 5.4. Üçüncü Eğitim Metrikleri 49

Çizelge 5.5. Dördüncü Eğitim Metrikleri 50

BÖLÜM 1

GİRİŞ

Destek Talep Sistemleri (DTS), Bilgi İşlem Birimleri tarafından yönetilen kritik öneme sahip yazılımlardır. Özellikle çağrı merkezi üzerinden destek sunmayan kurumlarda DTS'ler birimlerin veya personellerin karşılaştıkları teknik sorunların çözülmesi, yazılım ve donanım ihtiyaçlarının karşılanması veya sistemlerin performansıyla ilgili yaşadığı sorunları konunun muhatabı olan teknik destek personeline yönlendirmek amacıyla kullanılmaktadır. Ancak, bu sistemlerin etkinliği, taleplerin niteliğine, karmaşıklığına ve tekrarlanmasına bağlı olarak değişiklik gösterebilir. Ayrıntı verilmeyen hatta sadece bir adet kelime ile iletilen talepler, gereksiz bilgilerin içinde esas sorunun kaybolduğu talepler veya özellikle aynı işlemin tekrarlandığı talepler, bilgi işlem personelinin rutin iş yükünü artırarak daha karmaşık ve stratejik işlere ayrılabilecek zamanın azalmasına neden olur.

Son yıllarda Yapay Zekâ (YZ) alanında, özellikle Doğal Dil İşleme (DDİ) alanında Önceden Eğitilmiş Üretken Dönüştürücülerin (ÖEÜD) ve Büyük Dil Modelleri'nin (BDM'ler) çığır açan gücü ortaya çıkmıştır. BDM'lerin başarısı yakın diyebileceğimiz bir zamanda henüz 2018 yılında, Google'ın BERT ve OpenAI'ın ÖÜED modelleriyle başlamıştır (Liga ve Robaldo, 2023). YZ tabanlı çözümler, günümüzde birçok alanda giderek daha fazla ilgi görmektedir. Bu çözümler, DTS'lerin verimliliğini artırmak ve kullanıcı deneyimini iyileştirmek amacıyla da kullanılmaktadır. Özellikle, ChatGPT gibi ileri seviye dil modellerinin DTS'lere entegre edilmesi, bu sistemlerin interaktif çözüm üretme kapasitelerini önemli ölçüde artırabilir.

Bu tezin amacı, ChatGPT'nin DTS'lerde nasıl kullanılabileceğini, tekrarlı taleplerin yönetiminde ne tür faydalar sağlayabileceğini ve organizasyonel verimliliği nasıl iyileştirebileceğini incelemektir. Özellikle, ChatGPT'nin belirli bir DTS'ye (KLU

DTS) özel olarak hassas ayar (fine-tuning) yapılarak nasıl optimize edilebileceği ele alınacaktır. Hassas Ayar dil modelinin spesifik bir organizasyonun taleplerine, diline ve operasyonel ihtiyaçlarına uygun hale getirilmesini sağlayarak, daha hızlı ve daha doğru çözümler sunabilen bir sistem yaratılmasına olanak tanır. Bu çalışmada, böyle bir uyarlamanın sağlayabileceği avantajlar ve uygulama yöntemleri değerlendirilecektir.

Tez kapsamında, öncelikle DDİ kavramı açıklanacak, ardından dil modelleri ve BDM'ler hakkında bilgi verilecektir. OpenAI'ın ÖEÜD modellerinin temel yapısı ve çalışma prensipleri detaylandırılacaktır. Sonrasında, bu modellerin DTS'lerdeki potansiyel kullanım alanları ve sağladığı avantajlar değerlendirilecektir. Hassas Ayar sürecine ilişkin olarak, veri hazırlama aşamaları, gerekli dosyaların modele tanıtılması, eğitilmiş modelin optimize edilmesi ve örnek uygulamalar üzerinden verilen cevapların uygunluğunun değerlendirilmesi ele alınacaktır. Böylece, ChatGPT'nin interaktif çözüm üretimi konusundaki potansiyeli ve organizasyonel iş yükünü nasıl hafifletebileceği somut verilerle ortaya konacaktır. Bu çalışmanın sonunda, DTS'lerde ChatGPT entegrasyonunun nasıl yapılabileceği bilgi işlem birimlerinin verimliliğini nasıl artırabileceği konularında öneriler sunulacaktır.

BÖLÜM 2

KURAMSAL BİLGİLER

2.1. Doğal Dil İşleme (DDİ)

Doğal Dil İşleme (DDİ) alanı, insan dillerinin hesaplamalı olarak işlenmesi ve anlaşılmasını hedefler; bu doğrultuda pratik problemleri çözmek için modeller ve süreçler geliştirir (Otto, Medina ve Kalita, 2020). DDİ, metin ve konuşma gibi insan dilini analiz etmek ve yorumlamak, anlam çıkarmak ve yararlı bilgiler elde etmek için algoritmalar kullanmayı içeren bir YZ alanıdır (Manning ve Schutze, 1999).

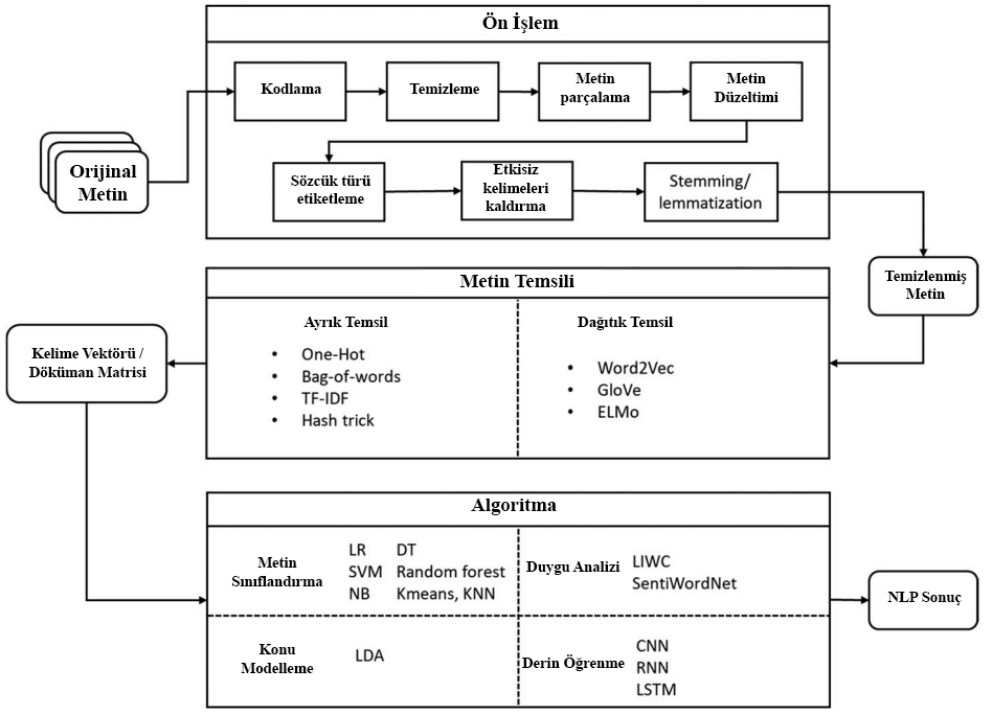

Şekil 2.1. DDİ akış şeması

DDİ süreci genel olarak dört aşamadan oluşur: metin ön işleme, metin temsili, modelleme ve modelin gelişimidir. Her bir aşama, Şekil 2.1'de gösterilen DDİ akış şemasında görüldüğü gibi, kendi içinde çeşitli alt basamakları içermektedir (Kang, Cai, Tan, Huang ve Liu, 2020).

2.2.Metin Ön İşleme

DDİ'nin ilk adımı, verilerin okunup analiz edilebilir hale getirilmesidir. Verilerin bu ön işlem kısmı yedi aşamadan oluşmaktadır.

1. Kodlama (Encoding), her dilde yaşanan en temel sorun karakter kodlamasıdır. Araştırmacılar bu sorunu UTF-8 karakter kodlamasını önererek çözmüşlerdir (Kang vd., 2020).
2. Temizleme (Cleaning), çeşitli platformlardan toplanan metin verilerindeki html etiketleri, görseller gibi metin dışı veriden temizlemektir (Kang vd., 2020).
3. Metin parçalama (Tokenization), metni genellikle kelime ve cümle birimleri halinde parçalara ayırma işlemidir (Kang vd., 2020).
4. Metin düzeltimi (Misspelling correction), bir giriş dizisinin (input string) geçerli bir indeks mi, yoksa sözlükte bulunan bir kelime mi olduğunu kontrol etmeyi ve yazım hatalarını düzeltmeyi içermektedir (Kang vd., 2020).
5. Sözcük türü etiketleme (POS tagging) , "part-of-speech tagging" teriminin kısaltmasıdır ve bir cümledeki her kelimeyi tanımı, bağlamı ve sözcük türüne göre belirli bir etiket setinden (örneğin, N isim, ADJ sıfat, ADV zarf gibi) uygun bir etiketle eşleştirme işlemidir (Kang vd., 2020).
6. Etkisiz kelimeler (Stop words), doğal dilde sıkça geçen ve bir cümlede önemli bir anlamsal bağlam taşımayan ya da belirli DDİ uygulamaları için gereksiz olan (Örneğin: de, ile, ve) kelimelerdir (Kang vd., 2020).
7. Lemmatizasyon, genellikle anlamlı kelimeleri, çekimsel formlarından genel formlarına indirgeme işlemidir. Diğer yandan, gövdeleme (stemming), kelimenin kök formunu veya gövdesini çıkarma işlemidir. Python'da WordNet, SpaCy ve Snowball gibi araçlar, lemmatizasyon ve gövdeleme işlemleri için sıkça kullanılmaktadır (Kang vd., 2020).

2.2.1. Metin Temsili

Ön işlemden geçmiş (temizlenmiş metin) verinin sayısal bir formata (vektörler veya matris) dönüştürülmesidir. Metinlerin en yaygın iki temsil yöntemi ayrık temsiller (discrete representation) ve dağıtık temsiller (distributed representation) olarak sınıflandırılabilir. (Patil, Boit, Gudivada ve Nandigam, 2023)

- Ayrık temsiller, metni bağımsız ve açık bir biçimde temsil eder. Örneğin, One Hot Encoding ve Bag of Words (BoW) bu kategoriye girer. Her kelime, belirli bir konumda sıfır veya bir değerini alarak ayrık bir şekilde temsil edilir. Ancak, bu yöntemler boyutlu ve seyrek matrisler oluşturur. Bu durum, boyutlanma laneti ve kaynak tüketimi gibi sorunlara yol açabilir. Ayrıca, bu temsiller kelimeler arasındaki anlam ilişkilerini yakalayamaz (Patil vd., 2023).
- Dağıtık temsiller, kelimeleri düşük boyutlu yoğun vektörler olarak ifade eder ve genellikle kelimeler arasındaki anlam ilişkilerini ve bağlamı daha iyi temsil eder. Word2Vec, GloVe, ve FastText gibi yöntemler, dağıtık temsillerin en yaygın örneklerindendir. Bu yaklaşımlar, her kelimeye anlam ilişkilerine dayalı sürekli bir vektör atar ve semantik benzerlikleri öğrenmek için etkili bir yöntem sunar (Patil vd., 2023).

2.2.2. Modelleme

Bir DDİ sistemi, doğal dildeki cümleleri girdi olarak alır ve bunları sınıflandırma görevleri için bir sınıf türüne, sıralama etiketleme görevleri için bir etiket dizisine veya soru-cevap (SC), diyalog, doğal dil üretimi (DDÜ) ve makine çevirisi (MÇ) gibi görevler için başka bir cümleye dönüştürür (Patil vd., 2023). Bu noktada en yaygın kullanılan algoritmalar:

1. Metin Sınıflandırma (Text Classification) algoritmaları verilen metinlerin belirlenen kategorilere göre sınıflandırılmaları için kullanılan algoritmalardır. Gözetimli öğrenme (Logistic Regression, Support Vector Machine, Naïve Bayes gibi) ve gözetimsiz learning (Kmeans ve K-Nearest-Neighbour) olmak üzere iki kategoride incelenebilir (Kang vd., 2020).
2. Duygu Analizi (Sentiment Analysis), her kelime sözlükte bir duygu puanına sahiptir ve bir cümledeki tüm kelimelerin duygu puanlarının

toplamı, ilgili cümlenin nihai duygu puanı olarak değerlendirilir. En popüler sözlükler arasında Linguistic Inquiry and Word Count (LIWC) ve SentiWordNet gösterilmektedir (Kang vd., 2020).

3. Konu Modelleme (Topic Modeling), veri oluşturma sürecini taklit ederek yazarın bir konu seçip bu konuyu ifade etmek için kelimeler seçmesini temel alır en yaygın kullanılan araç, Latent Dirichlet Allocation (LDA) yöntemidir (Kang vd., 2020).
4. Derin Öğrenme (Deep Learning) algoritmaları metin sınıflandırma görevlerinde yaygın olarak kullanılmaktadır. Bunlar: ESA (Evrişimli Sinir Ağı - Convolutional Neural Network), TSA (Tekrarlayan Sinir Ağı - Recurrent Neural Network), BP Neural Network (Backpropagation Neural Network) ve LSTM (Long Short-Term Memory) dir (Kang vd., 2020).

2.2.3. Doğal Dil İşleme Zorlukları

DDİ alanında, bir dilin anlamını çözümlemek ve o dilde üretim yapmak, genellikle ön koşul olarak kabul edilen bir dizi karmaşık görevi içerir. Her ne kadar dilin anlamını çözümlemek için temel kurallar bulunsa da bu kurallara dayanarak dilin bütüncül bir şekilde anlaşılması oldukça güçtür. Bunun temel nedenlerinden biri, insan dilinin her zaman katı kurallara uygun bir biçimde kullanılmamasıdır. Dil, aynı anlamın birçok farklı biçimde ifade edilebilmesine olanak tanır ve eksik kelimeler ya da dilbilgisel kusurlar içeren ifadeler bile anlam taşıyabilir. İnsanlar, bağlam ve sezgi sayesinde dildeki kusurları aşarak anlamı tahmin edebilirken, bilgisayarlar için bu durum ciddi bir engeldir (Kang vd., 2020).

Eksiklikler, belirsizlikler ve dilbilgisel hatalar, bilgisayarların dili doğru anlamasını zorlaştırır. Bu nedenle, DDİ modellerinin insan dilinin esnekliğini ve bağlam bağımlılığını anlayacak şekilde tasarlanması kritik bir öneme sahiptir.

2.3. Dil Modelleri (DM)

Dil, insanların düşüncelerini ifade etmek ve iletişim kurmak için kullandığı temel bir yetenektir. Bu yeti, erken çocukluk döneminde gelişmeye başlar ve hayat boyu ilerler (Hauser, Chomsky ve Fitch, 2002). Öte yandan, makinelerin insan dilini anlama ve bu dilde iletişim kurma yetisi doğuştan gelen bir özellik değildir. Bunu başarmak, ancak güçlü YZ algoritmalarının kullanılmasıyla mümkündür. Makinelere insanlar gibi okuma,

yazma ve iletişim becerisi kazandırmak, uzun yıllardır çözüme kavuşturulmaya çalışılan önemli bir araştırma alanıdır (Turing, 1950).

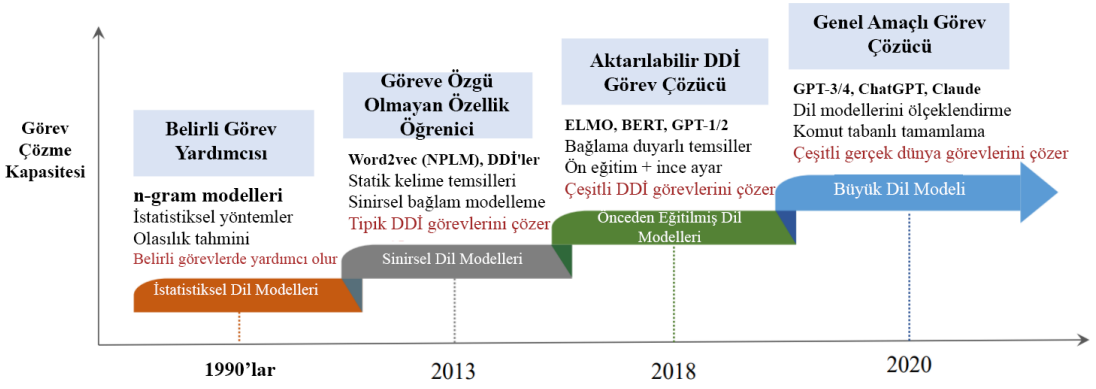

Şekil 2.2. Yıllara göre dil modelleri ve türleri

Şekil 2.2'de görüldüğü üzere dili anlama üzerine kurulmuş DM'ler temel olarak dört gruba ayrılmıştır.

2.3.1. İstatistiksel Dil Modelleri (İDM)

İstatistiksel analiz temelli İstatistiksel Dil Modelleri (İDM), en yakın bağlamı kullanarak bir sonraki kelimeyi tahmin etmeyi amaçlamıştır (Reti vd., 2024). Temel fikir, Markov varsayımına dayanarak kelime tahmin modelleri oluşturmaktır; örneğin, bir sonraki kelimenin en yakın bağlama dayanarak tahmin edilmesi. Sabit bir bağlam uzunluğu n olan İDM'ler, n-gram dil modelleri olarak adlandırılır; bunlara bigram ve trigram modelleri örnek verilebilir (Zhao vd., 2023).

Dil modellemenin çoğu uygulamasında, konuşma tanıma ve bilgi erişimi gibi, bir cümlenin olasılığı, n-gram olasılıklarının çarpımı olarak ayrıştırılır. Şöyle ki, S'nin k adet kelimeden oluşan belirli bir diziyi ifade ettiğini varsayarsak S'yi Denklem 2.1'deki gibi ifade edebiliriz (Liu ve Croft, 2005).

$$S = w_1, w_2, \dots, w_k \tag{2.1}$$

Bir n-gram dil modeli, kelime dizisi S'yi Markov süreci olarak ele alır ve bu durumda olasılık Denklem 2.2'deki gibi ifade edilir (Liu ve Croft, 2005).

$$P_n(S) = \prod_{i=1}^{k} P(w_i | w_{i-1},\ w_{i-2}, w_{i-3}, \dots, w_{i-n+1}) \tag{2.2}$$

Buradaki n değeri Markov sürecinin sırasını ifade eder. n = 2 olduğunda bigram dil modeli denir. Bigram dil modeli kelime çiftlerinin birlikte görülme sıklığı kullanılarak tahmin etmede kullanılır. n = 1için kelimelerin tekil olasılık tahminlerini kullanır ve unigram dil modeli adını alır. Kelime sırasının önemli olduğu konuşma tanıma ve makine çevirisi gibi uygulamalarda daha yüksek dereceli modeller (çoğunlukla trigram) kullanılır (Liu ve Croft, 2005).

İDM'ler, bilgi erişimi (IR) ve doğal dil işleme (DDİ) görevlerinde performansı artırmak için yaygın olarak kullanılmıştır. Ancak, boyutlanma laneti nedeniyle yüksek dereceli dil modellerinin tahmini zordur; çünkü çok fazla geçiş olasılığı hesaplanmalıdır. Bu sorunu çözmek için, geri dönüş kestirimi ve Good-Turing kestirimi gibi yöntemlerle veri seyrekliği azaltılmaya çalışılmıştır (Zhao vd., 2023).

2.3.2. Sinir Ağı Tabanlı Dil Modelleri (SATDM)

Sinir ağı tabanlı dil modelleri (SATDM'ler), kelime dizilerinin olasılıklarını sinir ağları kullanarak hesaplar. Bu modellerde, çok katmanlı algılayıcı (ÇKA) ve tekrarlayan sinir ağı (TSA) gibi yapılar öne çıkar (Zhao vd., 2023).

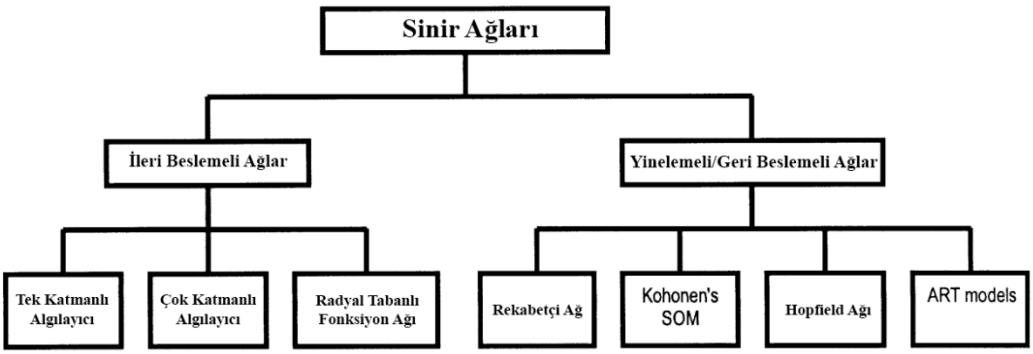

Şekil 2.3. Sinir ağlarının sınıflandırılması

Şekil 2.3'te, sinir ağları iki ana grupta sınıflandırılmıştır: döngü barındırmayan ileri beslemeli (Feed-forward) sinir ağları ve geri besleme bağlantısı nedeniyle döngü barındıran geri beslemeli (Recurrent/Feedback) sinir ağları. Bu sınıflandırma, sinir ağlarının yapısal özellikleri ve bilgi akış mekanizmalarına dayanmaktadır (Jain, Mao ve Mohiuddin, 1996).

İleri beslemeli sinir ağlarında bilgi, yalnızca ileri yönlü bir akış izler ve döngü bulunmaz. Bu ağlar, genellikle sınıflandırma ve regresyon problemleri gibi statik veri ile

çalışılan durumlarda tercih edilir. Geri beslemeli sinir ağları ise bilgi akışını geri besleme bağlantıları aracılığıyla döngüsel hale getirir. Bu özellik, özellikle zaman serileri veya sıralı veri gibi dinamik bilgilerle çalışırken önemli bir avantaj sağlar. Bu iki ağ türü arasındaki temel farklar, problem türüne ve veri yapısına uygun sinir ağı seçimini mümkün kılmaktadır.

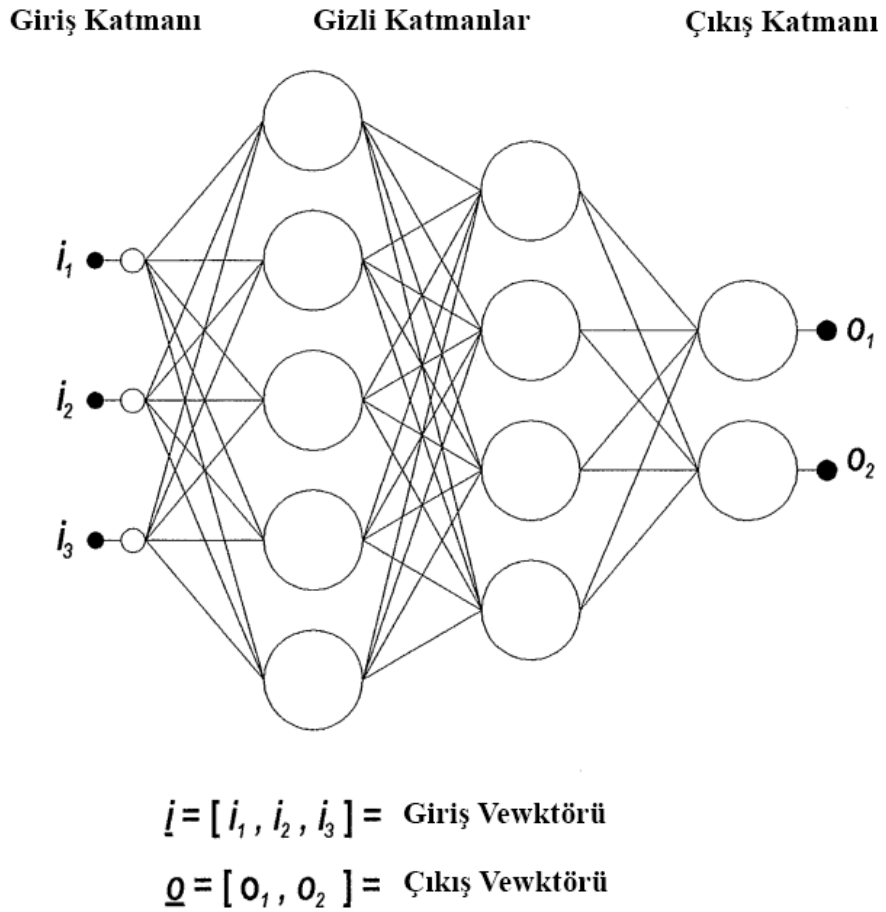

Şekil 2.4. İki gizli katmanlı bir ÇKA örneği

Şekil 2.4'te, giriş katmanı, iki gizli katman ve bir çıkış katmanından oluşan, dört katmanlı bir Çok Katmanlı Algılayıcı (ÇKA - Multi-Layer Perceptron) örneği sunulmuştur. Bu model, birbirine bağlı nöronlar veya düğümlerden oluşan bir sistemdir ve bir giriş vektörü ile bir çıkış vektörü arasında doğrusal olmayan bir eşlemeyi gerçekleştiren bir yapıyı temsil eder (Gardner ve Dorling, 1998).

ÇKA, her bir nöronun ağırlıklandırılmış girişleri topladığı, bir aktivasyon fonksiyonu uyguladığı ve bu işlem sonucunda elde edilen değeri bir sonraki katmana

aktardığı bir mekanizmaya sahiptir. Giriş katmanı, modele veri sağlar; gizli katmanlar, öğrenme ve özellik çıkarımı sürecinin gerçekleştiği bölgelerdir; çıkış katmanı ise son tahmin veya kararları üretir. Bu tür bir yapı, karmaşık ve doğrusal olmayan ilişkileri öğrenmekte oldukça etkilidir ve sınıflandırma, regresyon gibi birçok makine öğrenimi probleminde başarıyla kullanılmaktadır.

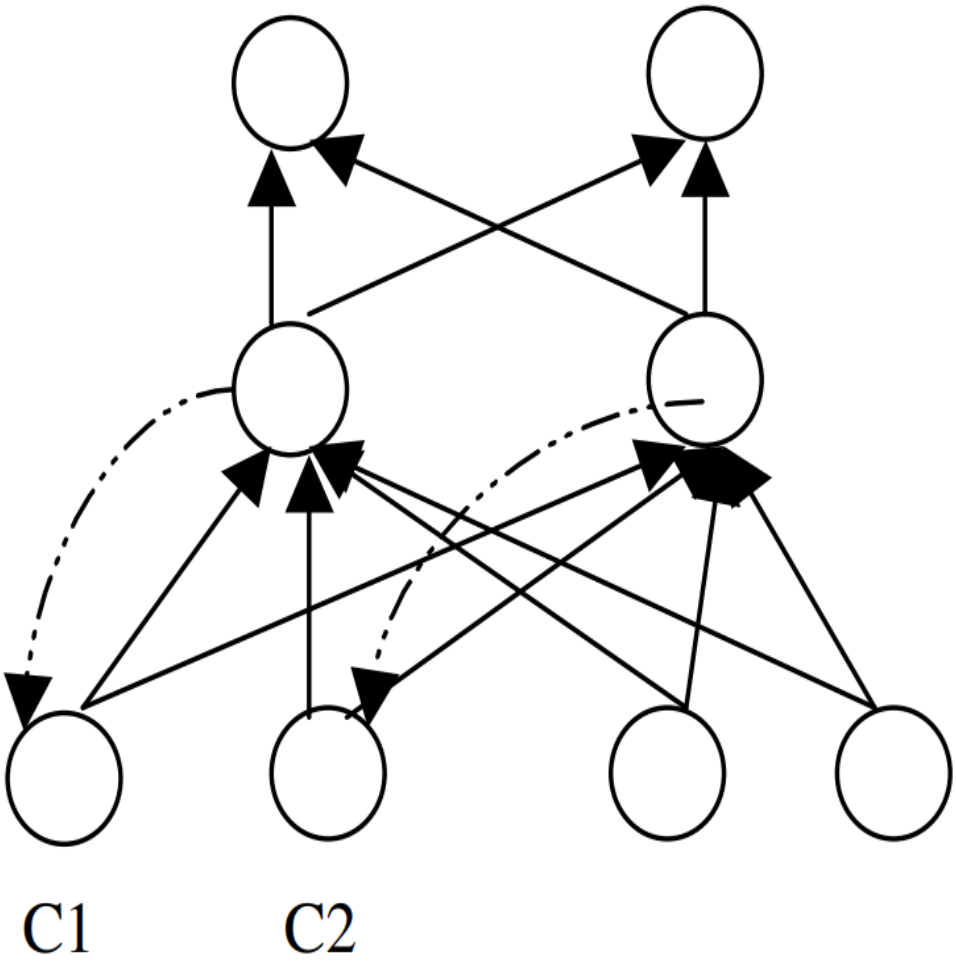

Şekil 2.5. Basit bir TSA örneği

Şekil 2.5'te karakter dizilerini öğrenmek için oluşturulmuş bir TSA örneği gösterilmiştir. Bazı düğümler ileri beslemeli yapıya aitken, diğerleri sıralı bağlamı sağlamak için kullanılır ve geri bildirim alır. Bağlam birimlerinin (C1 ve C2) ağırlıkları, giriş birimleri gibi geri yayılım yöntemiyle güncellenir. Bu birimler, ikinci katmandan

gecikmeli geri bildirim alır. Eğitim verisi, girdiler ve onların beklenen çıktılarından oluşur. Ağ, bir karakter dizisinde bir sonraki harfi tahmin etmek veya dizinin doğruluğunu kontrol etmek için eğitilebilir (Medsker ve Jain, 2001).

2.3.3. Önceden Eğitilmiş Dil Modelleri (ÖEDM)

Bilgisayarlı görme alanında VGGNet, AlexNet ve GoogleNet gibi önceden eğitilmiş görüntü modellerinin başarısından ilham alan doğal dil işleme (DDİ) araştırmacıları, dönüştürücü temelli ve kendinden denetimli öğrenmeye dayalı önceden eğitilmiş modeller geliştirmeye odaklanmıştır. Önceden eğitilmiş dil modelleri (ÖEDM'ler), büyük miktarda metin verisi üzerinde eğitilmiş, temelde dönüştürücü tabanlı gelişmiş derin öğrenme modelleridir ve sınırlı miktarda etiketli veriyle farklı görevlerde kolayca uyarlanabilir. Dönüştürücü modelinin yanı sıra kendinden denetimli öğrenme ve transfer öğrenme, ÖEDM'lerin mümkün olmasını sağlayan temel kavramlardır (Kalyan, 2023).

Şekil 2.6'da kullanılan bazı ÖEDMler arasındaki ilişkileri açıklığa kavuşturmak için, ÖEDM'lerin dört farklı bakış açısından sınıflandırıldığı bir gruplandırma gösterilmiştir. Bu sınıflar:

1. Temsil Türü: buna göre ÖEDM'leri bağlamsal olmayan ve bağlamsal modeller olarak ikiye ayrılmakta.
2. Mimari: ÖEDM'lerin kullandığı omurga ağına göre sınıflandırılır. Bu ağlar arasında LSTM, Dönüştürücü kodlayıcı (encoder), Dönüştürücü çözücü (decoder) ve tam Dönüştürücü mimarisi yer alır. "Dönüştürücü", standart kodlayıcı-çözücü mimarisini ifade eder. "Dönüştürücü kodlayıcı" ve "Dönüştürücü çözücü" ise bu mimarinin sırasıyla yalnızca kodlayıcı ve çözücü bölümlerini ifade eder. Aralarındaki fark, çözücü kısmının, maskelenmiş kendine dikkat mekanizmasını (masked self-attention) üçgen matris ile kullanarak token'ların gelecekteki (sağdaki) pozisyonlara odaklanmasını engellemesidir.
3. Ön Eğitim Görev Türleri: ÖEDM'lerin kullandığı ön eğitim görevlerinin türleri. Gözetimli ve gözetimsiz olmak üzere iki başlıkta toplanmıştır.
4. Genişletmeler: Çeşitli senaryolar için tasarlanmış ÖEDM'ler. Bunlar arasında bilgiyle zenginleştirilmiş ÖEDM'ler, çok dilli veya dile özgü ÖEDM'ler, çok

modelli ÖEDM'ler, alana özgü ÖEDM'ler ve sıkıştırılmış ÖEDM'ler bulunmaktadır.

şeklinde sınıflara ayrılabilir (Qui vd., 2020).

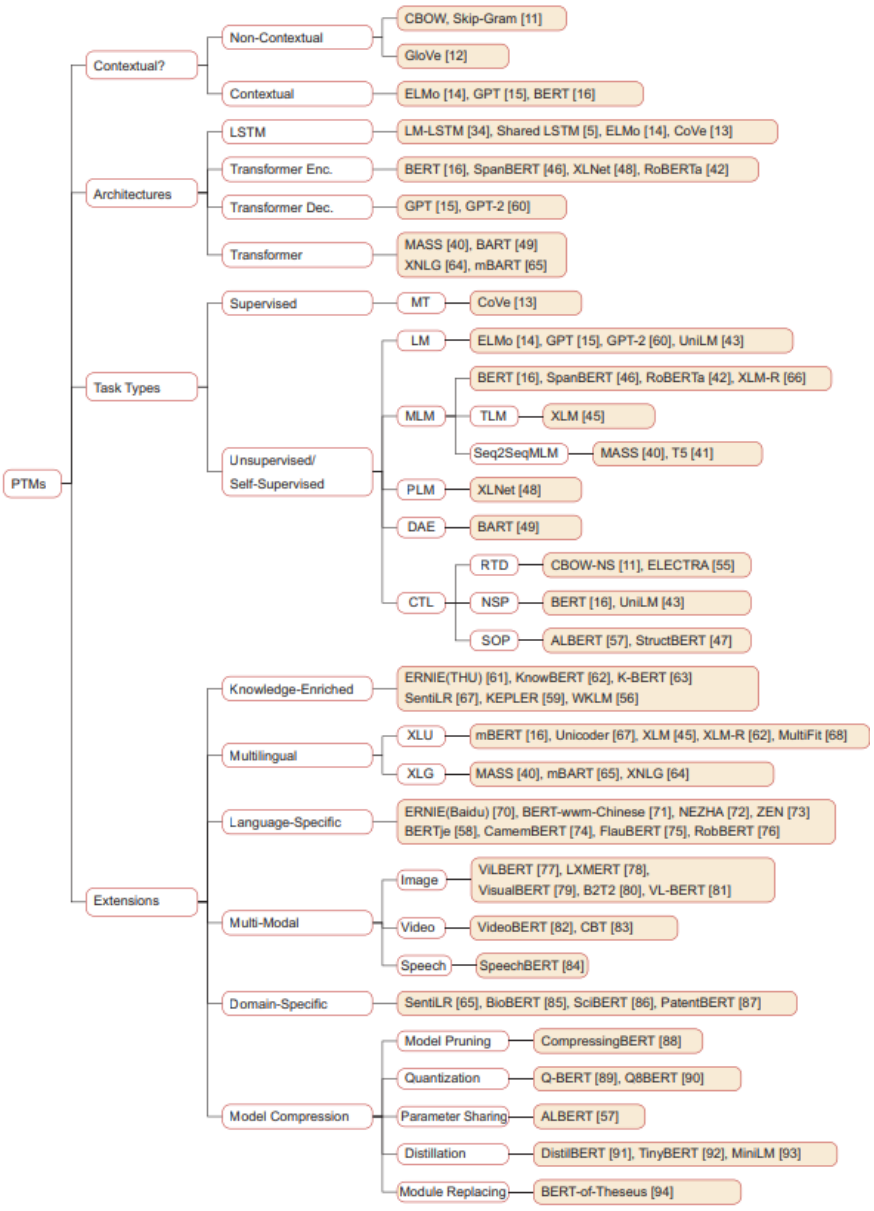

Şekil 2.6. Örnekleriyle ÖEDM sınıflandırması

Önceden eğitilmiş dil modelleri (ÖEDM'ler), GPT-1 ve BERT ile başlayan süreçte, hassas ayar ile görev odaklı görevlerde kullanılmak üzere büyük ilerlemeler

kaydetmiş ve görev odaklı modellerin eğitimi için gereken etiketli veri miktarını azaltmıştır (Kalyan, Rajasekharan ve Sangeetha, 2021, 2022). ÖEDM'ler, öncelikle büyük veri kümelerinde eğitilir, ardından etiketli veriyle görev odaklı hassas ayar uygulanılır. Ancak her görev için hassas ayar gereksinimi, modellerin genelleme yeteneğini sınırlandırır ve maliyetleri artırır (Kalyan ve diğerleri, 2021).

ÖEDM'lerin performansı, model boyutunun, eğitim verisinin ve hesaplama gücünün ölçeklendirilmesiyle artmıştır. Bu ölçekleme, GPT-3 gibi modellerin gelişmesine yol açmıştır. ÖEDM'ler, dar YZ sistemleri olarak kabul edilse de yapay genel zekâ hedefi, daha geniş ve genelleyici modeller geliştirmeye yönelik çalışmaları motive etmektedir (Kalyan, 2023).

ÖEÜD gibi modeller, doğal dil metinlerini işlemek için dönüştürücü mimarisini kullanır ve büyük metin verileri üzerinde gözetimsiz öğrenme ile önceden eğitilir. Bu süreçte, model, önceki kelimelere dayanarak bir sonraki kelimeyi tahmin etmeyi öğrenir ve kelimeler arasındaki bağlam ilişkilerini keşfeder (Yenduri vd., 2024).

Dönüştürücüler (transformer) ve Üretken Önceden Eğitilmiş Dönüştürücüler (Generative Pre-trained Transformer- ÖEÜD) son yıllarda doğal dil işleme (DDİ) alanında devrim niteliğinde ilerlemelere yol açmıştır. Bu modeller, dilin daha derin ve kapsamlı bir şekilde anlaşılmasını sağlayarak, metin üretimi, çeviri ve özetleme gibi görevlerde üstün performans sergilemektedir.

2.3.3.1.Dönüştürücüler

Dönüştürücü mimarisi, 2017 yılında Vaswani ve arkadaşları tarafından tanıtılmıştır. Bu mimari, dikkat mekanizmasını kullanarak, dil modellerinin daha uzun bağlamları ve karmaşık dil yapısını anlamasını mümkün kılar. Dönüştürücüler, geleneksel tekrarlayan sinir ağları (TSA) ve evrişimli sinir ağları (ESA) gibi yaklaşımların sınırlamalarını aşarak, paralel işlemeyi ve daha verimli öğrenmeyi sağlar.

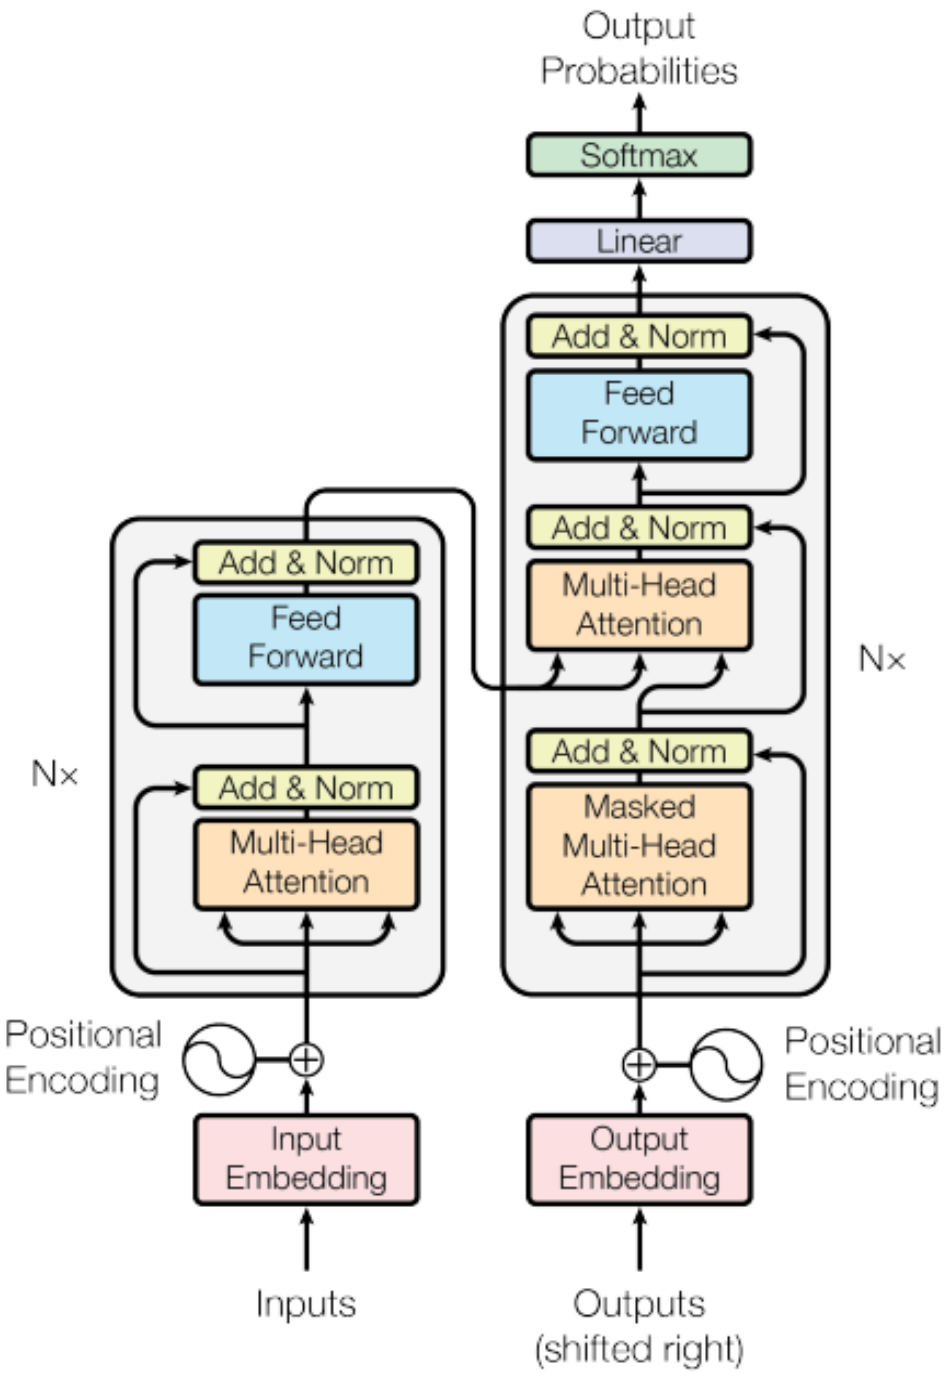

Şekil 2.7. Dönüştürücü (Transformer) Mimarisi

Sinirsel sıralı dönüştürme modelleri, kodlayıcı-çözümleyici (encoder-decoder) yapısına sahiptir. Bu yapıda, kodlayıcı bir giriş sembol dizisini (x1, ..., xn), sürekli temsillerden oluşan bir diziye z = (z1, ..., zn) dönüştürür. Bu temsiller (z) kullanılarak, çözümleyici (decoder) bir çıktı sembol dizisini (y1, ..., ym) birer birer oluşturur. Model,

her adımda otomatik-regresif bir şekilde çalışır; yani, bir sonraki sembolü üretirken daha önce oluşturulmuş sembolleri ek giriş olarak kullanır (Vaswani vd., 2017).

Dönüştürücü mimarisi, hem kodlayıcı (encoder) hem de çözümleyici (decoder) için yığınlanmış öz-dikkat (self-attention) ve noktasal, tam bağlantılı katmanları kullanarak, Şekil 2.7'nin sol ve sağ taraflarında sırasıyla kodlayıcı (encoder) ve çözümleyici (decoder) olmak üzere ikili yapı izlemektedir.

Kodlayıcı (Encoder) ve kod çözücü (Decoder), her biri N=6 aynı katmandan oluşan yığınlardan oluşmaktadır. Kodlayıcı, çoklu başlıklı kendi kendine dikkat mekanizması ve ileri beslemeli bir ağ içermekte iken, kod çözücü buna ek olarak kodlayıcı çıktısına dikkat uygulayan bir alt katman ekler. Tüm alt katmanlarda Artık Bağlantı (Residual Connection) ve katman normalleştirme kullanılır. Ayrıca kod çözücüde, gelecekteki pozisyonlara dikkat etmeyi önlemek için maskeleme uygulanır. Dikkat mekanizması, bir sorgu ile anahtar-değer çiftlerini ilişkilendirerek, değerlerin ağırlıklı toplamını hesaplar (Vaswani vd., 2017).

2.3.3.2.Önceden Eğitilmiş Üretken Dönüştürücüler (ÖEÜD)

Hem dönüştürücü hem de geleneksel derin öğrenme modelleri, sıfırdan eğitilme gereksinimi nedeniyle büyük miktarda etiketlenmiş veri gerektirir ve bu da model geliştirmeyi pahalı hale getirir (Kalyan, 2023).

ÖEÜD, görsel ve metin girdilerini işleyip çıktılar üretebilen çok modlu önceden eğitilmiş bir büyük dil modelidir ve geniş bir uygulama yelpazesinde kullanılabilir. Bu tür modeller, diyalog sistemleri, metin özetleme ve makine çevirisi gibi alanlarda güçlü bir potansiyele sahiptir. ÖEÜD modellerinin temel amacı, doğal dil metinlerini anlama ve oluşturma kabiliyetlerini geliştirmektir; özellikle karmaşık ve ince detaylara sahip senaryolarda başarılı olmaları hedeflenmektedir (Achiam vd.,2023).

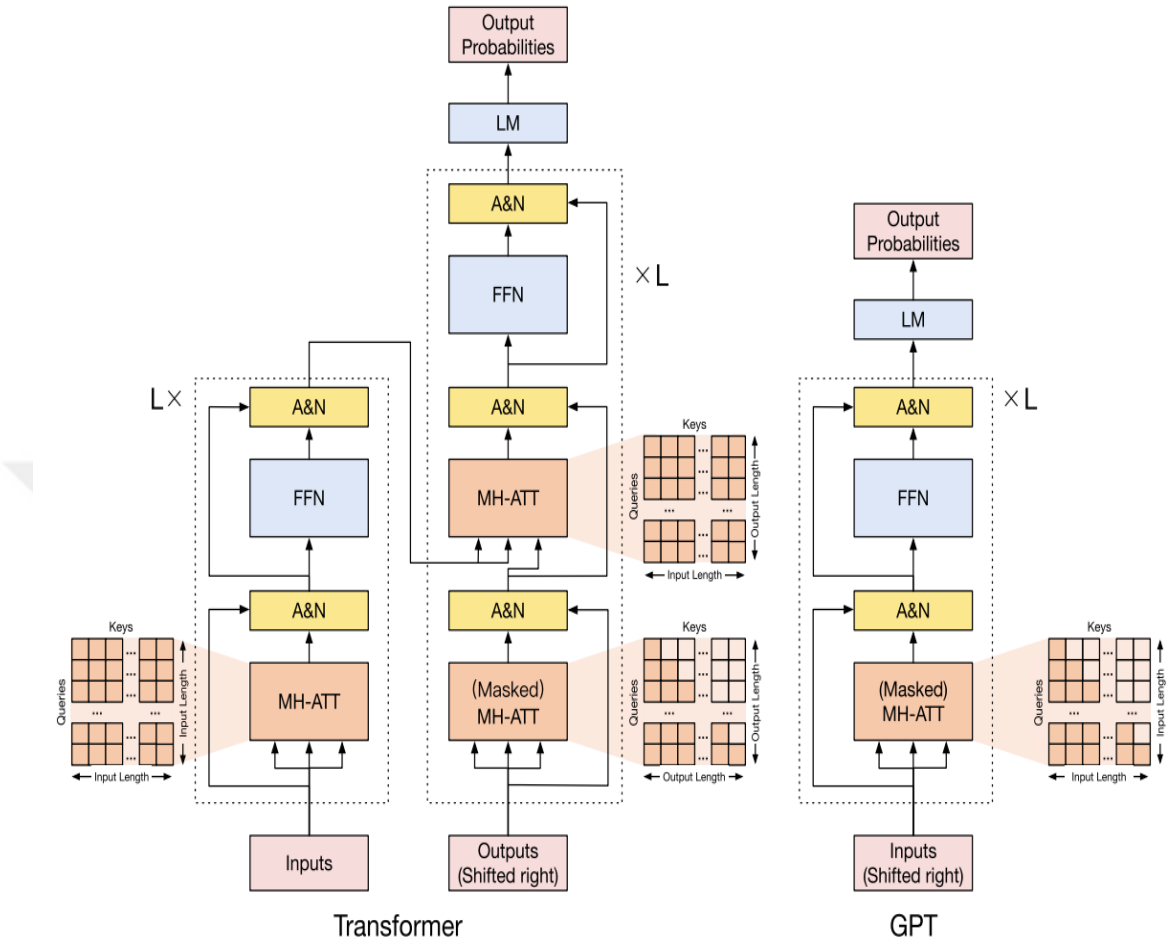

Şekil 2.8. Dönüştürücü ve ÖEÜD mimarileri

Önceden Eğitilmiş Üretken Dönüştürücü (ÖEÜD), OpenAI, Inc. tarafından geliştirilen ileri düzey bir dil modelidir. ÖEÜD'nin temel mimarisi, güçlü bir doğal dil işleme yeteneği sunarak, girdi metinlere (istemler) dayalı olarak anlamlı ve insan anlayışına uygun metinler üretebilmektedir. ChatGPT, bu modelin bir uygulaması olup, ÖEÜD tabanlı bir sohbet robotu olarak geliştirilmiştir ve kullanıcı girdilerine uygun akıcı ve bağlamsal metinler üretme yeteneğine sahiptir.

Şekil 2.8'de mimari yapısı gösterilen ÖEÜD, Dönüştürücü mimarisi üzerine inşa edilmiş bir YZ modelidir. Bu mimari, özellikle dikkat mekanizmaları sayesinde uzun metin bağlamlarını anlamada ve işleme alanda üstün performans göstermektedir. ÖEÜD'nin yeni içerikler üretme (generative) yeteneği, önceden eğitilmiş büyük ölçekli veri kümeleri ile gerçekleştirdiği ön eğitim (pre-training) aşamasına dayanmaktadır. Bu

özellikleri sayesinde ÖEÜD, çeşitli dil işleme görevlerinde esnek ve etkili bir çözüm sunmaktadır (Cheng vd., 2023).

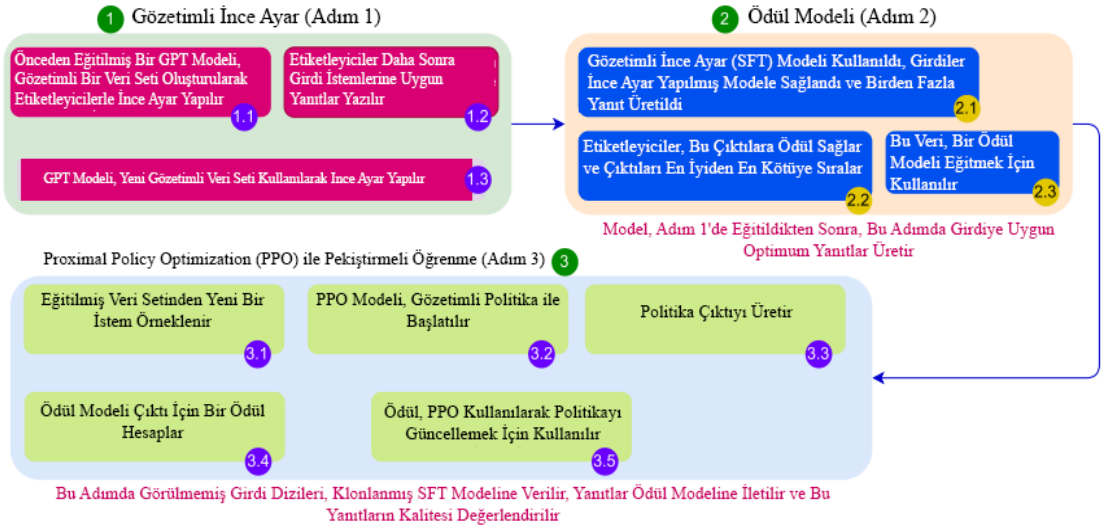

Şekil 2.9. ÖEÜD çalışma yolu

ÖEÜD'nin Şekil 2.9.'da gösterildiği gibi üç adımlı bir çalışma süreci vardır:

1. İlk adım, gözetimli hassas ayar işlemini içerir,
2. İkinci adım, girdilere optimal yanıtlar üretmeyi kapsar,
3. Üçüncü adım ise, yakınsal politika optimizasyonu (proximal policy optimization) ve pekiştirmeli öğrenmeyi içerir.

Model, ön eğitimden sonra, metin sınıflandırma veya metin üretimi gibi belirli görevler için hassas ayar uygulanabilir. Bu aşamada model, ele alınan göreve özgü daha küçük bir veri kümesi üzerinde eğitilir ve modelin parametreleri, o görevdeki performansı en üst düzeye çıkarmak için ayarlanır (Yenduri vd., 2024).

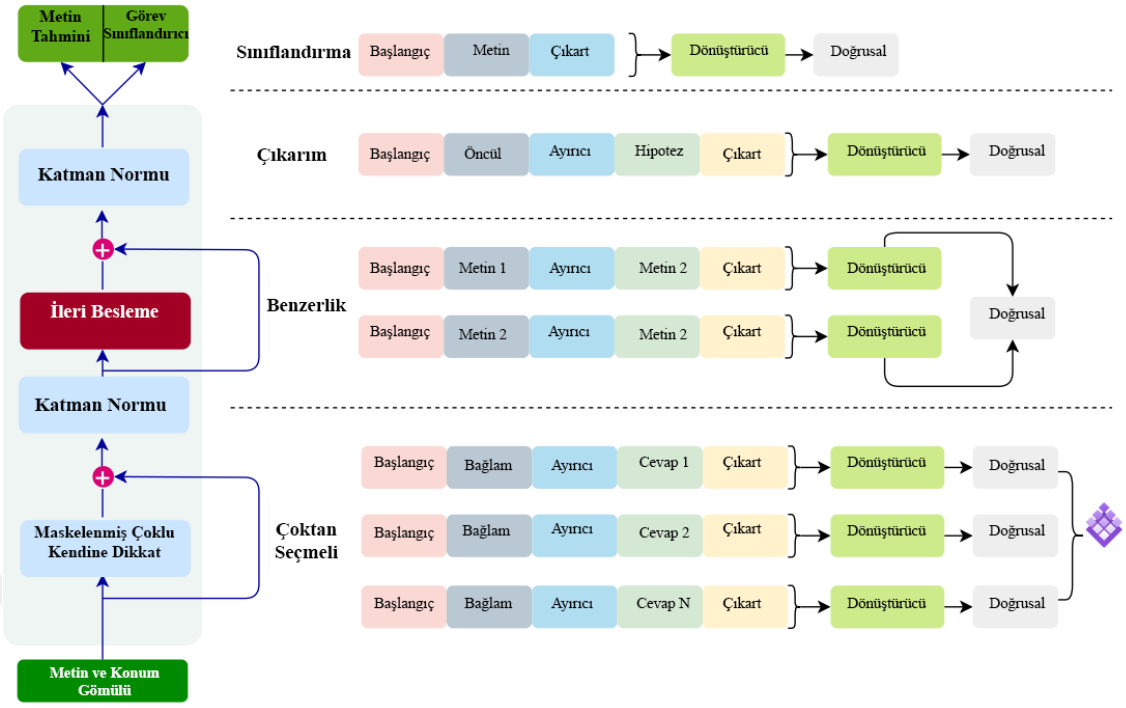

Şekil 2.10. Görev bazlı hassas ayar için Dönüştürücü ve girdi dönüşümleri.

ÖEÜD modelleri, metin oluşturma sırasında, önceki kelimelere dayanarak bir dizideki sonraki kelimeyi tahmin ederek metin üretir. Modelin nasıl modifiye edildiğine bağlı olarak, girdiye benzer metinler veya belirli bir tema ya da stile uygun içerikler üretebilir. Şekil 2.10, ÖEÜD modelinin dönüştürücü mimarisini ve farklı görevler için hassas ayar uygulamak amacıyla kullanılan girdi dönüşümlerini göstermektedir (Yenduri vd., 2024).

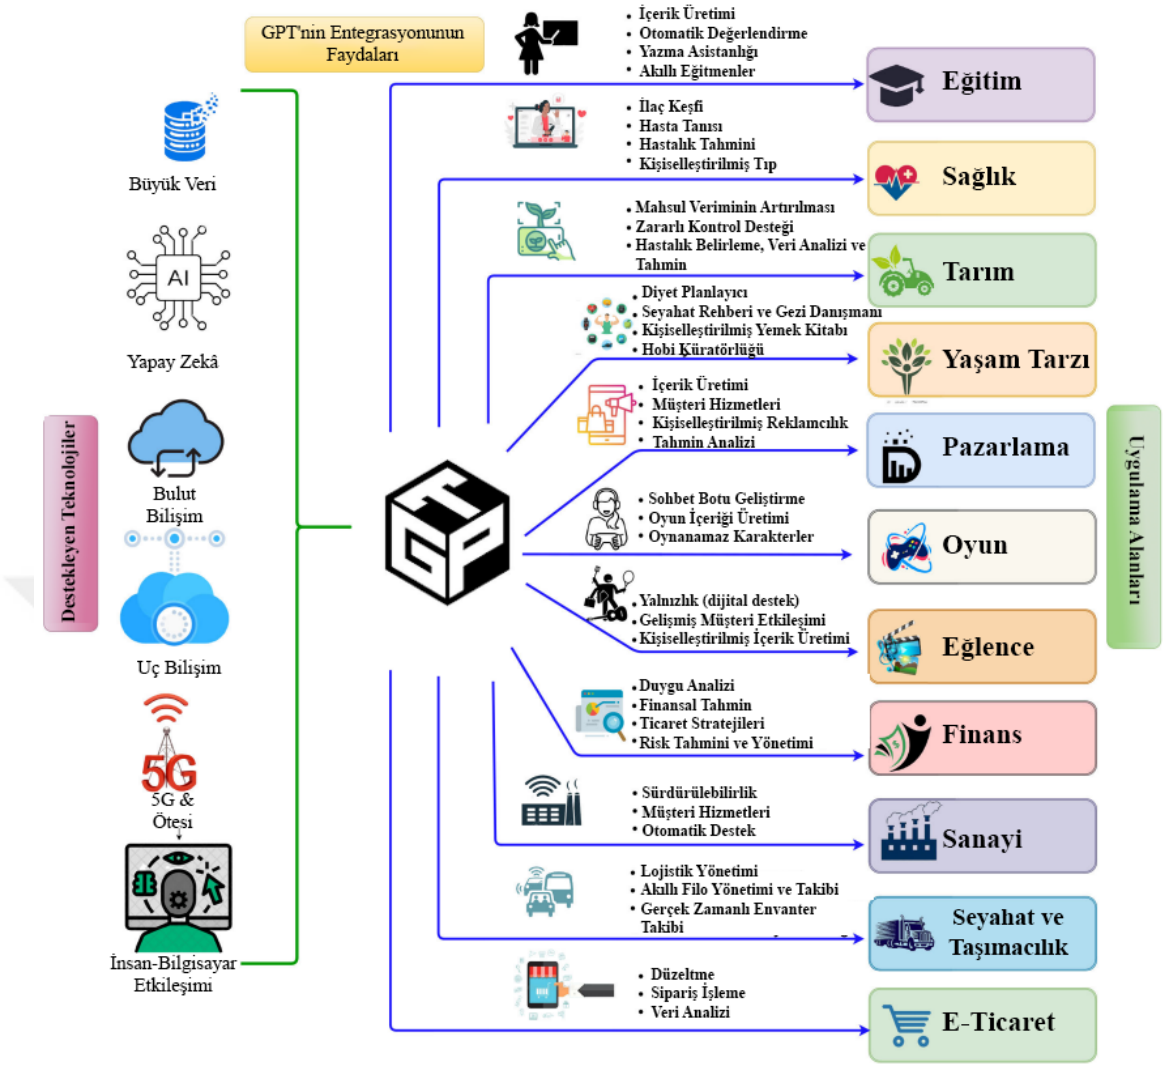

Şekil 2.11. ÖEÜD Modellerinin çeşitli uygulamalar üzerindeki etkisi

ÖEÜD modelleri günümüzde çok önemli ilerlemeler kaydetmiş olup, eğitim, sağlık, sanayi, tarım, seyahat ve ulaşım, e-ticaret, eğlence, yaşam tarzı, oyun, pazarlama ve finans gibi çeşitli sektörlerde etkisini hissettirmektedir. Şekil 2.11'de çeşitli uygulamalar üzerindeki etkileri görsel olarak gösterilmiştir (Yenduri vd., 2024).

2.3.4. Büyük Dil Modelleri (BDM)

Büyük Dil Modelleri (BDM), insan dilini anlamak ve işlemek amacıyla büyük miktarda metin verisinden bağlamlı metin anlamını ve olasılıklarını modelleyen, geniş parametrelere sahip dil modelleridir. Genellikle BDM'ler, yüz milyarlarca ya da daha fazla parametreye sahiptir ve bu parametreler, büyük ölçekli metin verilerinin işlenmesiyle optimize edilir (Yao vd., 2024). Bu modeller, dilin hem dil bilgisel yapısını

hem de semantik özelliklerini kavrayabilme yeteneklerinden dolayı doğal dil işleme (DDİ) alanındaki farklı görevleri (Örneğin, metin tamamlama, özetleme, çeviri, soru yanıtlama ve duygu analizi vb.) yerine getirme konusunda etkin olarak kullanılmaktadırlar.

BDM'ler dört temel özelliğe sahip olmalıdır. Öncelikle, doğal dili derinlemesine anlayarak bilgi çıkarımı ve çeviri gibi dil odaklı görevleri yerine getirebilmelidir. Ayrıca, insan benzeri metinler üretebilme yeteneğiyle cümle tamamlama, paragraf yazma ve makale oluşturma gibi görevlerde başarılı olmalıdır. Bağlamsal farkındalık sergileyerek alan bilgisine duyarlılık göstermeli ve bilgi yoğun görevleri desteklemelidir. Son olarak, problem çözme ve karar verme süreçlerinde etkili olarak bilgi alma ve soru-cevap sistemlerinde önemli bir rol üstlenmelidir (Yang vd., 2023). Şekil 2.12'de bazı BDM örnekleri verilmiştir.

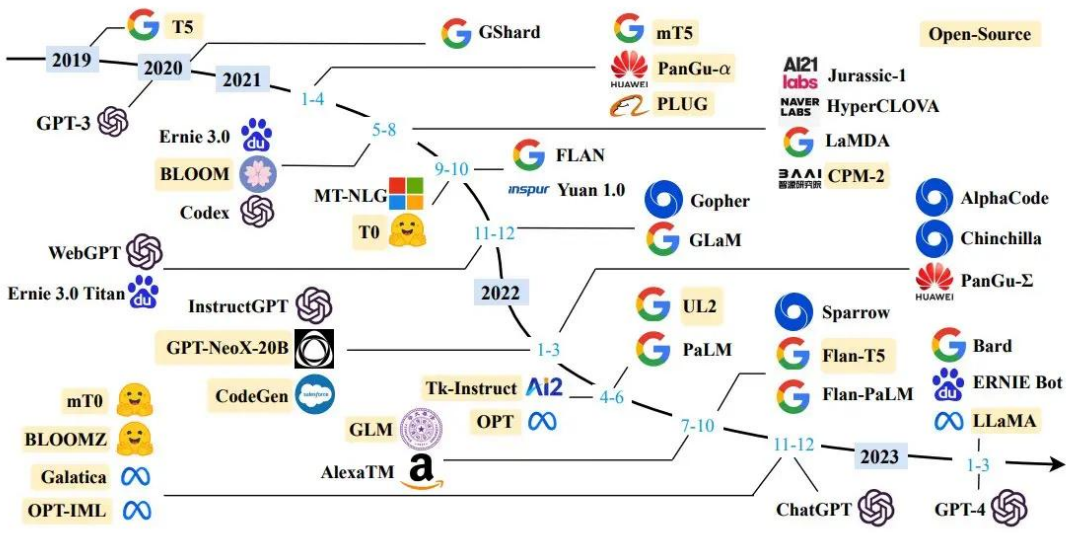

Şekil 2.12. BDM örnekleri

Dönüştürücü tabanlı modeller, büyük miktarda veri üzerinde eğitildiğinde, dilin karmaşık özelliklerini ve bağlamsal bağlantılarını öğrenebilir. Örnek olarak, OpenAI GPT serisi, dil üretimi üzerine optimize edilirken, BERT (Bidirectional Encoder Representations from Transformers) daha çok anlam çıkarma görevlerinde üstün performans göstermektedir. Bu modeller, hassas ayar teknikleri ile farklı disiplinlere veya görevlere uyarlanarak geniş bir kullanım yelpazesi sunar.

Çizelge 2.1. Popüler BDM'lerin karşılaştırması

Model	Tarih	Geliştirici	Mimari	Parametre Sayısı
GPT-4	2023.03	OpenAI	Çözücü	1.7 T
GPT-3	2020.06	OpenAI	Çözücü	175 B
BERT	2018.08	Google	Kodlayıcı	340 M
LLaMA	2023.02	Meta AI	Çözücü	65 B

2024 yılında Yao ve çalışma arkadaşları tarafından yayımlanan araştırmada, büyük dil modellerinin kapsamlı bir karşılaştırması sunulmuştur. Bu karşılaştırma, modellerin çıkış tarihleri, geliştiricileri ve eğitim sürecinde kullanılan parametre sayıları temel alınarak Çizelge 2.1'de özetlenmiştir.

2.4.Hassas Ayar (Fine-Tuning)

Hassas Ayar, önceden eğitilmiş bir YZ modelini (örneğin ÖEÜD gibi dil modelleri) belirli bir görev veya veri kümesi üzerinde yeniden eğiterek modelin performansını optimize etme sürecidir. ÖEÜD gibi BDM'ler genellikle genel bir metin veri seti üzerinde eğitilir. Ancak bu tür genel modeller, özel bir alana (örneğin tıbbi metinler, teknik belgeler veya müşteri destek talepleri) veya belirli bir göreve (örneğin soru yanıtlama, özetleme) uygun olacak şekilde özelleştirilmemişlerdir (Bousselham, Nfaoui ve Mourhir, 2024). Bu sebeple önceden eğitilmiş dil modelleri (ÖEDM'ler), manuel olarak yazılmış istem desenlerinin modele ek bir girdi olarak sağlandığı istemlerle daha da özelleştirilebilmektedirler. Bu istemlerin, birçok doğal dil anlama (DDA) görevinde performansı da önemli ölçüde artırdığı bilinmektedir (Brown vd., 2020).

Hassas Ayarın amaçları arasında:

1. **Özelleştirme:** Modeli, belirli bir alanın jargonunu veya stilini öğrenmeye zorlar.
2. **Performans İyileştirme:** Belirli bir görevde daha iyi sonuçlar almasını sağlamak,
3. **Kullanım Kolaylığı:** Daha az manuel müdahale ile daha tutarlı sonuçlar elde etmek, gösterilebilir.

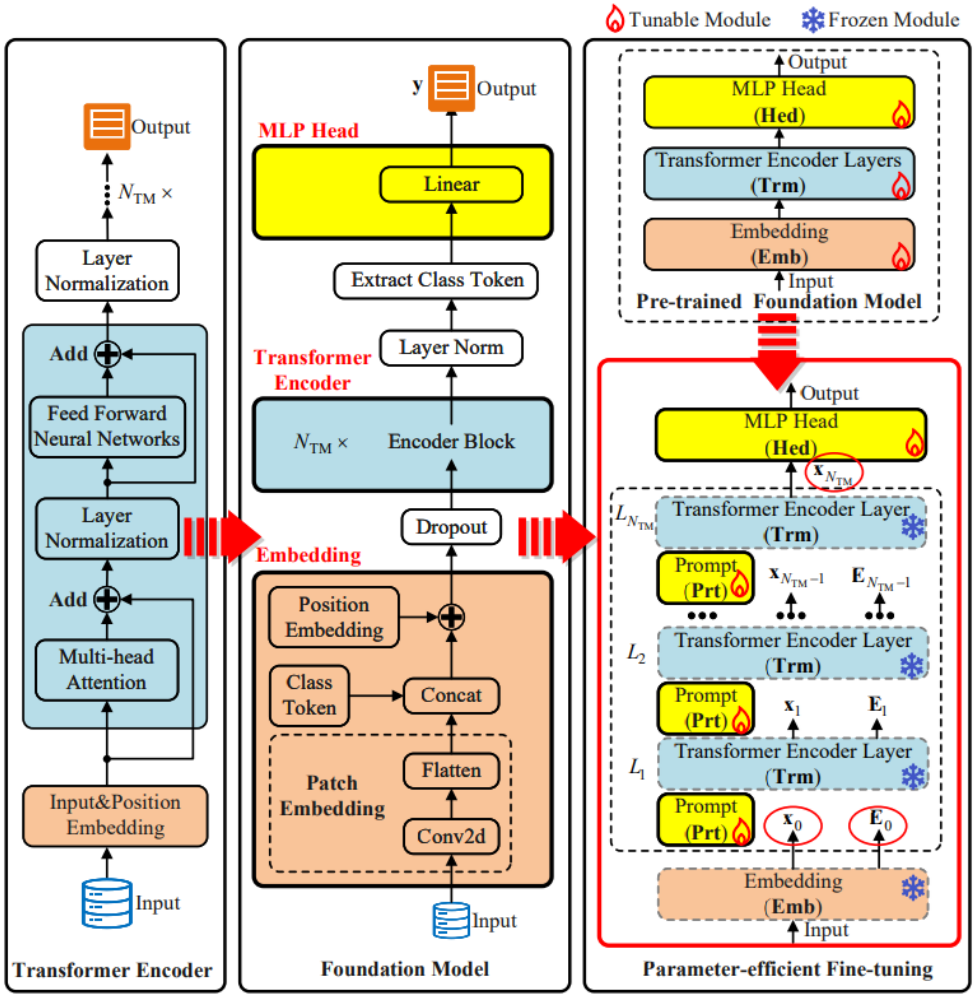

Şekil 2.13. Dönüştürücü tabanlı temel modelde parametre verimli hassas ayar

Şekil 2.13'te parametre açısından verimli hassas ayar gösterilmektedir. Burada frozen module ikonlu kısımların (Trm) çoğu eğitilmez. Tunable module ikonlu kısımlar Prompt(prt) ve ÇKA Başlığı (MLP Head) gibi, istem parametrelerini ekleyerek ve son katmanları hassas ayar uygulanarak verimli bir güncelleme yapılabilmektedir.

2.4.1. Hassas Ayar Yöntemleri

BDM'lerde kullanılacak hassas ayar yöntemleri iki başlıkta incelenebilmektedir.

2.4.1.1.Tam Model Hassas Ayar

Modelin tüm parametreleri üzerinde hassas ayar işlemi uygulanır. Bu yöntem, büyük veri kümeleri ve yüksek hesaplama gücü gerektirir. Daha fazla zaman ve enerji tüketir(Ye vd., 2023).

2.4.1.2.Parametre Verimli Hassas Ayar (PVHA)

PVHA tekniklerinde, sadece küçük ek parametreler veya istem tabanlı mekanizmalar eğitilirken, modelin büyük kısmı dondurulmuş olarak kalır. Bu, hesaplama maliyetini önemli ölçüde azaltır (Li ve Liang, 2021;Hu vd., 2021). Bazı öne çıkan teknikler:

1. LoRA (Düşük Dereceli Uyum / Low-Rank Adaptation) (Hu vd., 2021)
2. Önek Ayarlama (Li ve Liang, 2021)
3. Adaptör Katmanları
4. İstem Ayarlama (Ding vd., 2022)

Hassas ayar uygulamak için en önemli nokta veri seti olsa da modellerin eğitim sürecinde kullanılan önemli kavramlar olan epoch sayısı, öğrenme hızı (learning rate) ve küme boyutu, modelin performansı ve eğitim süreci üzerinde doğrudan etkili olan temel parametrelerdir (Li vd., 2024).

Epoch sayısı tüm veri kümesinin modele kaç kez gösterileceğini belirtir. Epoch sayısı, modelin eğitilme süresini belirler. Az epoch sayısı, modelin yeterince öğrenememesine (underfitting) yol açabilir. Fazla epoch sayısı ise modelin veri kümesine aşırı uyum sağlamasına (overfitting) neden olabilir.

Öğrenme hızı, modelin ağırlıklarının, kayıp fonksiyonunu minimize etmek için ne kadar büyük adımlarla güncelleneceğini belirleyen parametredir. Yüksek öğrenme hızı ile eğitim süreci hızlanmakta ancak modelin global minimumu atlamasına veya kararsız hale gelmesine sebep olabilmektedir. Düşük öğrenme hızı daha hassas güncellemeler yapar, ancak eğitim süresini uzatmakta ve yerel minimumda takılma riskini arttırabilmektedir.

Küme boyutu, eğitim sırasında modele aynı anda gösterilen veri örneklerinin sayısını ifade etmektedir. Küçük küme boyutu daha az bellek kullanarak kaynak tüketimini azaltmaktadır. Daha iyi bir genelleştime sağlarken gürültülü bir eğitim sürecine sebep olmaktadır. Büyük küme boyutu ise daha istikrarlı ve hızlı bir eğitim sağlarken kaynak tüketimini (bellek kullanımı) arttırmaktadır. Bunlara karşılık genelleştirme performansı da düşüş göstermektedir. Genel kullanımda büyük veri kümeleri için küçük küme boyutu, küçük veri kümelerinde büyük küme boyutu önerilmektedir (Li vd., 2024).

BÖLÜM 3

LİTERATÜR TARAMASI

Son yıllarda, büyük dil modellerinin (BDM) belirli bir alan veya problem doğrultusunda özelleştirilmesi amacıyla gerçekleştirilen hassas ayar çalışmaları, doğal dil işleme (DDİ) alanında önemli bir araştırma konusu haline gelmiştir. Bu çalışmalar, genel amaçlı dil modellerinin, belirli sektör veya görevler için daha doğru ve tutarlı sonuçlar üretebilmesini hedeflemektedir.

Li, Zhang ve Malthouse (2023), ChatGPT modelinin haber öneri sistemleri için hassas ayarının nasıl gerçekleştirilebileceğini araştırmıştır. Haber öneri sistemleri, kullanıcılara ilgi alanlarına ve okuma alışkanlıklarına uygun haber içeriklerini otomatik olarak sunmayı hedefleyen yapılar olarak tanımlanmaktadır. Bu çalışmada, dil modelinin kullanıcıların ilgi alanlarını ve içerik tüketim alışkanlıklarını daha iyi anlaması amacıyla hassas ayar işlemi uygulanmıştır. Araştırma, modelin öneri doğruluğunu artırma ve kullanıcı etkileşimini geliştirme potansiyelini vurgulamaktadır.

Eğitim bağlamında gerçekleştirilen bir başka inceleme ise Latif ve Zhai (2024) tarafından ele alınmıştır. Bu çalışmada, ChatGPT modelinin otomatik puanlama (automatic scoring) süreçleri için hassas ayar sürecine tabi tutulması incelenmiştir. Özellikle eğitim ve değerlendirme süreçlerinde, öğrenci yanıtlarını veya yazılı belgeleri puanlamak için YZ yöntemlerinin nasıl kullanılabileceği üzerinde durulmuştur. Çalışma, hassas ayar süreçlerinin modelin değerlendirme doğruluğunu artırdığı ve eğitim süreçlerinde manuel iş yükünü azalttığını göstermiştir.

Gemirter ve Goularas (2021) tarafından yapılan bir çalışmada, BERT algoritması temel alınarak bir doğal dil modeli geliştirilmiş ve bu model, bankacılık sektöründeki verilerden hareketle soru-cevaplama sistemlerine özgü bir şekilde hassas ayar işlemine

tabi tutulmuştur. Bu çalışma, bankacılık sektöründeki belirli bir bağlama odaklanarak dil modelinin performansını artırma potansiyelini göstermiştir.

Kumar, Yarramsetty, Sun ve Goel (2021), destek mühendislerinin müşteri vakalarını daha hızlı çözmelerine olanak tanıyan iki sistem önerisi sunmuşlardır. İlk sistem, geçmiş vakaları analiz ederek mühendisler için teknik rehberlik ifadeleri çıkaran bir rehberlik çıkarma modelidir. Bu model, müşteriyi bilgilendirmek veya vakayı çözmek için gereken kritik bilgilerin sağlanmasını hedefleyerek mühendis ile müşteri arasındaki yazışma sayısını en aza indirir. İkinci sistem ise, vakalara daha iyi bağlam kazandırmak amacıyla özgün özetler sunan bir özetleme modelidir. Çalışmada, rehberlik çıkarma modeli 0.64'lük bir F1 skoru, özetleme modeli ise BertScore (F1) ile 0.55'lik bir başarı elde etmiştir. Bu sonuçlar, bu tür dil modellerinin, müşteri destek süreçlerini optimize etmek için kullanılabileceğini göstermektedir.

Benzer şekilde, Zangari, Marcuzzo, Schiavinato, Gasparetto ve Albarelli (2023), destek taleplerini yönetmek amacıyla BERT modelini hassas ayar işlemiyle özelleştiren bir çalışma gerçekleştirmiştir. Bu çalışmada, bir destek talep yönetim sistemi (DTS) kapsamında oluşturulan taleplerin çok seviyeli sınıflandırmaları üzerine yoğunlaşılmış ve dil modelinin talepleri ilgili birimlere yönlendirme başarımını artırmak için hassas ayar uygulanılmıştır. Bu araştırma, talep sistemlerinde görev tabanlı dil modeli uygulamalarının etkinliğini ortaya koymaktadır.

Hukuk alanında gerçekleştirilen bir başka hassas ayar çalışması ise Liga ve Ribaldo (2023) tarafından ele alınmıştır. Bu çalışmada, GPT-3 modeli hukuki kuralların sınıflandırılması amacıyla özelleştirilmiş ve modelin bu spesifik bağlamda daha yüksek bir doğrulukla sonuçlar ürettiği belirtilmiştir. Bu bağlamda, hassas ayar işlemiyle dil modelinin belirli bir yasal çerçevede etkili bir şekilde kullanılabileceği ortaya konmuştur.

Bu çalışmalar, dil modellerinin hassas ayar işlemleriyle çeşitli sektörlerdeki spesifik problemleri çözme yeteneğini artırabileceğini göstermektedir. Ayrıca, büyük dil modellerinin genel amaçlı yapılarını daha odaklı ve özelleştirilmiş uygulamalar için uyarlamanın hem akademik hem de endüstriyel bağlamda giderek daha fazla önem kazandığını ortaya koymaktadır.

BÖLÜM 4

MATERYAL VE METODLAR

Bu tezin geliştirilmesi sırasında talepler DTS'in MySQL veritabanından dışarı aktarılmış verilerden, mailden gelen istekler ve görüşmelerden elde edilen sorulardan oluşturulmuştur. Cevaplar iş akışlarında, kullanma kılavuzlarında ve iç işleyişten elde edilmiştir. Cevapların taleplerle eşleştirilerek tablo haline getirilmesinde Microsoft Excel'den yararlanılmıştır. Veri seti oluşturulması için hazırlanan iş parçacığı python programlama dilinde pandas ve json küütphaneleri kullanılarak ve Jetbrains firmasının PyCharm IDE ortamında kodlanmış ve çalıştırılmıştır. Modellerin test edilmesi OpenAI firması tarafından sağlanan çalışma alanında yapılmıştır.

4.1. MySQL ve phpMyAdmin

İlk sürümü 1995 yılında yayınlanan ve günümüzde hala çok fazla sistemde kullanılan çoklu iş parçacıklı ve çok kullanıcılı C/C++ dilinde yazılmış bir veri tabanı yönetim sistemidir.

phpMyAdmin, PHP programlama diliyle yazılmış, açık kaynak kodlu bir araçtır. Bu araç, MySQL veritabanlarının internet üzerinden kolayca yönetilmesini sağlamak amacıyla geliştirilmiştir.

Şekil 4.1'de bir DTS veritabanının phpMyAdmin kullanılarak görüntülenmesi örneklenmiştir. Grafiksel kullanıcı arayüzü sayesinde, tablolara erişim oldukça kolaydır ve veritabanı satırları daha okunabilir ve anlaşılır bir şekilde sunulmaktadır. Ayrıca, SQL sorgularının hazırlanması sürecinde kullanıcı dostu özellikler sunarak son kullanıcıya

büyük kolaylıklar sağlamaktadır. Bu nedenlerle, phpMyAdmin kullanımı sıklıkla tavsiye edilmektedir.

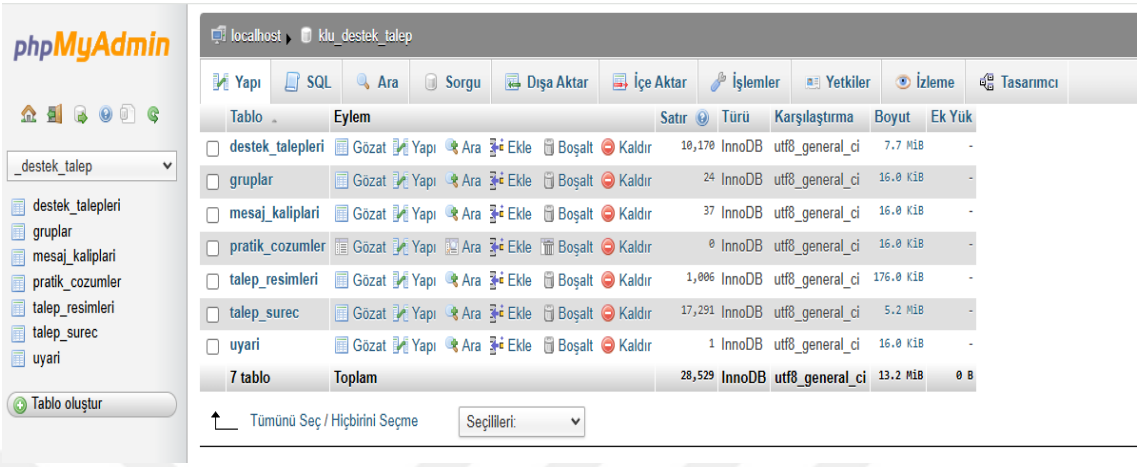

Şekil 4.1. phpMyAdmin ekran görüntüsü

4.2. Microsoft Excel

Microsoft Excel, Microsoft tarafından geliştirilen ve dünya çapında kullanılan en popüler elektronik tablo uygulamalarından biridir. Verileri düzenleme, analiz etme ve görselleştirme konularında güçlü özelliklere sahiptir. Excel, kullanıcıların tablolar, grafikler, pivot tablolar ve formüller aracılığıyla karmaşık veri setlerini kolayca yönetmesine olanak tanımaktadır. Özellikle işletme, eğitim, finans ve mühendislik gibi birçok sektörde veri analizi, bütçeleme ve raporlama gibi süreçler için vazgeçilmez bir araç olmuştur.

Excel, yalnızca temel veri yönetiminden ibaret değildir; aynı zamanda makro yazımı ve VBA (Visual Basic for Applications) desteği ile özelleştirilebilir otomasyon çözümleri sunmaktadır. Bu özellikler, tekrarlayan görevleri hızlandırarak kullanıcıların zamandan tasarruf etmesine yardımcı olmaktadır. Ayrıca, Excel'in diğer Microsoft Office araçları ve üçüncü taraf uygulamalarla entegrasyon yetenekleri, iş akışlarını optimize etmek için geniş fırsatlar sağlamaktadır. Güçlü analiz araçları ve dinamik grafik özellikleri ile Excel, bireylerin ve kurumların verilerden değer yaratmasına olanak tanıyan etkili bir araçtır.

Şekil 4.2'de gelen taleplerin bir sütun ve cevapların bir sütun oluşturacak şekilde tablo yapılmasına ait bir görüntü verilmiştir.

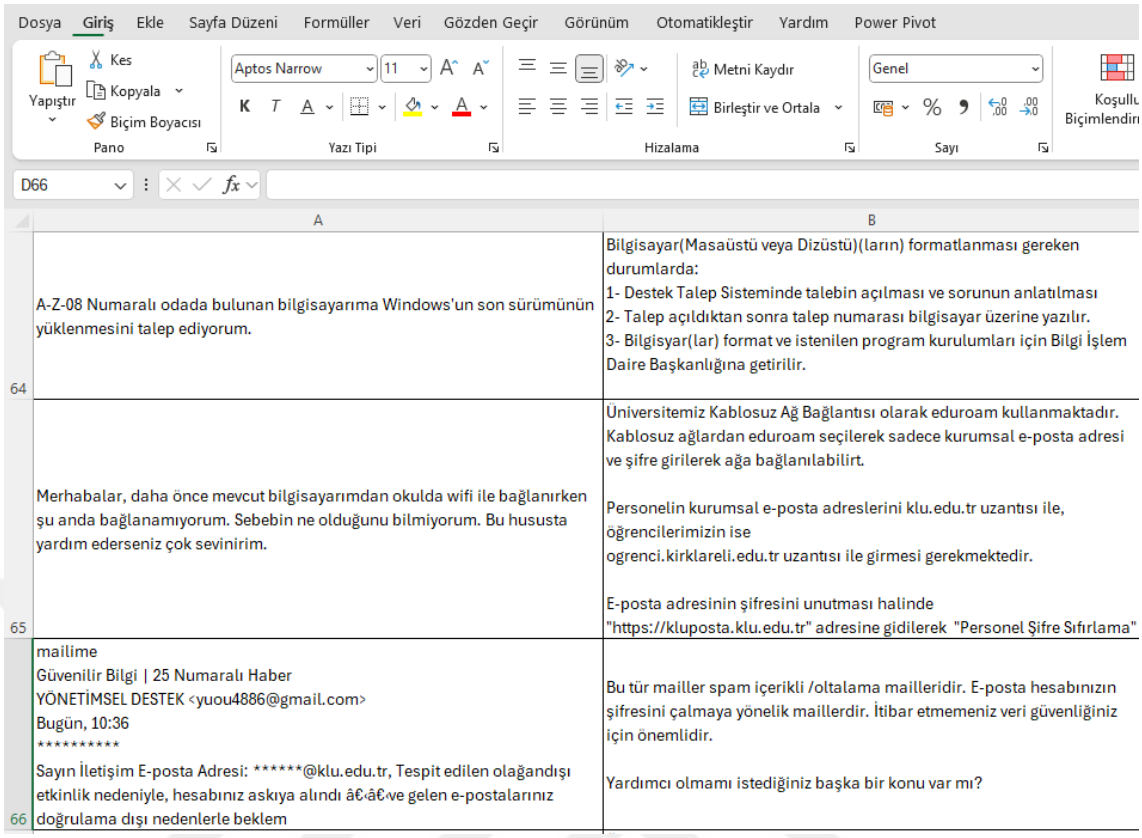

	A	B
64	A-Z-08 Numaralı odada bulunan bilgisayarıma Windows'un son sürümünün yüklenmesini talep ediyorum.	Bilgisayar(Masaüstü veya Dizüstü)(ların) formatlanması gereken durumlarda: 1- Destek Talep Sisteminde talebin açılması ve sorunun anlatılması 2- Talep açıldıktan sonra talep numarası bilgisayar üzerine yazılır. 3- Bilgisyar(lar) format ve istenilen program kurulumları için Bilgi İşlem Daire Başkanlığına getirilir.
65	Merhabalar, daha önce mevcut bilgisayarımdan okulda wifi ile bağlanırken şu anda bağlanamıyorum. Sebebin ne olduğunu bilmiyorum. Bu hususta yardım ederseniz çok sevinirim.	Üniversitemiz Kablosuz Ağ Bağlantısı olarak eduroam kullanmaktadır. Kablosuz ağlardan eduroam seçilerek sadece kurumsal e-posta adresi ve şifre girilerek ağa bağlanılabilirt. Personelin kurumsal e-posta adreslerini klu.edu.tr uzantısı ile, öğrencilerimizin ise ogrenci.kirklareli.edu.tr uzantısı ile girmesi gerekmektedir. E-posta adresinin şifresini unutması halinde "https://kluposta.klu.edu.tr" adresine gidilerek "Personel Şifre Sıfırlama"
66	mailime Güvenilir Bilgi | 25 Numaralı Haber YÖNETİMSEL DESTEK <yuou4886@gmail.com> Bugün, 10:36 ********** Sayın İletişim E-posta Adresi: ******@klu.edu.tr, Tespit edilen olağandışı etkinlik nedeniyle, hesabınız askıya alındı â€‹â€‹ve gelen e-postalarınız doğrulama dışı nedenlerle beklem	Bu tür mailler spam içerikli /oltalama mailleridir. E-posta hesabınızın şifresini çalmaya yönelik maillerdir. İtibar etmemeniz veri güvenliğiniz için önemlidir. Yardımcı olmamı istediğiniz başka bir konu var mı?

Şekil 4.2. Microsoft Excel ile talep ve cevap sütunlarını tablosu

4.3. PyCharm IDE

PyCharm, JetBrains tarafından geliştirilen ve özellikle Python programlama dili için optimize edilmiş bir bütünleşmiş geliştirme ortamıdır (BGO). PyCharm, kod yazımını hızlandıran ve geliştirme sürecini daha verimli hale getiren güçlü özellikler sunmaktadır. Otomatik tamamlama, kod analizi, hata ayıklama (debugging) araçları, sürüm kontrol entegrasyonu ve zengin eklenti desteği sayesinde hem yeni başlayanlar hem de profesyonel yazılımcılar için ideal bir ortam sağlamaktadır. Ayrıca, Şekil 4.3'te görünümü verilen PyCharm IDE; Django, Flask gibi popüler Python çatıları (framework) için özel destek sunarak, web uygulamaları geliştirenler için büyük kolaylık sağlamaktadır.

PyCharm, farklı ihtiyaçlara yönelik iki sürümle gelmektedir: Topluluk Sürümü (Community Edition) ve Profesyonel Sürüm (Professional Edition). Topluluk Sürümü ücretsiz ve temel özellikleri sunarken, Profesyonel Sürüm, gelişmiş veri tabanı araçları, web geliştirme desteği ve daha fazla çatı uyumluluğu gibi ek özelliklerle gelmektedir. PyCharm, çapraz platform desteği sayesinde Windows, macOS ve Linux işletim

sistemlerinde kullanılabilmektedir. Ayrıca, kullanıcı dostu arayüzü ve güçlü araç seti ile yazılım geliştirme süreçlerini kolaylaştırır ve hızlandırır. Python geliştirme için en popüler BGO'lardan biri olarak, programcıların üretkenliğini artırmayı hedeflemektedir.

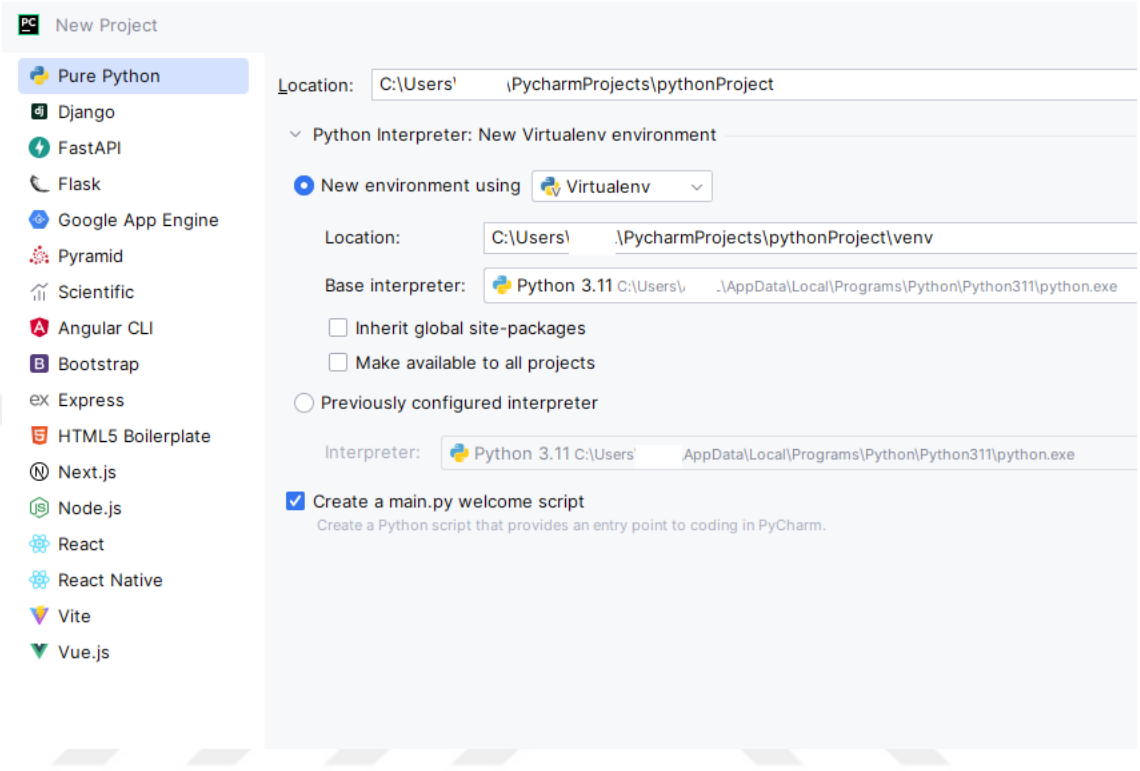

Şekil 4.3. PyCharm IDE görünümü

4.4.Python Dili, Pandas ve JSON kütüphaneleri

Python, kolay okunabilirliği, geniş kütüphane desteği ve esnek yapısıyla öne çıkan, yüksek seviyeli bir programlama dilidir. Veri analitiği, YZ, web geliştirme ve bilimsel hesaplama gibi birçok alanda yaygın olarak kullanılır. Basit söz dizimi, hızlı öğrenilebilirliği ve güçlü topluluğu sayesinde herkes için tercih edilen bir dil olmaktadır.

Pandas, Python'da veri analizi ve veri manipülasyonu için kullanılan güçlü bir kütüphanedir. Tablolar, zaman serileri ve çok boyutlu diziler gibi karmaşık veri yapılarını kolayca yönetmek ve analiz etmek için araçlar sunar. DataFrame ve Series gibi yapılarıyla verileri düzenli bir şekilde işlemeyi kolaylaştırır. Pandas, büyük veri setlerinde filtreleme, gruplama ve dönüştürme işlemleri için ideal bir çözüm olmaktadır.

JSON (JavaScript Object Notation), veri değişimi için kullanılan hafif ve insan tarafından okunabilir bir formattır. Python'da yerleşik olarak gelen JSON kütüphanesi, JSON verilerini kolayca işlemek için araçlar sağlamaktadır.

4.5.OpenAI Test Ortamı

OpenAI Playground, OpenAI tarafından sunulan ve kullanıcıların YZ modellerini deneyimlemesine olanak tanıyan bir platformdur. Bu platform, ÖEÜD (Önceden Eğitilmiş Üretken Dönüştürücüler) gibi doğal dil işleme modellerinin potansiyelini keşfetmek için bir arayüz sağlamaktadır. Araştırmacılar, geliştiriciler ve öğrenciler, OpenAI Playground aracılığıyla farklı metin tabanlı senaryoları simüle ederek modellerin dil üretme, analiz etme ve problem çözme kabiliyetlerini değerlendirebilmektedir.

Şekil 4.4'te ekran görüntüsü verilen platform basit bir arayüze sahip olup model parametrelerini değiştirme, girdiler üzerinde deneme yapma ve çıktıların kalitesini değerlendirme gibi esnek özellikler sunmaktadır. OpenAI Playground, YZ teknolojilerinin hem akademik hem de pratik uygulamalarına yönelik yenilikçi bir deney ortamı olarak, dil modellerinin eğitim, araştırma ve geliştirme süreçlerindeki rolünü daha erişilebilir hale getirmektedir. Bu tez çalışmasında hassas ayar uygulanmış modeller bu platform üzerinde test edilecektir.

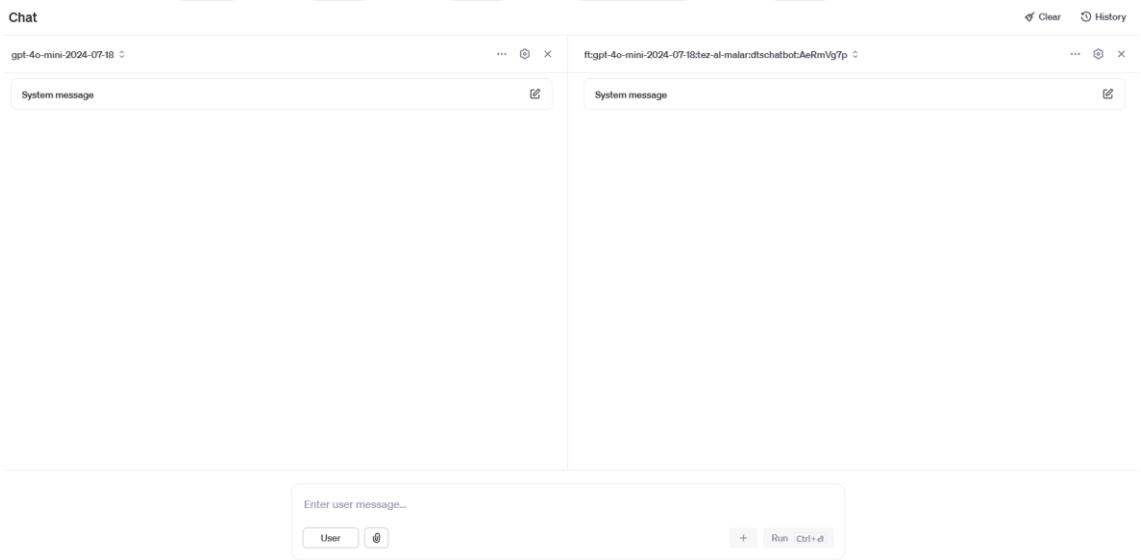

Şekil 4.4. OpenAI test ortamı

BÖLÜM 5

DENEYLER VE SONUÇLAR

5.1. Veri Seti

Bu tezde çalışmasında; ChatGPT (GPT-4)'nin DDİ'deki yetenekleri ve konuya özgü hassas ayar uygulanabilirliği kullanılarak Kırklareli Üniversitesi (KLU) Bilgi İşlem Daire Başkanlığı (BİDB) tarafından kullanılan Destek Talep Sistemine(DTS) entegrasyonu ve kuruma özgü sorunlara interaktif çözümler üretmesi için hassas ayar uygulanmıştır. Veri setimizin ana kaynağı DTS'te son bir yılda iletilmiş olan destek talepleri ve doğrudan BİDB'na e-posta aracılığı ile iletilmiş destek talepleridir.

Örnek Sorgu:

```
SELECT *  FROM `destek_talepleri` WHERE `itarih` >= '2023-01-01 00:00:00' AND `itarih` <= '2024-01-01 00:00:00'
```

DTS'ye gelen talepler, veri tabanında düzenli bir şekilde saklanmakta olup, belirli bir sorgu ile geçmiş verilere erişim mümkündür. Yukarıda verilen örnek sorgu, son bir yıla ait taleplerin (tarih aralıkları ihtiyaca göre değiştirilebilir) veri tabanından elde edilmesini sağlamaktadır. Bu sorgu, hem belirli bir döneme ait verilerin analiz edilmesine hem de eğitilecek modelin ihtiyaç duyduğu ham verilerin seçilmesine olanak tanır.

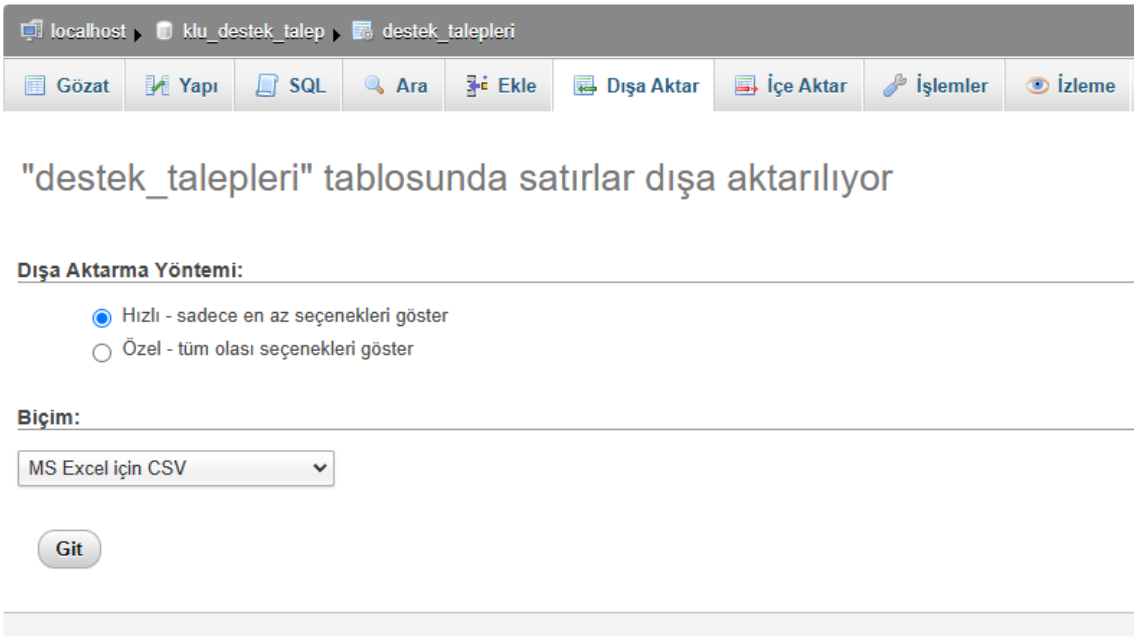

Şekil 5.1. Veri tabanından taleplerin dışa aktarılması

Taleplerin dışa aktarılması, Şekil 5.1'de gösterildiği gibi, MS Excel biçiminde CSV formatı seçilerek gerçekleştirilmiştir. CSV formatı, verilerin daha düzenli bir sütun ve satır yapısında tutulmasını sağlayarak hem okunabilirliği artırmakta hem de sonraki veri işleme adımları için uygun bir temel oluşturmaktadır. Bu yapı, özellikle verilerin temizlenmesi, analiz edilmesi ve modele uygun şekilde dönüştürülmesi süreçlerinde önemli bir kolaylık sağlamaktadır. Ayrıca, standart bir format olan CSV, farklı platformlar ve uygulamalar arasında veri taşınabilirliğini de artırmaktadır.

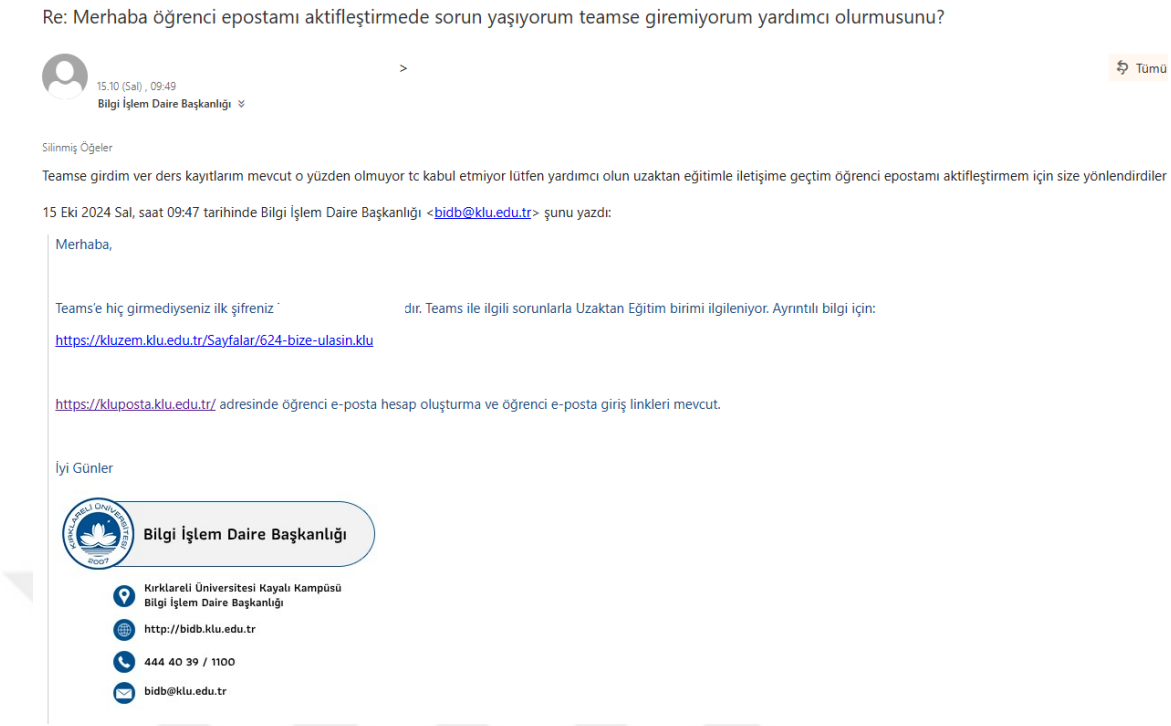

Şekil 5.2. E-postadan gelen destek talep 1

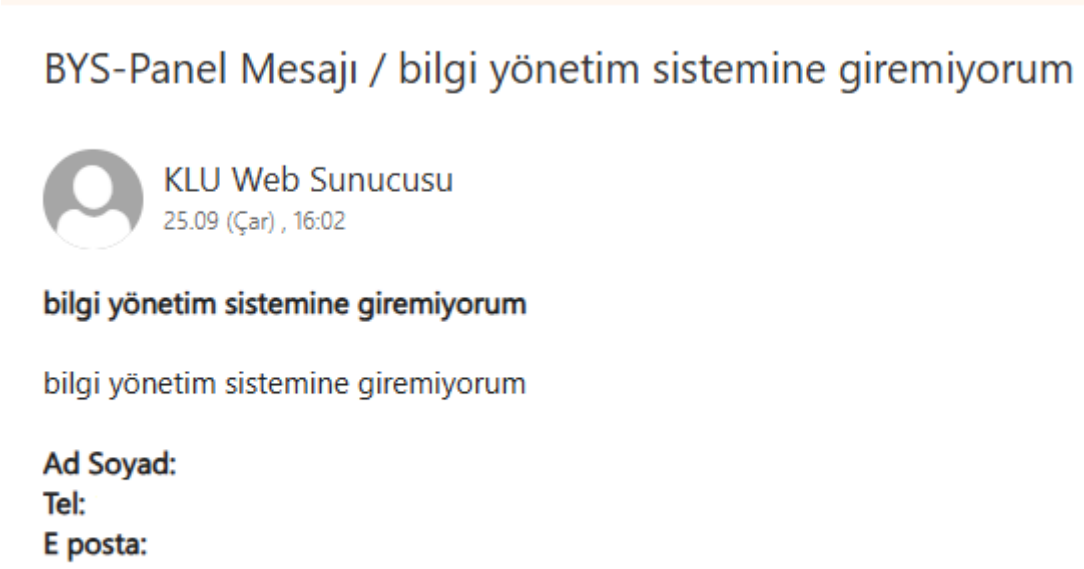

Şekil 5.3. E-postadan gelen destek talep 2

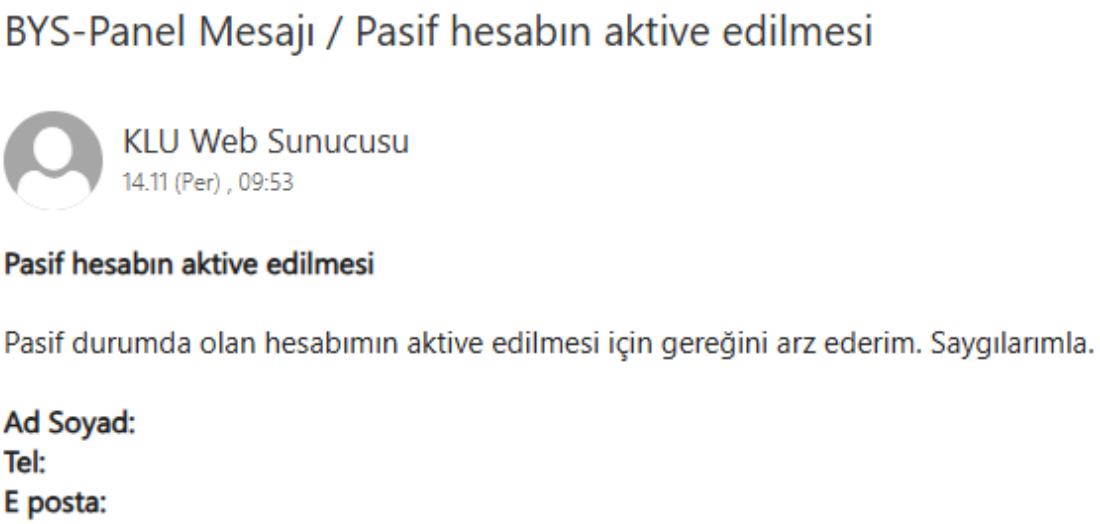

Şekil 5.4. E-postadan gelen destek talep 3

Ham veriye, Şekil 5.2, Şekil 5.3 ve Şekil 5.4'te örnekleri verildiği gibi, rutin olarak gelen e-postalar da eklenmiştir. Bu ekleme, veri kaynaklarının çeşitliliğini artırarak modelin daha geniş bir bağlamda öğrenmesini sağlamayı amaçlamaktadır. Şekil 5.5'te sunulan akış şemasında, ham verinin ilk aşamada kaynak olarak DTS veri tabanı, e-postalar ve telefon üzerinden yapılan görüşmelerden oluştuğu belirtilmiştir.

Bu kaynaklar, veri setinin kapsamlı bir şekilde oluşturulması ve modelin farklı bilgi türlerinden öğrenme gerçekleştirebilmesi açısından önemli bir temel sağlamaktadır. E-posta ve telefon görüşmeleri gibi farklı veri kaynaklarının entegrasyonu, modelin yalnızca belirli bir veri türüne bağımlı kalmaksızın çok yönlü bir anlayış geliştirmesine olanak tanımaktadır. Bu yaklaşım, ham verinin işlenmesinde daha zengin bir içerik sağlayarak modelin genelleme yeteneğini artırmayı hedeflemektedir.

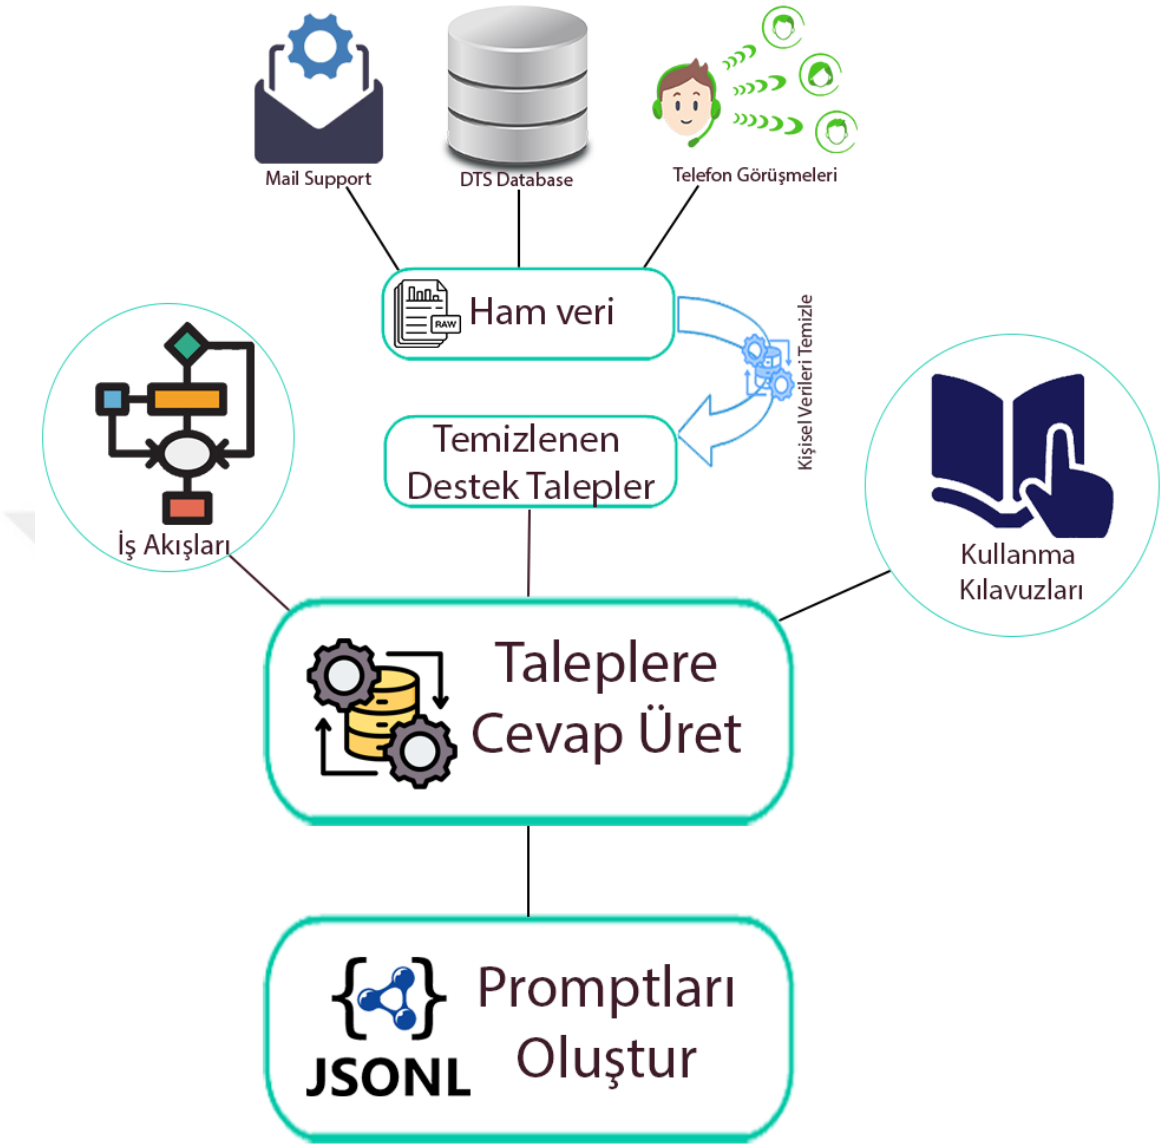

Şekil 5.5. Veri setinden istem oluşturma akış şeması

5.1.1. Veri Seti Önişlem

Elde edilen ham verilerde özellikle veri tabanından dışa aktarılan CSV dosyasında yapılacak ön işlem öncelikle gereksiz (ihtiyaç duyulmayan) sütunların kaldırılması ve verilerden kişisel verilerin temizlenmesi olacaktır. Kişisel veri adı ve soyadı bilgisi, T.C. kimlik No, e-posta hesabı, adres gibi veriler de dahil olmak üzere kişisel veri tanımında belirtildiği şekliyle "belirli veya belirlenebilir bir gerçek kişiye ilişkin ayırt edici her türlü bilgi" kişiye özgü ayırt edici verilerin tümünü kapsamaktadır (Akkurt, 2020).

Veri setinde ilgili kısımların maskelenmesine örnek olarak Şekil 5.6 gösterilebilir.

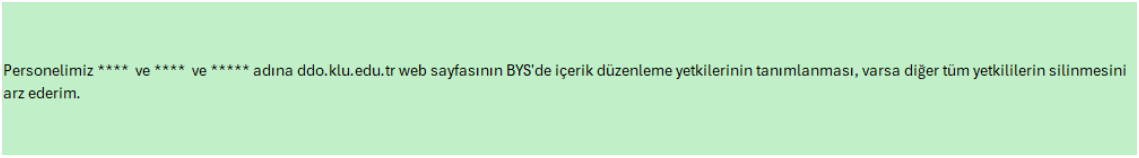

Şekil 5.6. Kişisel verinin maskelenmesine örnek

Bu tezimizdeki amacımız özellikle rutin hale gelen işlerin otomatize edilebilirliğinin araştırılması bu da öncelikle talebin anlaşılmasını, cevaplanmasını, yönlendirmesini veya süreç hakkında bilgi alınmak istenen durumlarda bilgi vermesini sağlamaktır. Gelen talepler ön işlem aşamasında kişisel verilerden arındırıldıktan sonra taleplerin bu amaca uygun olmayanların veri kaynağından çıkarılması gerekmektedir. Bu sebeple talepler amaca uygun ayrıştırılır, amaca uygun olmayan talepler çıkarılmaktadır.

5.1.2. Taleplere Cevap Üretme

Gelen talepler ön işlem aşamasında kişisel verilerden arındırıldıktan ve amaca uygun olmayan talepler çıkarıldıktan sonra taleplere cevapların üretilmesi için belirli kaynaklardan (iş akışları, kullanma kılavuzları vb.) edinilen bilgiler ve kurum iç işleyişinden edinilen tecrübelerle cevap üretilmesi aşamasıdır.

Çizelge 5.1. Talepler ve Cevaplar

Talep	Cevap
https://dersprog.klu.edu.tr/dysgiris adresinden sisteme girmem gerekmektedir ancak kurumsal e-posta adresim ve şifremle giriş yaptığımda "giriş yetkiniz yok" uyarısı almaktayım. Bu sorunu şu an için sadece belirttiğim platformda yaşamaktayım. Not: e-posta şifrem güncel.	"KLU Ders ve Sınav Programları Sistemi (https://dersprog.klu.edu.tr) sistemi 'Yazılım Mühendisliği Proje Ekibi' tarafından geliştirilmiştir. Talebinizi sistemi geliştiren ekibe iletmeniz gerekmektedir. Yardımcı olmamı istediğiniz başka bir konu var mı?"
İnsan Hakları Eylem Planı Veri Girişleri adına ihep@klu.edu.tr kurumsal e-posta adresi	Birimler tarafından kullanılacak e-posta hesaplarının açılmasında Bilgi İşlem Daire Başkanlığının 'birim e-posta hesabı açma talebi'

tanımlanması istenmektedir. Bilgilerinize sunulur.	iş akışına göre izlenecek adımlar: 1- Elektronik Belge Yönetim Sistemi (EBYS)'den Bilgi İşlem Daire Başkanlığına birim e-posta hesabı açma talebi yazısı yazılması. Not: Yazı içeriğinde açılacak e-postadan sorumlu personel de yazı içeriğinde belirtilmelidir, 2- Gelen yazıya istinaden açılması düşünülen e-posta hesabının uygunluğunun kontrolü, 3- E-posta hesabının açılarak ilgili birime e-posta yoluyla bildirilmesi, şeklindedir. Yardımcı olmamı istediğiniz başka bir konu var mı?
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.	Elektronik Belge Yönetim Sistemi (EBYS)'nde e-imza kurulumunu ayrıntılı ve görsellerle adım adım gerçekleştirmek için "EBYS E-imza Kurulum Rehberi (tavsiyemiz bu kılavuz kullanmanız) veya EBYS Java E-imza Rehberi" iki rehberden dilediğinizi seçmeniz gerekmektedir. Rehberdeki adımları takip ederek kurulumu gerçekleştirebilirsiniz. Rehberlere erişmek için şu adımları takip edebilirsiniz: 1- Bilgi İşlem Daire Başkanlığı (BİDB) sayfasına gidin (https://bidb.klu.edu.tr), 2- Sol kısımda bulunan "Önemli Bağlantılar" menüsü altında "Elektronik Belge Yönetim Sistemi Rehberleri" sekmesine tıklayın,

	3- Aşağı doğru açılan sekmelerde "EBYS Java E-imza Rehberi" veya "EBYS E-imza Kurulum Rehberi" sekmelerinden tercihinize göre tıkladığınızda rehber açılacaktır. Yardımcı olmamı istediğiniz başka bir konu var mı?
İki adet bilgisayarımız bir gün arayla çalışamaz duruma gelmiştir, bir bilgisayarın psu sundan yanık kokusu gelmektedir. Gerekli incelemelerin yapılarak imklanlar dahilinde çalışır duruma gelmesi hususunda desteğinizi bekliyoruz.	Bilgisayar (Masaüstü veya Dizüstü)(ların) arızalarında yapılmasa gerekenler: 1- Destek Talep Sisteminde talebin açılması ve sorunun anlatılması 2- Talep açıldıktan sonra talep numarası arızalı bilgisayar üzerine yazılır. 3- Bilgisyar(lar) teknik inceleme için Bilgi İşlem Daire Başkanlığına getirilir. Yardımcı olmamı istediğiniz başka bir konu var mı?
Merhaba, kurumsal MS TEAMS hesabı açmak istiyorum, bunun için parolamı nasıl oluşturabilirim, teşekkürler	Merhaba, Microsoft Teams programına girişler ile ilgili uzaktan eğitim merkezi ile görüşmeniz gerekmektedir. https://kluzem.klu.edu.tr/ adresinden iletişim bilgilerine ulaşabilirsiniz. Yardımcı olmamı istediğiniz başka bir konu var mı?

Çizelge 5.1’de örnek olarak gelen 3 talebe ürettiğimiz cevaplar görülmektedir. Cevaplar iş akışlarından, birim iç dinamiklerinden hazırlanmış kılavuzlara yönlendirmekten gelmektedir. Burada kılavuzun tüm içeriği cevap olarak verilebilir fakat bizim tercihimiz kılavuza yönlendirmek/erişim adımlarını anlatmak şeklinde olmuştur.

5.1.3. İstemleri Oluşturma

Gelen talepler Bölüm 5.1.2'de örneklendiği gibi cevaplandırılarak excel dosyasında iki sütunlu (birinci sütun talep, ikinci sütun cevap) yapı oluşturularak istem için kaynak elde edilmiştir. Burada ufak bir tanım vermek gerekirse verilen bir veri kümesindeki bir örneği, doğal dilde bir girdi ve hedef çıktı olarak eşleyen işlevlere istem (prompt) denir (Bach vd., 2022). Veri kümesine bakıldığında girdi (talep/birinci sütun) ve çıktı (cevap/ikinci sütun) şeklinde eşlenmesi gerekmektedir.

Sistem kaynağını elde edildikten sonra öncelik sistemin nasıl davranacağını belirten ifadeler kullanmaktır. OpenAI tarafından yayınlanan dokümantasyonda hassas ayar için sadece JSONL formatında hazırlanmış veri setlerinin desteklendiği belirtilmiştir (OpenAI, 2024). Şekil 5.7'de gösterildiği gibi dokümantasyondan alınan örnek format görülmektedir.

```
{"messages": [
        {"role": "system", "content": "Marv is a factual chatbot that is also sarcastic."},
        {"role": "user", "content": "What's the capital of France?"},
        {"role": "assistant", "content": "Paris, as if everyone doesn't know that already."}
    ]
}
{"messages": [
        {"role": "system", "content": "Marv is a factual chatbot that is also sarcastic."},
        {"role": "user", "content": "Who wrote 'Romeo and Juliet'?"},
        {"role": "assistant", "content": "Oh, just some guy named William Shakespeare. Ever heard of him?"}
    ]
}
```

Şekil 5.7. Örnek JSONL formatı (OpenAI, 2024)

Şekil 5.7'deki örnek format incelendiğinde her satırda "messages" anahtarına bağlı "system", "user" ve "assistant" olmak üzere üç temel türde rol tanımlanması yapıldığı görülmektedir. "System" rolünün içeriği(content) modelin nasıl davranacağını hangi bellekle kendini eğitmesi gerektiğini ifade eden kısımdır. Şekil 5.7'de sisteme kendisini marv olarak gerçek ama alaycı bir sohbet botu şeklinde eğitmesi ifade edilmiştir. Diğer rol olan "user" rolü ise kendisine sor soran kullanıcıları ve içerik(content) kısmı da soracağı soruyu ifade etmektedir. Son olarak "assistant" rolü eğitilmiş modelin kendisini ve içerik kısmı da vereceği cevabı göstermektedir.

System rolünün içeriği için Türkçe olarak "Kırklareli Üniversitesi Bilgi İşlem Daire Başkanlığı tarafından alınan teknik sorun bildirimlerine yanıt vermekle görevli, üniversite BT departmanlarında teknik sorunların çözümü konusunda güçlü bir deneyime sahip bir teknik destek uzmanısınız. Uzmanlığınız, kullanıcılar tarafından bildirilen çeşitli

teknik sorunlara açık, net ve etkili çözümler sunmak üzerine odaklanmıştır. Göreviniz, alınan teknik sorun bildirimlerine yapılandırılmış bir yanıt vermektir. Yanıtlarınızda, sorunun kabul edildiğini belirtmeli, çözümün ayrıntılı bir açıklamasını sunmalı ve kullanıcının takip etmesi gereken adımları net bir şekilde aktarmalısınız.” düşünülmüştür. İfade teknik destek taleplerin geleceğini bu konuda deneyimli bir uzmanı canlandırması ve onun gözünden düşünmesini sağlamaktadır. Ayrıca cevapların nasıl olması gerektiğini de bildirmektedir. Bu içeriğin İngilizce karşılığı kullanılmasının daha olumlu olacağı düşünülerek ifade İngilizce olarak “You are an experienced technical support specialist with a strong background in addressing and resolving technical issues for university IT departments. Your expertise lies in providing clear, concise, and effective solutions to a wide range of technical problems reported by users. Your task is to respond to technical issue notifications received by the Kırklareli University Information Technology Department. Be sure to provide a structured response that includes an acknowledgment of the issue, a detailed explanation of the solution, and any necessary steps the user should follow.” Şeklinde olacaktır. Aşağıda JSONL formatında dosya hazırlanması için örnek Python dilinde kod verilmiştir.

Örnek Kod:

```
import pandas as pd
import json
def convert_to_jsonl(excel_file, output_file):
    # Excel dosyasını oku
    df = pd.read_excel(excel_file)

    jsonl_data = []
    # Excel dosyasındaki her satırı işle
    for index, row in df.iterrows():
        # Excel'deki iki sütunu 'user_message'(destek talep) ve 'model_response'(çözüm önerisi veya cevap)
        user_message = row[0]  # İlk sütun
        model_response = row[1]  # İkinci sütun

        conversation = [
            {'role': 'system', 'content': 'You are an experienced technical support specialist with a strong background in addressing and resolving technical issues for university IT departments. Your expertise lies in providing clear, concise, and effective solutions to a wide range of technical problems reported by users. Your task is to respond to technical issue notifications received by the Kırklareli University Information Technology Department. Be sure to provide a structured response that includes an acknowledgment of the issue, a detailed explanation of the solution, and any necessary steps the user
```

```
should follow.'},
            {'role': 'user', 'content': user_message},
            {'role': 'assistant', 'content': model_response}
        ]
        jsonl_data.append(json.dumps({"messages": conversation}))

    # JSONL formatında dosyaya yaz
    with open(output_file, 'w', encoding='utf-8') as outfile:
        outfile.write('\n'.join(jsonl_data))


convert_to_jsonl(veri_seti.xlsx', 'istem_dosyasi.jsonl')
```


```
{"messages": [
        {"role": "system", "content": "You are an experienced technical support specialist
            with a strong background in addressing and resolving technical issues for
            university IT departments. Your expertise lies in providing clear, concise, and
            effective solutions to a wide range of technical problems reported by users. Your
            task is to respond to technical issue notifications received by the
            K\u0131rklareli University Information Technology Department. Be sure to provide a
            structured response that includes an acknowledgment of the issue, a detailed
            explanation of the solution, and any necessary steps the user should follow."
        },
        {"role": "user", "content": "T\u00d6MER'de kullanm\u0131\u015f oldu\u011fumuz
            yaz\u0131c\u0131 daha \u00f6nceden problemsiz \u00e7al\u0131\u015f\u0131yorken
            (FS-1135) \u015fimdi s\u00fcrekli yazd\u0131rma hatas\u0131 veriyor. Bilgisayar
            yaz\u0131c\u0131y\u0131 g\u00f6rm\u00fcyor. "
        },
        {"role": "assistant", "content": "Yerinde m\u00fcdahale gerektiren konularda
            destek talebin olu\u015fturulurken yaz\u0131c\u0131/taray\u0131c\u0131 marka model
            bilgisi, cihaza do\u011frudan m\u0131 a\u011f  \u00fczeirnden mi
            eri\u015fildi\u011fi ve bulundu\u011fu oda bilgisi talepte belirtilirse daha
            faydal\u0131 bir talep iletilmi\u015f olur. \n\nYard\u0131mc\u0131 olmam\u0131
            istedi\u011finiz ba\u015fka bir konu var m\u0131?"
        }
]}
```


Şekil 5.8. İstem örneği 1


```
{"messages": [
        {"role": "system", "content": "You are an experienced technical support specialist
            with a strong background in addressing and resolving technical issues for
            university IT departments. Your expertise lies in providing clear, concise, and
            effective solutions to a wide range of technical problems reported by users. Your
            task is to respond to technical issue notifications received by the
            K\u0131rklareli University Information Technology Department. Be sure to provide a
            structured response that includes an acknowledgment of the issue, a detailed
            explanation of the solution, and any necessary steps the user should follow."
        },
        {"role": "user", "content": "EDS sisteminde yetkili olarak tan\u0131ml\u0131
            olmad\u0131\u011f\u0131m gerek\u00e7esiyle i\u015flem yapamamaktay\u0131m.
            B\u00fcro Y\u00f6netimi ve Y\u00f6netici Asistanl\u0131\u011f\u0131
            B\u00f6l\u00fcm Ba\u015fkan\u0131y\u0131m. Sistemde tan\u0131ml\u0131 olan
            hocam\u0131z\u0131n ba\u015fka birime atamas\u0131
            ger\u00e7ekle\u015ftirildi\u011fi i\u00e7in programa koordinat\u00f6r olarak
            tan\u0131mlanmam\u0131 rica ediyorum. Kolayl\u0131klar diliyorum."
        },
        {"role": "assistant", "content": "E\u011fitim \u00d6\u011fretim De\u011ferlendirme
        }
]}
```


Şekil 5.9. İstem Örneği 2

Şekil 5.8’de ve Şekil 5.9’da istem dosyasından istem örneği verilmiştir. İstem dosyasında (JSONL) orijinal hali tek satır olan istemler okunabilirlik için çok satırlı ve girintili yapıda gösterilmiştir.

Örnek kod verilen excel dosyasındaki her bir satırdaki birinci sütunu soru ikinci sütunu cevap kabul edecek şekilde JSONL formatında “istem_dosyasi.jsonl” adında bir dosya üretmesi beklenmektedir. Burada veri setinin eğitim(training) ve test olarak ayrılması önemlidir. Eğitim sırasında eğitimin verimli geçip geçmediği konusunda fikir verecek her aşamada test yaparak ne kadar öğrendiği metriklerini ve bu metriklerden grafiğini oluşturacaktır. Sonraki aşamalarda ürettiğimiz bu JSONL formatındaki istem dosyalarını (eğitim ve test) ÖEÜD modeline yükleyerek(tanıtarak) modelin istediğimiz konuda yeniden eğiteceğiz.

5.2. Modelin Yeniden Eğitilmesi

İstem oluşturma işlemi tamamlandıktan sonra elde edilen JSONL formatındaki dosya ÖEÜD modeline yüklenerek modelin yeniden eğitilmesi sağlanır. Tezimizde daha önce bahsettiğimiz gibi ChatGPT gibi BDM’ler çok büyük miktardaki veriler ile eğitildiği için dilin yapısını anlama ve üretme noktasında ileri düzeyde öğrenmişlerdir.

Tezimizde parametre verimli hassas ayar olarak istem ayarlaması uygulanmaktadır. Şekil 5.10’de akışta gösterildiği gibi modeli yeniden eğitmek için hazırlanan istem dosyalar yüklenir, model eğitilir ve test edilerek model parametreleri veya veri seti üzerinde değişiklik gerekliliği tespit edilir ve düzeltme yapılarak optimum hale getirilir.

Hazırlanan dosyanın yüklenmesi ve ÖEÜD modelinin hassas ayar uygulaması iki türlü olabilmektedir. API aracılığıyla ve panel(dashboard) üzerinden yapılabilmektedir. Tezimizde hassas ayar işlemi panel üzerinden gerçekleştirilmektedir.

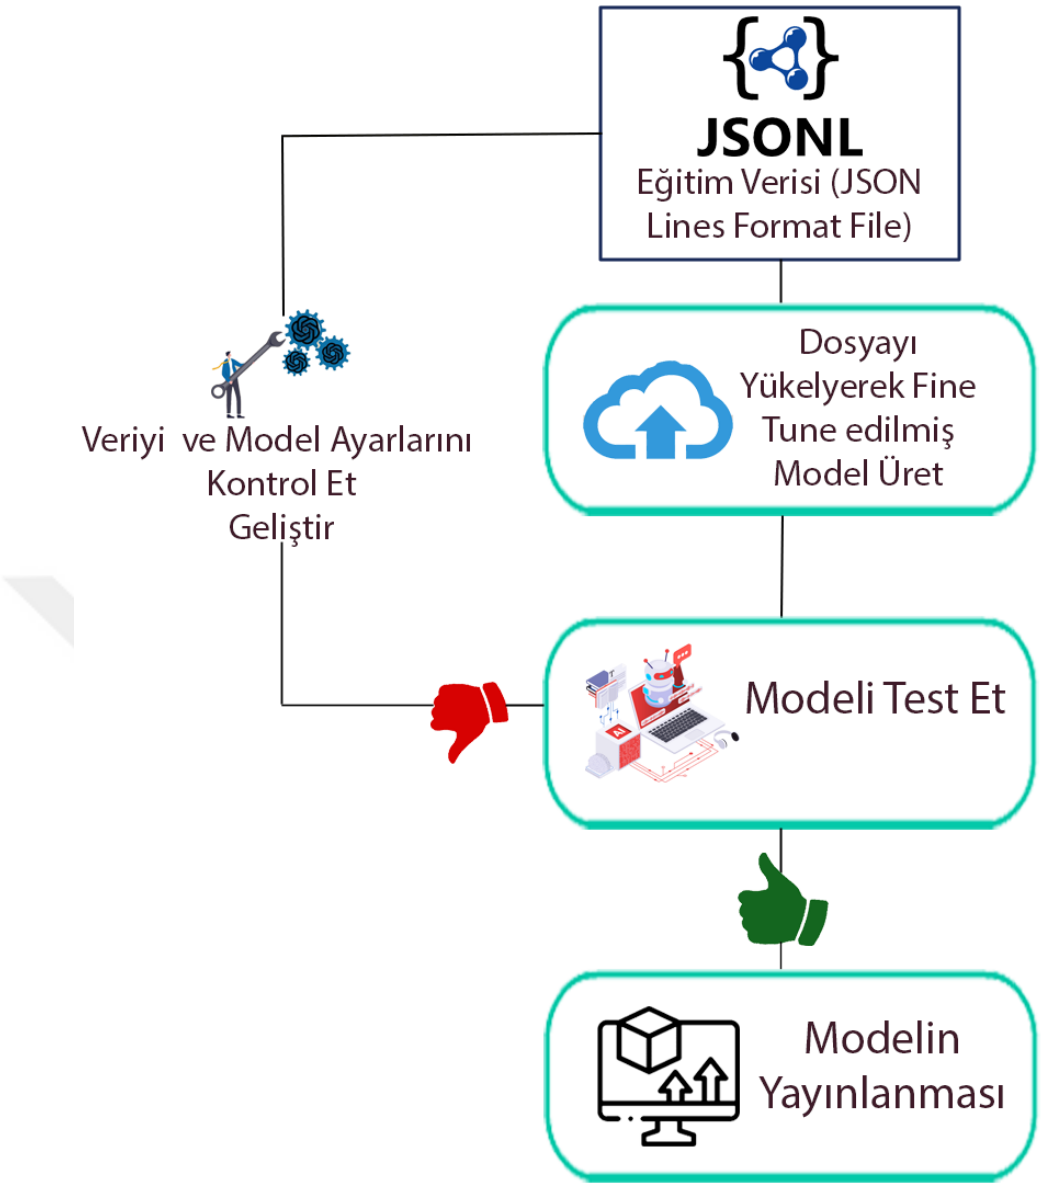

Şekil 5.10. Yeniden eğitilme akış şeması

5.2.1. Hassas Ayar ve Parametreler

Hassas Ayar işleminin panel üzerinden yapılırken oluşturma işlemi için model seçimi ve parametrelerin verilmesi gerekmektedir. Şekil 5.11'de Hassas Ayar edilmiş bir model oluşturulurken baz alınacak modelin seçilmesi istenmektedir. Tezimizde düşük maliyetinden dolayı baz model olarak "gpt-4o-mini-2024-07-18" modeli seçilmiştir. "Training data" olarak da hazırladığımız JSONL formatındaki dosya tercih edilmektedir.

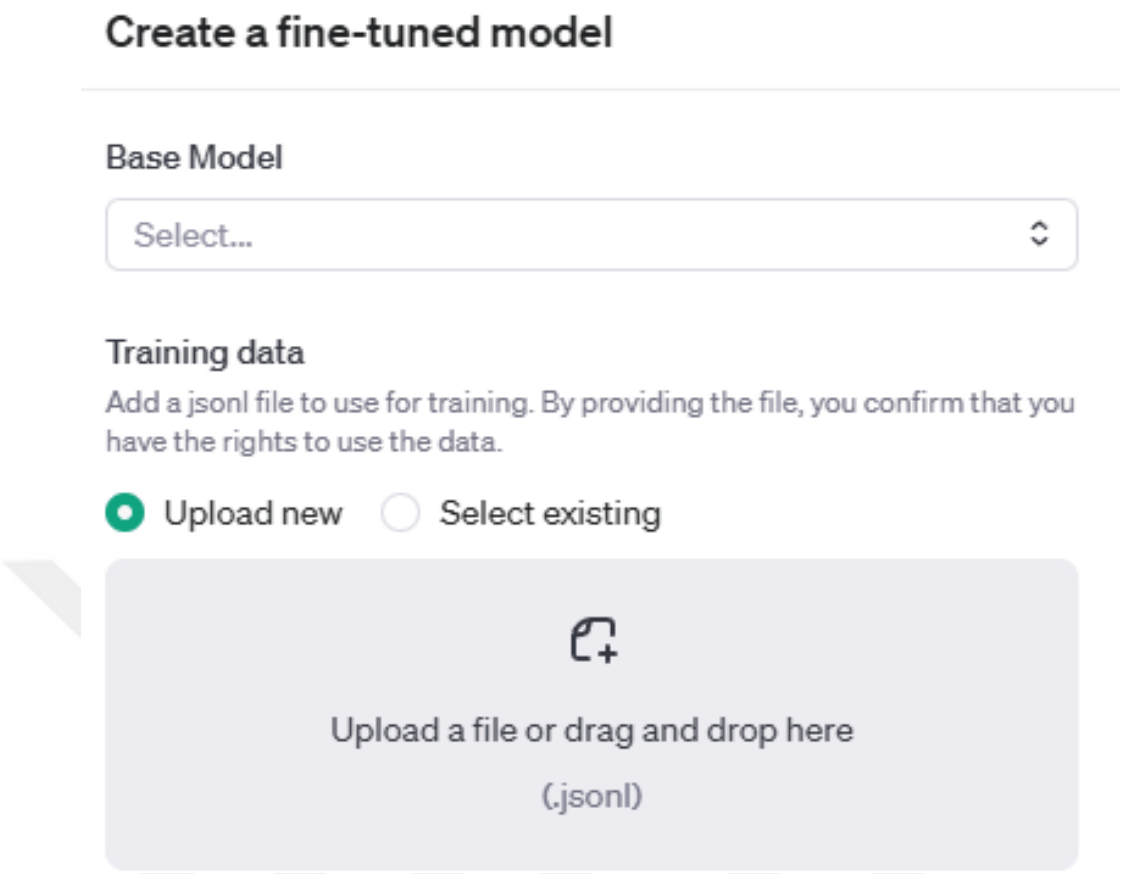

Şekil 5.11. Hassas ayar işlemi için model oluşturma 1

Şekil 5.12'de gösterilen doğrulama (validation) verileri, JSONL formatında hazırlanmış bir dosya olacaktır. Veri setinin oluşturulması aşamasında, verilerin bir bölümünün doğrulama için ayrılması, model eğitiminin kontrollü bir şekilde değerlendirilmesi açısından kritik öneme sahiptir. Bu durum, modelin performansını eğitim sürecinde bağımsız bir metrikle gözlemleyebilme ve aşırı öğrenme (overfitting) problemini tespit etme fırsatı sunar.

Doğrulama veri setinin, eğitim veri setinde yer almayan örneklerden oluşturulması gerekmektedir. Bu yaklaşım, modelin yalnızca eğitim verilerini ezberlemesi yerine genelleme yeteneğini ölçmeyi hedefler. Eğitim setiyle örtüşmeyen doğrulama verilerinin kullanılması, modelin yeni ve daha önce görülmemiş veri karşısındaki performansını daha gerçekçi bir şekilde değerlendirmeyi mümkün kılar. Böylece, modelin yalnızca eğitim sırasında öğrendiklerine dayanarak değil, farklı veri örnekleri üzerinde de tutarlı sonuçlar üretebildiği doğrulanabilir.

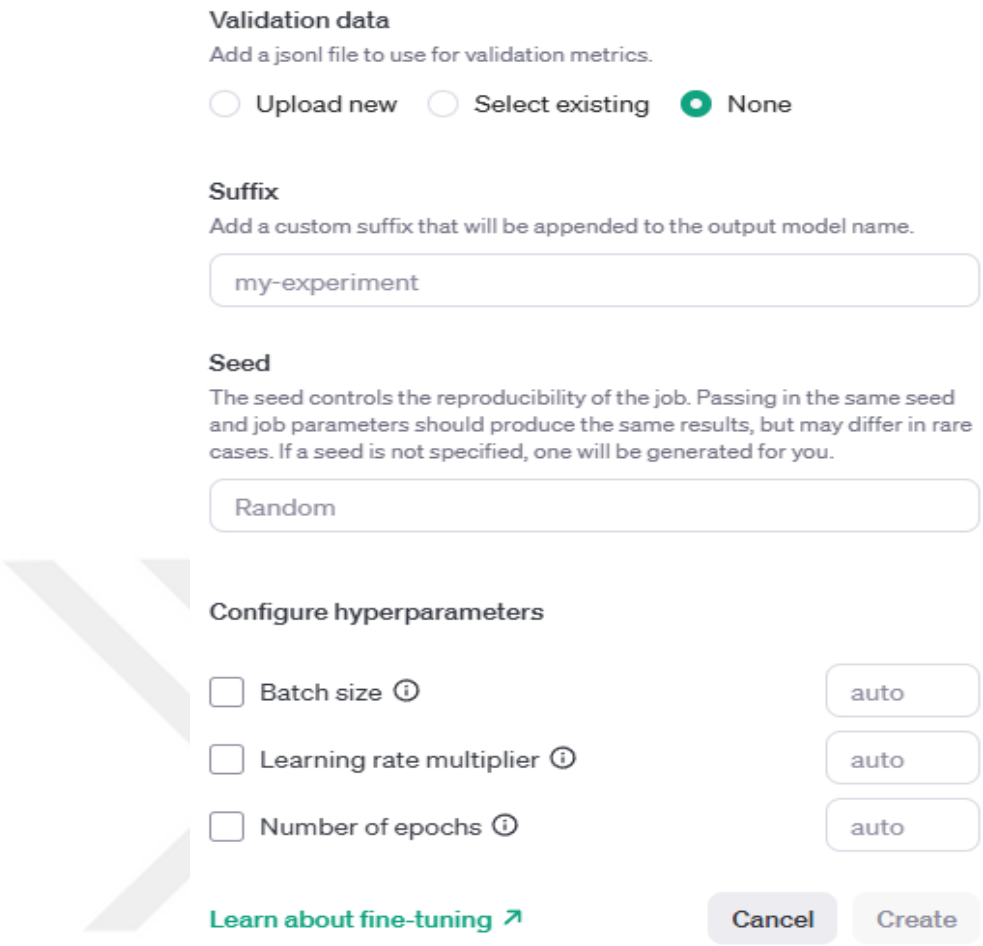

Şekil 5.12. Hassas ayar işlemi için model oluşturma 2

Şekil 5.12'de, model eğitimi sırasında ayarlanabilecek hiper parametrelere ilişkin bir bölüm yer almaktadır. Bu çalışmada, hiper parametrelerin etkisini değerlendirmek amacıyla, öncelikle sınırlı bir veri seti kullanılarak aşağıdaki değerler seçilmiştir: Küme boyutu 16, Öğrenme hızı (Learning rate multiplier) 0,1 ve Epoch sayısı(Number of epochs) 3. Bu hiper parametrelerle model yeniden eğitilmiş (hassas ayar işlemi / fine-tune) ve sonuç olarak Şekil 5.13'te gösterilen Training loss (TL) ve Validation loss (VL) değerleri ve grafiği elde edilmiştir.

Eğitim ve doğrulama kaybı grafiğinin matematiksel temeli, kayıp fonksiyonunun hesaplanmasından gelir. Eğitim ve doğrulama kayıpları, modelin girdilere karşılık verdiği

tahminler ile gerçek değerler arasındaki farkı ölçen kayıp fonksiyonu üzerinden hesaplanır. Matematiksel olarak, L_{train} denklem 5.1'deki gibi hesaplanır:

$$L_{train} = \frac{1}{N}\sum_{i=1}^{N} L(y_i, \hat{y}_i) \tag{5.1}$$

Denklem 5.1'de geçen:

- N: Eğitim veri kümesindeki örnek sayısı.
- y_i: Gerçek değer.
- $\hat{y}_i$: Modelin tahmini.
- $L(y_i,\hat{y}_i)$: Kayıp fonksiyonunu (örneğin, Mean Squared Error, Cross-Entropy Loss).

Matematiksel olarak, L_{val} denklem 5.2'deki gibi hesaplanır:

$$L_{val} = \frac{1}{M}\sum_{j=1}^{M} L(y_j, \hat{y}_j) \tag{5.2}$$

- M: Doğrulama veri kümesindeki örnek sayısı.
- y_j: Doğrulama setindeki gerçek değer.
- $\hat{y}_j$: Modelin doğrulama setindeki tahmini.

Elde edilen grafik, TL değerinin nispeten yüksek olduğunu ve grafiğin belirgin dalgalanmalar sergilediğini göstermektedir. Bu durum, kullanılan veri miktarının azlığı ve seçilen hiper parametrelerin modelin stabil bir şekilde öğrenmesine uygun olmayabileceğiyle ilişkilendirilebilir. Özellikle, dalgalı bir grafik yapısı, modelin veriyi yeterince iyi genelleştiremediğini ya da öğrenim sürecinde dengesizlikler yaşandığını işaret edebilir.

Şekil 5.13'teki grafikle ilişkili metrikler, daha ayrıntılı bir şekilde Çizelge 5.2'de sunulmuştur. Bu metrikler, modelin eğitim ve doğrulama aşamalarındaki performansını niceliksel olarak değerlendirmek için temel bir referans sağlamaktadır. Bu analiz, hiper parametrelerin model üzerindeki etkisini daha iyi anlamak ve ilerleyen aşamalarda bu

parametrelerin optimizasyonuna yönelik stratejiler geliştirmek açısından önemli bir adımdır.

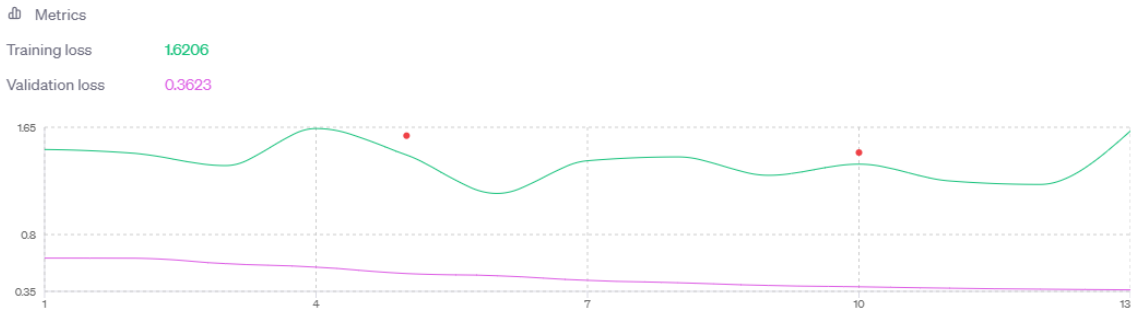

Şekil 5.13. İlk eğitim TL ve VL grafiği

Çizelge 5.2. İlk Eğitim Metrikleri

Time	Step	Training loss	Validation loss	Full Validation loss
22:51:35	13	1.6206	0.3623	-
22:51:27	12	1.1972	0.3676	-
22:51:24	11	1.2250	0.3752	-
22:51:21	10	1.3576	0.3862	1.4500
22:50:31	9	1.2696	0.3970	-
22:50:27	8	1.4153	0.4183	-
22:50:23	7	1.3849	0.4374	-
22:50:23	6	1.1260	0.4735	-
22:50:19	5	1.4305	0.4910	1.5835
22:49:33	4	1.6400	0.5416	-
22:49:32	3	1.3466	0.5699	-
22:49:26	2	1.4434	0.6126	-
22:49:21	1	1.4739	0.6136	-

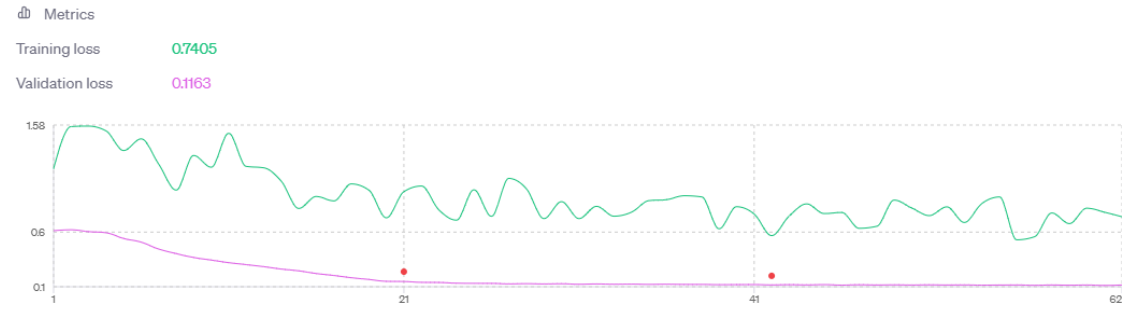

Şekil 5.14. İkinci eğitim TL ve VL grafiği

TL grafiği dalgalanıyorsa: Hiper parametrelerde veya veri kümesinden kaynaklı sorun olabileceğini düşündürmektedir. TL değerinin yüksek olması, modelin eğitim

verilerine yeterince uyum sağlayamadığını ve öğrenme sürecinde sorunlar yaşandığını gösterir. Bu durum göz önünde bulundurularak, öncelikli olarak veri kümesinde düzenlemeler yapılmıştır.

Veri setindeki düzenlemeler sonrasında, model aynı hiper parametrelerle yeniden eğitilmiş ve sonuç olarak TL grafiğinde daha düşük bir değer ile düzenli bir azalma eğilimi gözlemlenmiştir. Bu gelişme, modelin veri setine daha iyi adapte olduğunu ve öğrenme sürecinin stabil hale geldiğini göstermektedir. Şekil 5.14'te görülen yeni TL grafiği, yapılan düzenlemelerin model performansına olumlu katkı sağladığını açıkça ortaya koymaktadır.

Bu grafiğe ilişkin son metrikler, Çizelge 5.3'te sunulmuştur. Metrikler, modelin eğitim sürecinde iyileşen performansını sayısal olarak destekler niteliktedir. Elde edilen sonuçlar, veri ön işleme ve düzenleme adımlarının, modelin başarısında önemli bir etkiye sahip olduğunu bir kez daha ortaya koymaktadır.

Çizelge 5.3. İkinci Eğitim Metrikleri

Time	Step	Training loss	Validation loss	Full Validation loss
23:06:51	62	0.7405	0.1163	-
23:06:48	61	0.7823	0.1121	-
23:06:46	60	0.8192	0.1158	-
23:06:44	59	0.6783	0.1142	-
23:06:41	58	0.7747	0.1160	-
23:06:39	57	0.5573	0.1134	-
23:06:37	56	0.5297	0.1162	-
23:06:34	55	0.9219	0.1155	-
23:06:32	54	0.8611	0.1146	-
23:06:32	53	0.6888	0.1165	-
23:06:30	52	0.8309	0.1160	-

Hiper parametre değişikliklerinin model performansına etkisini değerlendirmek amacıyla, farklı bir deney gerçekleştirilmiştir. Bu aşamada, epoch sayısı sabit tutulurken, Küme boyutu değeri 2 ve Öğrenme hızı değeri 0,1 olarak belirlenmiştir. Bu yeni hiper

parametrelerle model yeniden eğitilmiş ve sonuç olarak Training Loss (TL) ve Validation Loss (VL) grafikleri Şekil 5.15'te sunulmuştur.

Elde edilen TL grafiği, daha düzenli bir azalma eğilimi göstermiştir. Bu durum, modelin veri setindeki ilişkileri daha iyi öğrenmeye başladığını ve eğitim sürecinin istikrar kazandığını ifade etmektedir. TL ve VL grafiğindeki paralel azalma, küçük küme boyutunun ve uygun öğrenme oranının, modelin ağırlık güncellemelerini daha etkili hale getirdiğini göstermektedir.

Bu eğitime ilişkin metrikler ise Çizelge 5.4'te detaylı olarak sunulmuştur. Metriklerin incelenmesi, farklı hiper parametre kombinasyonlarının model performansı üzerindeki etkilerini karşılaştırmak ve optimum parametre setini belirlemek için değerli bir referans sağlamaktadır. Bu analizler, modelin genelleme yeteneğini artırmaya yönelik stratejilerin geliştirilmesine katkı sağlamaktadır.

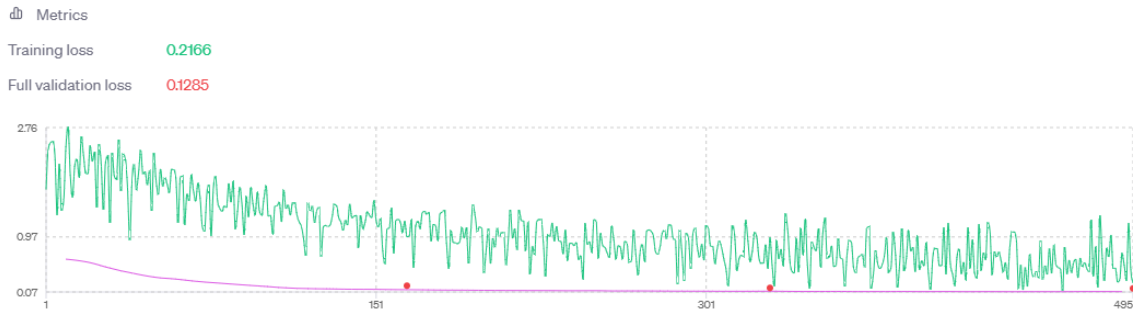

Şekil 5.15. Üçüncü eğitim TL ve VL grafiği

Çizelge 5.4. Üçüncü Eğitim Metrikleri

Time	Step	Training loss	Validation loss	Full Validation loss
00:38:40	495	0.2166	-	0.1285
00:38:12	494	0.4321	-	-
00:38:11	493	1.1783	-	-
00:38:07	492	0.2641	-	-
00:38:07	491	0.5113	-	-
00:38:06	490	0.6948	0.0753	-
00:38:06	489	0.2782	-	-
00:38:03	488	0.2332	-	-
00:38:03	487	0.4573	-	-

00:38:03	486	0.4574	-	-
00:38:02	485	0.9948	-	-

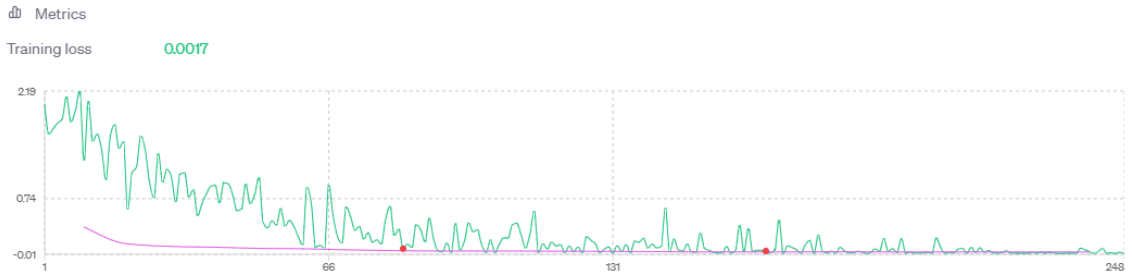

Şekil 5.16. Dördüncü eğitim TL ve VL grafiği

Şekil 5.16'te sunulan grafik, Küme boyutu değeri 4 ve Öğrenme hızı değeri 0,8 olarak belirlenmiş hiper parametrelerle gerçekleştirilen eğitime aittir. Bu parametre kombinasyonuyla model, yeterince düşük bir Training Loss (TL) değeri ve düzenli bir azalma eğilimi gösteren bir grafik elde etmiştir. Bu durum, modelin eğitim sürecinde veriye daha iyi adapte olduğunu ve öğrenme sürecinin istikrarlı bir şekilde ilerlediğini göstermektedir.

Çizelge 5.5'te, dördüncü eğitim sırasında elde edilen son kısım adımlardaki Training Loss (TL) ve Validation Loss (VL) değerleri verilmiştir. Bu metrikler, modelin eğitim sürecinde yalnızca eğitim verisi üzerinde değil, aynı zamanda doğrulama verisi üzerinde de iyi performans gösterdiğini doğrulamaktadır.

Elde edilen sonuçlar, uygun hiper parametre seçiminin, modelin öğrenme sürecine ve genel performansına etkisini açıkça ortaya koymaktadır. Bu sonuçlar, hiper parametre optimizasyonunun model geliştirme sürecinde kritik bir rol oynadığını bir kez daha vurgulamaktadır.

Çizelge 5.5. Dördüncü Eğitim Metrikleri

Time	**Step**	**Training loss**	**Validation loss**	**Full Validation loss**
22:07:39	248	0.0017	-	-
22:07:31	247	0.0177	-	-
22:07:31	246	0.0026	-	-
22:07:30	245	0.0109	-	-

22:07:25	244	0.0022	-	-
22:07:25	243	0.0682	-	-
22:07:25	242	0.0266	-	-
22:07:24	241	0.0039	-	-
22:07:19	240	0.0256	0.0218	-
22:07:19	239	0.0526	-	-
22:07:19	238	0.0721	-	-

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
EBYS (Elektronik Belge Yönetim Sistemi) sistemine e-imzanızı aktiv etmek için aşağıdaki adımları takip edebilirsiniz:

1. **E-imza Yazılımının Kurulumu:** E-imzanızı kullanabilmek için öncelikle ilgili e-imza yazılımının bilgisayarınıza kurulu olduğundan emin olun. Genellikle, e-imza sağlayıcınızın web sitesinden veya ilgili e-imza kartı ile birlikte gelen yazılımı kullanarak bu işlemi gerçekleştirebilirsiniz.

2. **E-imza Donanımını Bağlayın:** E-imza kartınızı (e-imza token/device) bilgisayarınıza takın. Gerekli sürücülerin yüklü olduğundan emin olun.

3. **EBYS Sistemine Giriş:** E-imzanızı kullanarak giriş yapmanız gereken EBYS platformuna gidin.

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
E-Belge Yönetim Sistemi (EBYS) gibi sistemlerde e-imzanızı aktifleştirmek için genellikle aşağıdaki adımları izleyebilirsiniz:

1. **Gerekli Yazılımlar**: Öncelikle, e-imzanızı kullanabilmek için gerekli yazılımların (örneğin, e-imza sürücüleri veya uygulamaları) doğru şekilde bilgisayarınıza yüklendiğinden emin olun.

2. **EBYS Giriş**: EBYS sistemine kullanıcı adı ve şifrenizle giriş yapın.

3. **Profil ve Ayarlar**: Sisteme giriş yaptıktan sonra, genellikle 'Hesap', 'Profil' veya 'Ayarlar' kısmına giderek e-imza ayarlarını bulabilirsiniz.

4. **E-imza Aktifleştirme**: Bu bölümde, e-imzanızı aktifleştirmek için bir seçenek bulunabilir. İlgili kısımları doldurduktan sonra, e-imzanızın bağlı olduğu USB cihazını

Şekil 5.17. İlk eğitim sonrası soru-cevap 1

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Güvenlik 2. Merkezi Derslik bilgisayarının açılmaması durumu için aşağıdaki adımları takip edebilirsiniz:

1. **Güç Kaynağını Kontrol Edin**:
   - Bilgisayarın fişe takılı olduğundan emin olun.
   - Güç kablosunun sağlam olduğuna ve bilgisayara düzgün bir şekilde bağlı olduğuna bakın.
   - Fişi farklı bir prizin içine takarak deneyin.

2. **Güç Butonunu Kontrol Edin**:
   - Bilgisayarın güç butonuna basmayı deneyin. Bazen buton yanıt vermeyebilir.

3. **Aydınlatma Durumunu Kontrol Edin**:
   - Bilgisayarın güç ışığı yanıyor mu? Eğer yanmıyorsa, güç kaynağında bir sorun olabilir.

4. **Donanım Bağlantılarını Gözden Geçirin**:
   - Bilgisayarın içerisindeki tüm kablo ve parçaların düzgün

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Güvenlik 2. Merkezi Derslik Bilgisayarı'nın açılmaması durumu için aşağıdaki adımları izleyerek sorun gidermeye çalışabilirsiniz:

1. **Güç Kaynağını Kontrol Etme**:
   - Bilgisayarın elektrik prizine doğru bir şekilde bağlı olup olmadığını kontrol edin.
   - Eğer mümkünse, farklı bir priz deneyin.
   - Uzatma kablosu kullanıyorsanız, uzatma kablosunun çalıştığından emin olun.

2. **Donanım Kontrolleri**:
   - Bilgisayarın güç düğmesine basarak açmayı deneyin. Eğer yanıt yoksa, güç kaynağının çalışıp çalışmadığını test etmek için bilgisayarı açmadan önce güç kaynağının LED gösterge lambasının yanıp yanmadığını kontrol edin.
   - Bilgisayar kasasının üzerindeki bağlantı kablo ve fişlerin doğru bir şekilde bağlandığını kontrol edin.

Şekil 5.18. İlk eğitim sonrası soru-cevap 2

Şekil 5.17 ve Şekil 5.18'de, modelin ilk eğitim sonrası test amacıyla sorulan sorulara verdiği yanıtlar gösterilmektedir. Bu sorular, eğitim setinde yer alan verilerden seçilmiş olmasına rağmen, modelin başarısız bir eğitim sürecinden geçtiği için verilen yanıtlar, eğitimsiz haliyle ürettiği yanıtlardan farksızdır. Bu durum, modelin eğitim verilerindeki örneklerden öğrenim gerçekleştiremediğini ve hiper parametrelerin veya veri setinin düzenlenmesi gerektiğini göstermektedir.

Eğitim verileriyle yeterli ilişki kurulamaması, modelin genelleme yeteneğini kaybetmesine ve başarısız bir performans sergilemesine neden olmuştur. Bu gözlem,

eğitim sürecini optimize etmek için hiper parametre ayarlarının dikkatlice düzenlenmesi ve eğitim verilerinin özenle hazırlanması gerektiğini vurgulamaktadır.

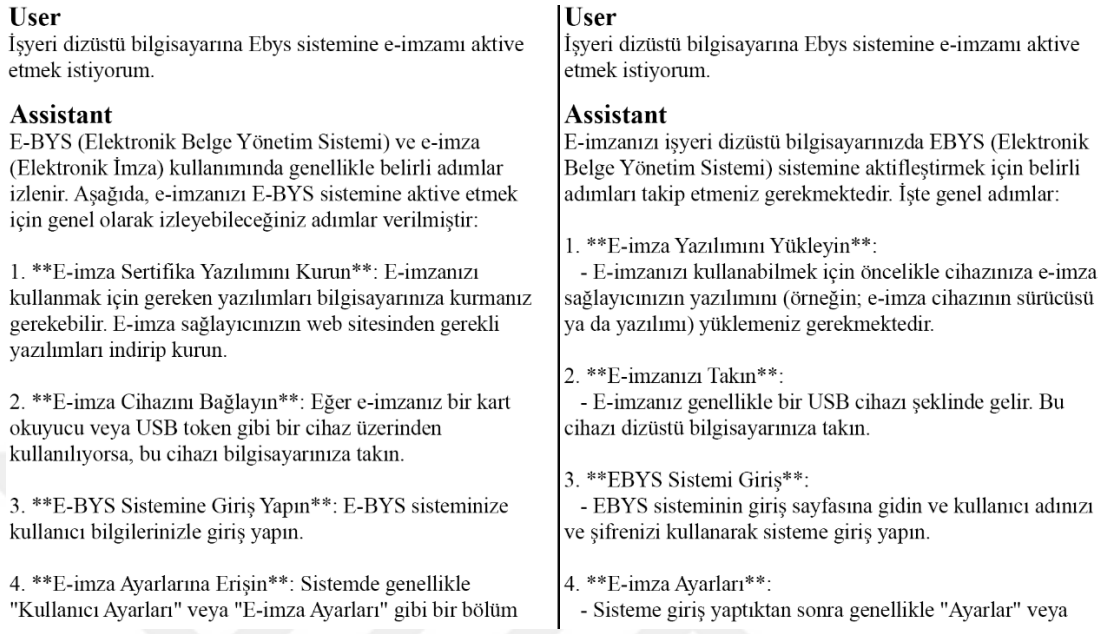

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
E-BYS (Elektronik Belge Yönetim Sistemi) ve e-imza (Elektronik İmza) kullanımında genellikle belirli adımlar izlenir. Aşağıda, e-imzanızı E-BYS sistemine aktive etmek için genel olarak izleyebileceğiniz adımlar verilmiştir:

1. **E-imza Sertifika Yazılımını Kurun**: E-imzanızı kullanmak için gereken yazılımları bilgisayarınıza kurmanız gerekebilir. E-imza sağlayıcınızın web sitesinden gerekli yazılımları indirip kurun.

2. **E-imza Cihazını Bağlayın**: Eğer e-imzanız bir kart okuyucu veya USB token gibi bir cihaz üzerinden kullanılıyorsa, bu cihazı bilgisayarınıza takın.

3. **E-BYS Sistemine Giriş Yapın**: E-BYS sisteminize kullanıcı bilgilerinizle giriş yapın.

4. **E-imza Ayarlarına Erişin**: Sistemde genellikle "Kullanıcı Ayarları" veya "E-imza Ayarları" gibi bir bölüm

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
E-imzanızı işyeri dizüstü bilgisayarınızda EBYS (Elektronik Belge Yönetim Sistemi) sistemine aktifleştirmek için belirli adımları takip etmeniz gerekmektedir. İşte genel adımlar:

1. **E-imza Yazılımını Yükleyin**:
   - E-imzanızı kullanabilmek için öncelikle cihazınıza e-imza sağlayıcınızın yazılımını (örneğin; e-imza cihazının sürücüsü ya da yazılımı) yüklemeniz gerekmektedir.

2. **E-imzanızı Takın**:
   - E-imzanız genellikle bir USB cihazı şeklinde gelir. Bu cihazı dizüstü bilgisayarınıza takın.

3. **EBYS Sistemi Giriş**:
   - EBYS sisteminin giriş sayfasına gidin ve kullanıcı adınızı ve şifrenizi kullanarak sisteme giriş yapın.

4. **E-imza Ayarları**:
   - Sisteme giriş yaptıktan sonra genellikle "Ayarlar" veya

Şekil 5.19. İkinci eğitim sonrası soru-cevap 1

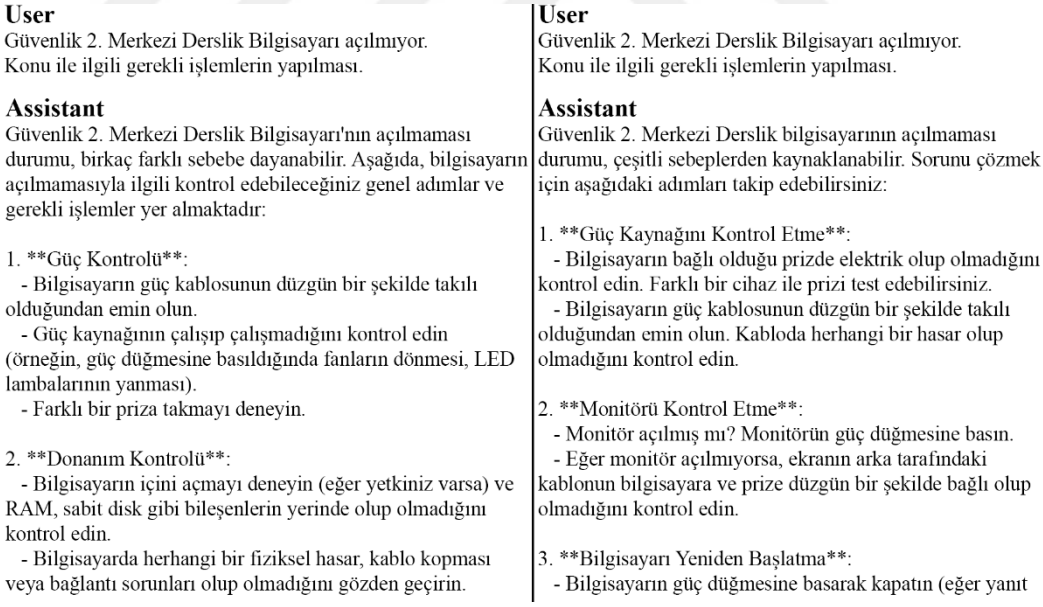

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Güvenlik 2. Merkezi Derslik Bilgisayarı'nın açılmaması durumu, birkaç farklı sebebe dayanabilir. Aşağıda, bilgisayarın açılmamasıyla ilgili kontrol edebileceğiniz genel adımlar ve gerekli işlemler yer almaktadır:

1. **Güç Kontrolü**:
   - Bilgisayarın güç kablosunun düzgün bir şekilde takılı olduğundan emin olun.
   - Güç kaynağının çalışıp çalışmadığını kontrol edin (örneğin, güç düğmesine basıldığında fanların dönmesi, LED lambalarının yanması).
   - Farklı bir priza takmayı deneyin.

2. **Donanım Kontrolü**:
   - Bilgisayarın içini açmayı deneyin (eğer yetkiniz varsa) ve RAM, sabit disk gibi bileşenlerin yerinde olup olmadığını kontrol edin.
   - Bilgisayarda herhangi bir fiziksel hasar, kablo kopması veya bağlantı sorunları olup olmadığını gözden geçirin.

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Güvenlik 2. Merkezi Derslik bilgisayarının açılmaması durumu, çeşitli sebeplerden kaynaklanabilir. Sorunu çözmek için aşağıdaki adımları takip edebilirsiniz:

1. **Güç Kaynağını Kontrol Etme**:
   - Bilgisayarın bağlı olduğu prizde elektrik olup olmadığını kontrol edin. Farklı bir cihaz ile prizi test edebilirsiniz.
   - Bilgisayarın güç kablosunun düzgün bir şekilde takılı olduğundan emin olun. Kabloda herhangi bir hasar olup olmadığını kontrol edin.

2. **Monitörü Kontrol Etme**:
   - Monitör açılmış mı? Monitörün güç düğmesine basın.
   - Eğer monitör açılmıyorsa, ekranın arka tarafındaki kablonun bilgisayara ve prize düzgün bir şekilde bağlı olup olmadığını kontrol edin.

3. **Bilgisayarı Yeniden Başlatma**:
   - Bilgisayarın güç düğmesine basarak kapatın (eğer yanıt

Şekil 5.20. İkinci eğitim sonrası soru-cevap 2

Şekil 5.19 ve Şekil 5.20'de, modelin ikinci eğitimi sonrasında test amacıyla sorulan sorulara verdiği yanıtlar yer almaktadır. Bu testte, hem gpt-4o-mini-2024-07-18 temel modeli hem de hassas ayar işlemi uygulanmış model değerlendirilmiştir. Ancak, eğitim sonucu elde edilen grafiklerin gösterdiği paralellik, modelin öğrenme

gerçekleştiremediğini ve eğitim sürecinin hedeflenen etkileri sağlamadığını ortaya koymuştur.

Verilen cevapların, eğitimden önceki yanıtlarla benzerlik göstermesi, modelin eğitim verilerindeki örneklerden anlamlı bir şekilde öğrenemediğini doğrulamaktadır. Bu durum, eğitim sürecindeki veri seti, hiper parametre ayarları veya model mimarisinde daha kapsamlı iyileştirme ve düzenleme gerektiğini işaret etmektedir. Eğitim sürecinin optimize edilmesi ve daha etkili bir öğrenme mekanizmasının oluşturulması, modelin performansını artırmak için kritik bir adım olacaktır.

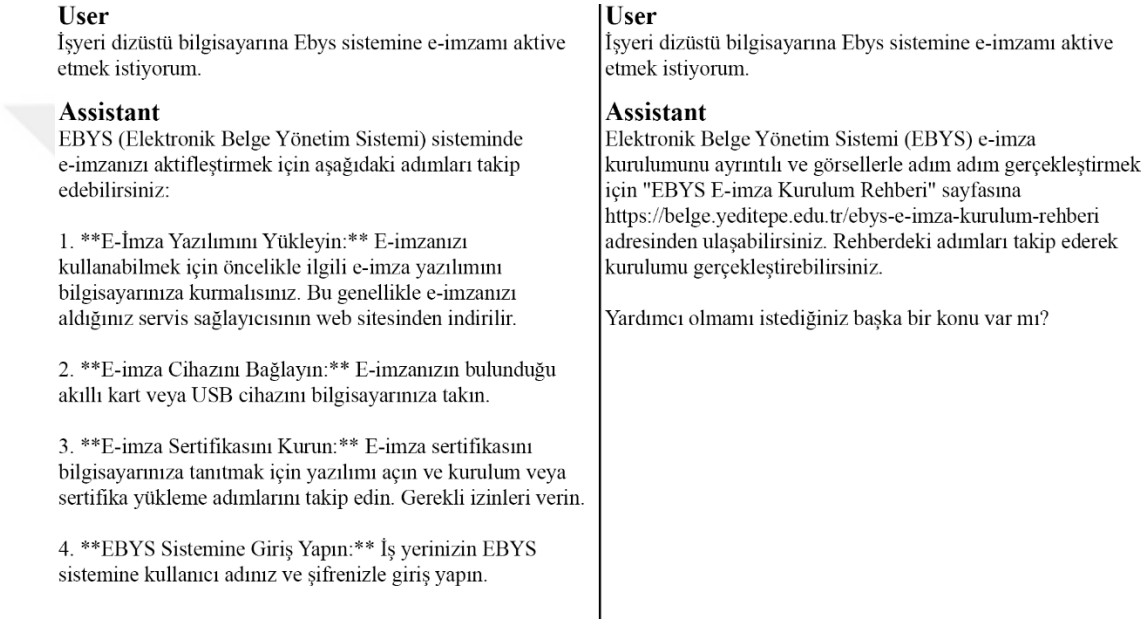

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
EBYS (Elektronik Belge Yönetim Sistemi) sisteminde e-imzanızı aktifleştirmek için aşağıdaki adımları takip edebilirsiniz:

1. **E-İmza Yazılımını Yükleyin:** E-imzanızı kullanabilmek için öncelikle ilgili e-imza yazılımını bilgisayarınıza kurmalısınız. Bu genellikle e-imzanızı aldığınız servis sağlayıcısının web sitesinden indirilir.

2. **E-imza Cihazını Bağlayın:** E-imzanızın bulunduğu akıllı kart veya USB cihazını bilgisayarınıza takın.

3. **E-imza Sertifikasını Kurun:** E-imza sertifikasını bilgisayarınıza tanıtmak için yazılımı açın ve kurulum veya sertifika yükleme adımlarını takip edin. Gerekli izinleri verin.

4. **EBYS Sistemine Giriş Yapın:** İş yerinizin EBYS sistemine kullanıcı adınız ve şifrenizle giriş yapın.

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
Elektronik Belge Yönetim Sistemi (EBYS) e-imza kurulumunu ayrıntılı ve görsellerle adım adım gerçekleştirmek için "EBYS E-imza Kurulum Rehberi" sayfasına https://belge.yeditepe.edu.tr/ebys-e-imza-kurulum-rehberi adresinden ulaşabilirsiniz. Rehberdeki adımları takip ederek kurulumu gerçekleştirebilirsiniz.

Yardımcı olmamı istediğiniz başka bir konu var mı?

Şekil 5.21. Üçüncü eğitim sonrası soru-cevap 1

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Güvenlik 2. Merkezi Derslik Bilgisayarı'nın açılmamasıyla ilgili olaraka şağıdaki adımları takip edebilirsiniz:
1. Güç Kaynağını Kontrol Etme:**
- Bilgisayarın güç bağlantısını kontrol edin. Elektrik prizine bağlı mı?
- Bilgisayarın arka tarafındaki güç anahtarını kontrol edin. Açık durumda mı?
2. **Kabloları Gözden Geçirme*
- Güç kablosunun sağlam birş ekilde bağlandığından emin olun.
- Herhangi bir kablonun zarar görüp görmediğini kontrol edin.
3.**Donanım Kontrolleri:**
- Bilgisayarın ekranının açılıp açılmadığını kontrol edin. Eğer ekran açılmıyorsa, monitör ve kabloları da kontrol edin.
- Bilgisayarın kasasının üzerindeki LED ışıklarının yanıp yanmadığını kontrol edin.

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Bilgisayar teknik destek ihtiyacı nedeniyle formatlanması gereken bilgisayarlar) için:
1-Bilgisyar(lar) sabit diskten işletim sistemleri ile çalıştıkları için sorun kayıt altına alındıktan sonra istek üzerine "BİL216" kurupta "Derslik Bilgisayarları Talep Formu'ndan talep edilmeli ve teknik desteke kibi talebi uygun bulunursa ilgili birime yönlendirme yaparak sorunu gidermeye çalışmaktadır.
3- Talepler personel tarafından yapılması gereken talepler olduğu için formda birim/personel adının belirtilmesi daha uygun olacaktır.
Not: Bilgisyar(lar) sorun kayıt altına alındıktan sonra onarım süresi talebi de birim/personel tarafında iletilmesi uygun olacaktır.

Şekil 5.22. Üçüncü eğitim sonrası soru-cevap 2

Şekil 5.21 ve Şekil 5.22'de, eğitilmemiş model ile eğitilmiş modele aynı sorular sorulduğunda alınan yanıtların karşılıklı çıktıları sunulmuştur. İlk iki eğitimin, model üzerinde herhangi bir etkisi olmadığı ve modelin eğitimsiz haliyle verdiği yanıtlardan farklı bir cevap üretemediği görülmüştür. Bu durum, ilk iki eğitim sürecinin modelin öğrenmesine katkı sağlayamadığını açıkça ortaya koymaktadır.

Bununla birlikte, üçüncü eğitim sonucunda, modelin bazı sorulara yanlış cevaplar vermesine rağmen genel yanıtlar yerine farklı ve belirli bir cevap ürettiği gözlemlenmiştir. Bu durum, eğitimin istenilen seviyede olmasa da modelin öğrenme sürecinde bir ilerleme kaydettiğini göstermektedir. Yanıtlardaki bu farklılık, eğitim

sürecinin modelin veriyle ilişki kurma yeteneğini kısmen de olsa geliştirdiğini ve eğitimin etkisinin daha ileri optimizasyonlarla artırılabileceğini işaret etmektedir.

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
EBYS (Elektronik Belge Yönetim Sistemi) sisteminde e-imzanızı aktive etmek için aşağıdaki adımları izleyebilirsiniz. Lütfen unutmayın ki bu adımlar genel bilgiler sunmakta olup, kullandığınız sistemin spesifik gereksinimlerine göre değişiklik gösterebilir:

1. **E-imza Yazılımınızı Kurun:** E-imzanızı kullanabilmek için, e-imza yazılımının bilgisayarınıza düzgün bir şekilde kurulu olduğundan emin olun. E-imza sağlayıcınızın web sitesinden en güncel sürümü indirip kurabilirsiniz.

2. **E-imza Kiti Bağlantısını Yapın:** Eğer e-imza oluşturmak için bir donanım (token ya da akıllı kart) kullanıyorsanız, bu cihazı bilgisayarınıza bağlayın. Eğer bu bir akıllı kart ise, kart okuyucusu kullanmanız gerekebilir.

3. **EBYS Sisteminde Giriş Yapın:** EBYS sistemine kullanıcı adınız ve şifrenizle giriş yapın.

User
İşyeri dizüstü bilgisayarına Ebys sistemine e-imzamı aktive etmek istiyorum.

Assistant
Elektronik Belge Yönetim Sistemi(EBYS)'nde e-imza kurulumunu ayrıntılı ve görsellerle adım adım kurulum için "EBYS E-imza Kurulum Rehberi(tavsiyemiz bu kılavuz kullanmanız) veya EBYS Java E-imza Rehberi" iki rehberden birisini uygulayarak gerçekleştirebilirsiniz. Rehberlere erişmek için şu adımları takip edebilirsiniz:

1- Bilgi İşlem Daire Başkanlığı(BİDB) sayfasına gidin (https://bidb.klu.edu.tr),
2- Sol tarafta "Önemli Bağlantılar" menüsü altında "Elektronik Belge Yönetim Sistemi Rehberleri" sekmesine tıklayın,
3- Aşağı doğru açılan sekmelerde "EBYS Java E-imza Rehberi" veya "EBYS E-imza Kurulum Rehberi" sekmelerinden tercihinize göre tıkladığınızda rehber açılacaktır.

Yardımcı olmamı istediğiniz başka bir konu var mı?

Şekil 5.23. Dördüncü eğitim sonrası soru-cevap 1

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Güvenlik 2. Merkezi Derslik bilgisayarının açılmaması durumunda aşağıdaki adımları izleyerek sorunu çözmeye çalışabilirsiniz:
1. Güç Kaynağını Kontrol Etme**:
- Bilgisayarın fişinin prize düzgün şekilde takılı olduğundan emin olun.
- Elektrik prizi çalışıyor mu? Farklı bir cihaz ile deneme yaparak prizin çalıştığını kontrol edin.
2.*Donanım Bağlantılarını Kontrol Etme**:
- Bilgisayarın arkasındaki güç kablosunu kontrol edin; kablonun sağlam takılı olduğundan emin olun.
- Eğer bir uzatma kablosu kullanıyorsanız, o kablonun da çalıştığından emin olun.
3. “Batarya ve Şarj Durumu (Laptop ise)*:
- Eğer dizüstü bilgisayar kullanıyorsanız, bataryanın düzgün bir şekilde takılı olup olmadığını ve şarj durumunu kontrol edin.n.

User
Güvenlik 2. Merkezi Derslik Bilgisayarı açılmıyor.
Konu ile ilgili gerekli işlemlerin yapılması.

Assistant
Bilgisayar(Masaüstü veya DizüstüMların) arızalarında yapılmasa gerekenler:
1- Destek Bilgi Sisteminde tiket açarak sorunun anlatılması
2- Tiket açıldıktan sonra tiketteki numara arızalı bilgsayar üzerine yazılır.
3- Bilgisyar(lar) Teknik inceleme için Bilgi İşlem Daire Başkanlığına getirilir.

Yardımcı olmamı istediğiniz başka bir konu var mı?

Şekil 5.24. Dördüncü eğitim sonrası soru-cevap 2

Şekil 5.23 ve Şekil 5.24’te, son eğitimden geçirilen modele sorulan sorulara verilen yanıtlar sunulmaktadır. Bu test sonuçları, eğitilmiş modelin istenilen düzeyde doğru cevaplar verdiğini ve önceki eğitim süreçlerine kıyasla belirgin bir ilerleme

kaydedildiğini göstermektedir. Modelin, eğitim verilerindeki örneklerden öğrenim gerçekleştirdiği ve bu öğrenimi test aşamasında etkili bir şekilde uygulayabildiği gözlemlenmiştir.

Son eğitim sonucunda elde edilen grafiğin gösterdiği paralellik ile modelin verdiği doğru yanıtlar, bu eğitimin başarılı bir şekilde tamamlandığını ve modelin beklenen performans seviyesine ulaştığını doğrulamaktadır. Bu sonuçlar, doğru yapılandırılmış bir eğitim sürecinin ve optimize edilmiş hiper parametrelerin model performansı üzerindeki kritik etkisini bir kez daha ortaya koymaktadır.

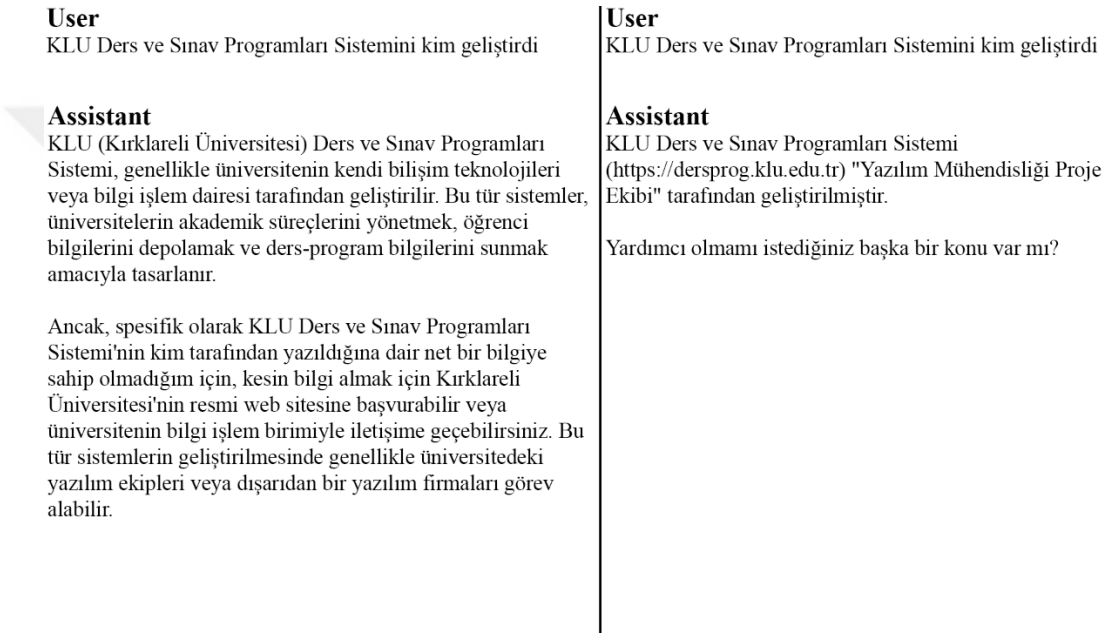

Şekil 5.25. Eğitimde olmayan soru-cevap

Şekil 5.25'te, eğitim sırasında doğrudan cevabı verilmemiş ancak çıkarım yapılarak yanıtlanması beklenen bir soru modele yöneltilmiştir. Sonuçlar, modelin doğru bir çıkarım yaparak soruya anlamlı bir yanıt verdiğini göstermektedir. Bu durum, modelin yalnızca eğitim sürecinde sunulan soru-cevap çiftlerini ezberlemediğini, aynı zamanda bu verilerden anlam çıkarma ve genelleme yapma yeteneği kazandığını ortaya koymaktadır.

Modelin bu şekilde çıkarım yapabilmesi, eğitim sürecinde verilen veri ve yapılandırılmış hiper parametrelerin etkinliğini ve modelin öğrenme mekanizmasının güçlendiğini göstermektedir. Bu sonuç, modelin daha önce karşılaşmadığı durumlarda dahi öğrenilen bilgilere dayanarak mantıklı yanıtlar üretebileceğini ve problem çözme kapasitesini geliştirdiğini işaret etmektedir.

BÖLÜM 6

SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında, IT birimleri tarafından yaygın olarak kullanılan Destek Talep Sistemlerinin, ChatGPT gibi büyük dil modelleri ile nasıl geliştirilebileceği üzerinde durulmuştur. Çalışmanın temel hedefi, bu sistemlerin kullanıcılarla daha etkili ve hızlı bir şekilde etkileşim kurabilen, aynı zamanda çözüm önerileri üretebilen interaktif bir yapıya kavuşmasını sağlamaktır. Bu doğrultuda, bir destek talep sistemini simüle etmek amacıyla ChatGPT'nin hassas ayar uygulanması süreci gerçekleştirilmiş ve sonuçları gözlemlenmiştir.

Elde edilen bulgular, büyük dil modellerinin dil anlama ve kullanıcı taleplerine uygun yanıt oluşturma kapasitesinin oldukça yüksek olduğunu göstermiştir. Hassas ayar uygulanılmış model, destek talepleri anlamak, doğru çözümleri önererek hızlı çözümler üretmek açısından başarılı bir performans sergilemiştir.

Modelin, kullanıcı taleplerine doğal dil ile yanıt verme yeteneği, operasyonel verimliliği artıracağı sonucuna ulaştırmakla kalmamış, aynı zamanda kullanıcıların sistemle olan etkileşim deneyimini de iyileştirebileceği gözlemlenmiştir. Bu durum, büyük dil modellerinin IT birimleri gibi yüksek yoğunlukta talep alan sistemler için güçlü bir araç olabileceğini kanıtlamıştır.

Ayrıca bu çalışma, ChatGPT'nin alt görevler için optimize edilebilme esnekliğini ve farklı alanlara uygulanabilirliğini de vurgulamaktadır. Destek talep sistemi üzerinde yapılan bu örnek uygulama, ChatGPT'nin, müşteri destek sistemleri, otomasyon süreçleri ve diğer iş odaklı uygulamalarda da başarılı bir şekilde kullanılabileceğini ortaya koymuştur.

Hiper parametrelerin doğru şekilde belirlenmesi, bir modelin performansını doğrudan etkileyen kritik bir faktördür. Öncelikle, Küme boyutu ve Learning rate gibi temel hiper parametrelerin, modelin ağırlık güncellemelerindeki dengenin sağlanması ve öğrenme sürecinin istikrarı açısından optimize edilmesi gerekmektedir. Küçük küme boyutları, modelin daha ayrıntılı öğrenmesini sağlayabilirken, öğrenme hızının aşırı düşük veya yüksek olması modelin ya çok yavaş öğrenmesine ya da kararsız bir hale gelmesine neden olabilir. Epoch sayısı, modelin aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) arasındaki dengeyi kurması için yeterli düzeyde seçilmelidir.

Gelecekte yapılacak çalışmalar, büyük dil modellerinin destek talep sistemleri için daha spesifik ve özelleştirilmiş hale getirilmesine odaklanabilir. Özellikle sektörlere özgü veri setleri ile daha kapsamlı bir hassas ayar süreci, modelin performansını artırabilir. Bunun yanı sıra, modellerin gerçek zamanlı olarak öğrenme ve adaptasyon becerilerinin geliştirilmesi, dinamik ve sürekli değişen taleplerle daha etkin bir şekilde başa çıkmalarını sağlayabilir.

Yapılan testler, hassas ayar uygulanılmış modelin, talep yönetim süreçlerini hızlandırmanın yanı sıra sistem üzerindeki insan müdahalesini azaltabilecek bir potansiyele sahip olduğunu göstermektedir. Bundan kaynaklı olarak yeni çalışmalarda sadece metin formatlı cevaplardan farklı olarak işlemleri gerçekleştirecek fonksiyonları harekete geçirecek şekilde düzenlenmesi önerilmektedir.

Ayrıca, modelin yanıtlarının doğruluğunu ve güvenilirliğini artırmak için insan geri bildirimlerine dayalı bir inceleme ve düzeltme mekanizması entegre edilmesi önerilmektedir. Güvenlik ve veri gizliliği konularında daha kapsamlı çalışmalar yapılması, dil modellerinin geniş çapta benimsenmesini teşvik edecektir. Bu bağlamda, ChatGPT ve benzeri modellerin, yalnızca destek sistemlerinde değil, daha geniş yelpazede operasyonel süreçlerde de fayda sağlayacak şekilde optimize edilmesi önemli bir adım olacaktır.

KAYNAKLAR

Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., Aleman, F. L., ... & McGrew, B. (2023). Gpt-4 Technical Report. *arXiv*. Advance online publication. doi: https://doi.org/10.48550/arXiv.2303.08774

Akkurt, S. S. (2020). Kişisel Veri Kavramının Hukukî Niteliğine İlişkin Yaklaşımlara Mukayeseli Bir Bakış. *Kişisel Verileri Koruma Dergisi, 2*(1), 20-32.

Bach, S. H., Sanh, V., Yong, Z. X., Webson, A., Raffel, C., Nayak, N. V., ... & Rush, A. M. (2022). *Promptsource: An integrated development environment and repository for natural language prompts*. In 2022 60th Annual Meeting Of The Association For Computational Linguistics (ACL 2022), Dublin. doi: https://doi.org/10.48550/arXiv.2202.01279

Bousselham, H., & Mourhir, A. (2024, February). *Fine-Tuning GPT on biomedical NLP tasks: an empirical evaluation*. In 2024 International Conference On Computer, Electrical & Communication Engineering (ICCECE 2024), Kolkata. doi: https://doi.org/10.1109/ICCECE58645.2024.10497313

Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... & Amodei, D. (2020). *Language models are few-shot learners*. In 2020 34th Annual Conference on Neural Information Processing Systems (NeurIPS 2020), Çevrimiçi Konferans. Erişim adresi: https://papers.nips.cc/paper_files/paper/2020/hash/1457c0d6bfcb4967418bfb8ac142f64a-Abstract.html

Cheng, S. W., Chang, C. W., Chang, W. J., Wang, H. W., Liang, C. S., Kishimoto, T., ... & Su, K. P. (2023). The now and future of ChatGPT and GPT in psychiatry. *Psychiatry And Clinical Neurosciences*, *77*(11), 592-596.

Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron) — a review of applications in the atmospheric sciences. *Atmospheric Environment*, *32*(14-15), 2627-2636.

Gemirter, C. B., & Goularas, D. (2021). A Turkish question answering system based on deep learning neural networks. *Journal Of Intelligent Systems: Theory And Applications*, *4*(2), 65-75.

Hauser, M. D., Chomsky, N., & Fitch, W. T. (2002). The Faculty of Language: What Is It, Who Has It, and How Did It Evolve?. *Science, 298*(5598), 1569-1579. doi: https://doi.org/10.1126/science.298.5598.1569

Hu, J.E., Shen, Y., Wallis, P., Allen-Zhu, Z., Li, Y., Wang, S., & Chen, W. (2021). *LoRA: Low-Rank Adaptation of Large Language Models*. In 2022 International Conference On Learning Representations (ICLR 2022), Çevrimiçi Konferans. Erişim adresi: https://openreview.net/forum?id=nZeVKeeFYf9

Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, *29*(3), 31-44.

Kalyan, K. S. (2024). A survey of GPT-3 family large language models including ChatGPT and GPT-4. *Natural Language Processing Journal, 6*, 100048.

Kalyan, K.S., Rajasekharan, A., & Sangeetha, S. (2021). AMMUS: A Survey of Transformer-based Pretrained Models in Natural Language Processing. *arXiv*. Advance online publication. doi: https://doi.org/10.48550/arXiv.2108.05542

Kalyan, K.S., Rajasekharan, A., Sangeetha, S., (2022). AMMU: a survey of transformer-based biomedical pretrained language models. *Journal Of Biomedical Informatics. 126*, 103982.

Kang, Y., Cai, Z., Tan, C. W., Huang, Q., & Liu, H. (2020). Natural language processing (NLP) in management research: A literature review. *Journal Of Management Analytics*, *7*(2), 139-172.

Kumar, V. B., Yarramsetty, M., Sun, S., & Goel, A. (2021). *SupportNet: Neural networks for summary generation and key segment extraction from technical support tickets*. In 2021 The 4th Workshop On E-Commerce And NLP, Bangkok (pp. 164-173). doi: https://doi.org/10.18653/v1/2021.ecnlp-1.20

Latif, E., Zhai, X., (2024). Fine-tuning ChatGPT for automatic scoring. *Computers and Education: Artificial Intelligence. 6*, 100210.

Li, X., Zhang, Y., & Malthouse, E.C. (2023). Exploring Fine-tuning ChatGPT for News Recommendation. *arXiv*. Advance online publication. doi: https://doi.org/10.48550/arXiv.2311.05850

Li, S., Zhao, P., Zhang, H., Sun, X., Wu, H., Jiao, D., Wang, W., Liu, C., Fang, Z., Xue, J., Tao, Y., Cui, B., & Wang, D. (2024). *Surge Phenomenon in Optimal Learning Rate and Batch Size Scaling*. In 2024 38th Annual Conference on Neural Information Processing Systems (NeurIPS 2024), Vancouver. Erişim adresi: https://openreview.net/forum?id=hD9TUV4xdz

Li, X. L., & Liang, P. (2021). *Prefix-tuning: Optimizing continuous prompts for generation*. In 2021 Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, Çevrimiçi Konferans. doi: https://doi.org/10.18653/v1/2021.acl-long.353

Liga, D., & Robaldo, L. (2023). Fine-tuning GPT-3 for legal rule classification. *Computer Law & Security Review*, *51*, 105864.

Liu, X., & Croft, W. B. (2005). Statistical language modeling for information retrieval. *Annual Review Of Information Science and Technology*, *39*(1), 1-31.

Medsker, L. R., & Jain, L. (Ed.) (1999). *Recurrent Neural Networks: Design And Applications*. Washington D.C.: CRC Press.

Manning, C., & Schutze, H. (1999). *Foundations of statistical natural language processing*. London: The MIT Press.

Otter, D. W., Medina, J. R., & Kalita, J. K. (2020). A survey of the usages of deep learning for natural language processing. *IEEE Transactions On Neural Networks And Learning Systems*, *32*(2), 604-624.

Patil, R., Boit, S., Gudivada, V., & Nandigam, J. (2023). A survey of text representation and embedding techniques in nlp. *IEEE Access*, *11*, 36120-36146.

Qiu, X., Sun, T., Xu, Y., Shao, Y., Dai, N., & Huang, X. (2020). Pre-trained models for natural language processing: A survey. *Science China Technological Sciences*, *63*(10), 1872-1897.

Reti, D., Becker, N., Angeli, T., Chattopadhyay, A., Schneider, D., Vollmer, S., & Schotten, H. D. (2024). *Act as a Honeytoken Generator! An Investigation into Honeytoken Generation with Large Language Models*. In 2024, 11th ACM Workshop on Adaptive and Autonomous Cyber Defense, Salt Lake City. doi: https://doi.org/10.1145/3689935.3690394

Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, *59*(236), 433–460

Vaswani, A., Shazeer, N.M., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L., & Polosukhin, I. (2017). *Attention is All you Need*. In 2017 31th Annual Conference on Neural Information Processing Systems (NeurIPS 2017), Long Beach. Erişim adresi: https://papers.nips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html

Yang, J., Jin, H., Tang, R., Han, X., Feng, Q., Jiang, H., Yin, B., & Hu, X. (2023). Harnessing the Power of LLMs in Practice: A Survey on ChatGPT and Beyond. *ACM Transactions On Knowledge Discovery From Data*, *18*(6), 1-32.

Yao, Y., Duan, J., Xu, K., Cai, Y., Sun, Z., & Zhang, Y. (2024). A survey on large language model (llm) security and privacy: The good, the bad, and the ugly. *High-Confidence Computing*, *4*(2), 100211.

Ye, P., Huang, Y., Tu, C., Li, M., Chen, T., He, T., & Ouyang, W. (2023). Partial Fine-Tuning: A Successor to Full Fine-Tuning for Vision Transformers. *arXiv*. Advance online publication. doi: https://doi.org/10.48550/arXiv.2312.15681

Yenduri, G., Ramalingam, M., Selvi, G.C., Supriya, Y., Srivastava, G., Maddikunta, P.K., Raj, G.D., Jhaveri, R.H., Prabadevi, B., Wang, W., Vasilakos, A.V., & Gadekallu, T.R. (2023). GPT (Generative Pre-Trained Transformer) — A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions. *IEEE Access*, *12*, 54608-54649.

Zangari, A., Marcuzzo, M., Schiavinato, M., Gasparetto, A., & Albarelli, A. (2023). Ticket automation: An insight into current research with applications to multi-level classification scenarios. *Expert Systems with Applications*, *225*, 119984.

Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., ... & Wen, J. R. (2023). A survey of large language models. *arXiv*. Advance online publication. doi: https://doi.org/10.48550/arXiv.2303.18223

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Bilal ÖRÜCÜ

Medeni Durumu: Evli

EĞİTİM

2011 - 2016 : On dokuz Mayıs Üniversitesi, Bilgisayar Mühendisliği (Lisans)

2004 - 2007 : Gaziantep Vehbi Dinçerler Fen Lisesi

İŞ DENEYİMİ

10/2020- Devam **Kırklareli Üniversitesi – Bilgi İşlem Daire Başkanlığı**

- Yazılım Şube Müdür V. (Mühendis)

08/2013 - 10/2020 **Giresun Defterdarlığı – Hizmetli**