

**İŞE ALIM SÜREÇLERİNDE YAPAY ZEKAYA DAYALI
BİR KARAR DESTEK SİSTEMİ MODELİ KULLANARAK
YANLILIĞIN AZALTILMASI**

YÜKSEK LİSANS TEZİ

Murat ÇİÇEK

Danışman

Doç. Dr. Celal Onur GÖKÇE

İNTERNET VE BİLİŞİM TEKNOLOJİLERİ YÖNETİMİ

ANABİLİM DALI

Temmuz 2026

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**İŞE ALIM SÜREÇLERİNDE YAPAY ZEKAYA DAYALI BİR
KARAR DESTEK SİSTEMİ MODELİ KULLANARAK
YANLILIĞIN AZALTILMASI**

Murat ÇİÇEK

Danışman

Doç. Dr. Celal Onur GÖKÇE

**İNTERNET VE BİLİŞİM TEKNOLOJİLERİ YÖNETİMİ
ANABİLİM DALI**

Temmuz 2026

TEZ ONAY SAYFASI

Murat ÇİÇEK tarafından hazırlanan “İşe Alım Süreçlerinde Yapay Zekaya Dayalı Bir Karar Destek Sistemi Modeli Kullanarak Yanlılığın Azaltılması” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 01 / 07 / 2026 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **İnternet ve Bilişim Teknolojileri Yönetimi Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Celal Onur GÖKÇE

Başkan : Doç. Dr. Selçuk TAŞCIOĞLU
Ankara Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Celal Onur GÖKÇE
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Dr. Ebru AYDOĞAN
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

01 / 07 / 2026

Murat ÇİÇEK

ÖZET
Yüksek Lisans Tezi

**İŞE ALIM SÜREÇLERİNDE YAPAY ZEKAYA DAYALI BİR KARAR DESTEK
SİSTEMİ MODELİ KULLANARAK YANLILIĞIN AZALTILMASI**

Murat ÇİÇEK

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

İnternet ve Bilişim Teknolojileri Yönetimi Anabilim Dalı

Danışman: Doç. Dr. Celal Onur GÖKÇE

Bu araştırmada; çağdaş iş dünyasının işe alım süreçlerinde giderek daha fazla kullandığı yapay zeka (YZ) destekli analitik sistemlerin, tarihsel önyargıları devralarak sistematik ayrımcılığa ve etik ihlallere yol açma riski ele alınmaktadır. Bu çalışma, bahsi geçen kritik boşluğu gidermek için yeni bir Karar Destek Sistemi (KDS) modeli önermektedir. Model, LLM teknolojisi kullanarak aday potansiyelini analiz etmek, algoritmik yanlılığı tespit etmek ve en aza indirmek üzere tasarlanmış olup, İK profesyonellerini şeffaf ve kapsayıcı işe alım kararlarına yönlendirmektedir. Temel amaç, sübjektif değerlendirmeleri ve algoritmik önyargıları azaltarak tüm adaylar için fırsat eşitliğini sağlamaktır. Metodoloji, yapay olarak üretilmiş (sentetik) özgeçmiş verilerinde bulunan cinsiyet, yaş veya etnik kökenle ilgili örtük önyargıları hafifletmek için Büyük Dil Modeli (LLM) teknolojisini kullanmaktadır. Bu "Adil İşe Alım Karar Destek Sistemi", İK'da etik YZ uygulaması için hayati bir çerçeve sunmaktadır.

2026, x + 109 sayfa

Anahtar Kelimeler: İşe alım süreci, Yapay zeka, Karar destek sistemi, Algoritmik yanlılık, Yanlılık azaltma.

ABSTRACT
M.Sc. Thesis

**REDUCING BIAS IN RECRUITMENT PROCESSES BY USING AN ARTIFICIAL
INTELLIGENCE-BASED DECISION SUPPORT SYSTEM MODEL**

Murat ÇİÇEK

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Internet and Information Technologies Management

Supervisor: Assoc. Prof. Celal Onur GÖKÇE

This research addresses the risk of algorithmic bias in artificial intelligence (AI)-driven analytical systems, which are increasingly utilized in the recruitment processes of the contemporary business world, as these tools inherit historical prejudices, leading to systematic discrimination and ethical violations. To address this critical gap, this study proposes a novel Decision Support System (DSS) model. Designed to analyze candidate potential, as well as detect and minimize algorithmic bias by leveraging Large Language Model (LLM) technology, the model guides HR professionals toward transparent and inclusive hiring decisions. The primary objective is to ensure equal opportunity for all candidates by reducing subjective evaluations and algorithmic biases. The methodology employs LLM technology to mitigate implicit biases related to gender, age, or ethnicity found in synthetically generated resume data. This "Fair Recruitment Decision Support System" offers a vital framework for ethical AI implementation in HR.

2026, x + 109 pages

Keywords: Recruitment process, Artificial intelligence, Decision support system,
Algorithmic bias, Bias reduction.

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasındaki büyük katkılarından dolayı tez danışmanım Sayın Doç. Dr. Celal Onur GÖKÇE'ye; araştırma ve yazım süresince her konudaki öneri, eleştiri ve destekleriyle yanımda olan tüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerinden dolayı aileme teşekkür ederim.

Murat ÇİÇEK
Afyonkarahisar 2026

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ.....	viii
RESİMLER DİZİNİ	ix
ÇİZELGELER DİZİNİ.....	x
1. GİRİŞ.....	1
1.1 Çalışmanın Konusu ve Önemi	2
1.2 Araştırma Soruları.....	5
1.3 Çalışmanın Kapsamı ve Sınırlılıklar.....	6
1.3.1 Kapsam.....	6
1.3.2 Sınırlılıklar	6
1.4 Araştırmanın Metodolojik Yaklaşımı	7
1.4.1 Araştırma Tasarımı.....	7
1.4.2 Nicel ve Nitel Veri Analizi.....	8
1.5 Kurumsal Temeller	8
1.5.1 İnsan Kaynakları Yönetimi ve İşe Alım Süreçleri	8
1.6 Yapay Zeka Teknolojileri	11
1.6.1 Yapay Zeka ve Makine Öğrenmesi Kavramları.....	11
1.6.2 Makine Öğrenmesi Modelleri: Lojistik Regresyon ve Karar Ağaçları	12
1.7 İşe Alım Süreçlerinde Yapay Zeka Kullanımı.....	12
1.7.1 Özgeçmiş (CV) Tarama ve Eşleştirme Sistemler.....	12
1.7.2 Aday Mülakatlarında Yapay Zeka (Chatbotlar ve Duygu Analizi)	12
1.8 Yapay Zeka Destekli İşe Alımda Etik ve Hukuki Boyut.....	14
1.8.1 Algoritmik Önyargı (Bias) ve Adil Yapay Zeka.....	14
1.8.2 Veri Mahremiyeti ve KVKK Uyumluluğu.....	15
1.8.3 AB Yapay Zeka Yasası ve Türkiye'ye Etkileri	15
1.9 Dünyada Yapay Zeka Destekli İşe Alım Uygulamaları	16
1.9.1 Öne Çıkan Platform ve Araçlar	16

2. LİTERATÜR BİLGİLERİ	18
2.1 Yurt İçinde Yapılan Çalışmalar	18
2.1.1 Aday Perspektifi, Kabul Modelleri ve Duygusal Tepkiler.....	18
2.1.2 Kamu Sektöründe İşe Alım ve Blokzincir Temelli Çözüm Önerileri.....	20
2.1.3 Türkiye'deki Araştırmaların Metodolojik Değerlendirmesi.....	21
2.2 Yurt Dışında Yapılan Çalışmalar.....	22
2.2.1 Dijital İşe Alım Araçları ve Uygulamaları	22
2.2.2 Algoritmik Önyargı, Etik ve Adil Kullanım Sorunları	24
2.3 Literatürün Değerlendirilmesi ve Mevcut Boşluklar	26
2.3.1 Genel Sentez ve Karşılaştırma	26
2.3.2 Kuramsal Çerçeve: Adil Yapay Zeka Prensipleri	30
3. MATERYAL ve METOT	31
3.1 Sistemin Genel Mimarisi	31
3.1.1 Mimari Tasarım Kararları ve Gerekçeleri.....	32
3.1.2 Sistem Güvenlik Modeli.....	33
3.2 Uygulamanın Geliştirilmesi	34
3.2.1 Kullanılan Teknolojiler, Yazılım Mimarisi ve Kütüphaneler	34
3.3 REST API Teknik dokümantasyonu.....	40
3.3.1 Proje Genel Bakışı ve Repository Yapısı.....	40
3.3.2 Mimari Yapı	40
3.3.3 Çalışma Akışı ve Konfigürasyon	41
3.3.4 Katman ve Bileşen Detayları.....	44
3.4 Veri Seti ve Veri Ön İşleme.....	48
3.4.1 Veri Seti Yapısı ve Temini.....	48
3.4.2 Veri Dengesi ve Yanlılık Temeli	50
3.5 Önerilen Model / Algoritma	52
3.5.1 Ana Model (Aday Sıralama):	52
3.5.2 Algoritma Akış Şemaları.....	53
3.5.3 Büyük Dil Modeli (LLM) Entegrasyonu ve Analiz Parametreleri	57
3.6 Güvenlik ve Veri Koruma Mimarisi	59
3.6.1 Veri Anonimleştirme ve Maskeleye.....	59
3.6.2 Veri İhlali ve Gizlilik Tasarımı	61
4. BULGULAR	63
4.1 Sistemin Çalışma Performansı.....	63

4.1.1 Sistem Yanıt Süresi ve Bileşen Profili	64
4.1.2 Güvenilirlik ve Hata Toleransı	64
4.2 Test Sonuçları ve Doğruluk Oranları	64
4.2.1 Test Metodolojisi ve Veri Bölümleme Stratejisi	65
4.3 Kullanıcı Deneyimi Bulguları	66
4.3.1 Kullanıcı Çalışması Metodolojisi ve Katılımcı Profili	67
4.4 Geleneksel Yöntem ile Karşılaştırmalı Analiz	68
4.4.1 Çok Boyutlu Performans Analizi	69
4.5 Sistem Sınırlamaları ve Geçerlilik Analizi	71
4.5.1 Veri Seti Sınırlılıkları	71
4.5.2 Teknik Geçerlilik: İç ve Dış Geçerlilik	72
5. TARTIŞMA ve SONUÇ	74
5.1 Tartışma	74
5.1.1 Bulgular Işığında Literatürle Karşılaştırmalı Tartışma	75
5.2 Sonuç	76
5.3 Gelecek Çalışmalar İçin Öneriler	78
5.4 Araştırmanın Özgün Katkıları	80
5.5 Araştırmanın Etik ve Metodolojik Sınırları	81
6. KAYNAKLAR	83
ÖZGEÇMİŞ	86
EKLER	87

SİMGELER ve KISALTMALAR DİZİNİ

Kisaltmalar

API	Uygulama Programlama Arayüzü (Application Programming Interface)
ATS	Başvuru Takip Sistemi (Applicant Tracking System)
AUC	Eğri Altı Alan (Area Under the Curve)
CV	Özgeçmiş (Curriculum Vitae)
DPD	Demografik Eşitlik Farkı (Demographic Parity Difference)
EOD	Eşit Fırsat Farkı (Equal Opportunity Difference)
GDPR	General Data Protection Regulation (Genel Veri Koruma Tüzüğü)
İK	İnsan Kaynakları
JSON	JavaScript Nesne Gösterimi (JavaScript Object Notation)
JWT	JSON Web Token
KDS	Karar Destek Sistemi
KVKK	Kişisel Verilerin Korunması Kanunu
LLM	Büyük Dil Modeli (Large Language Model)
NLP	Doğal Dil İşleme
ROC	Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SPA	Tek Sayfalı Uygulama (Single Page Application)
XAI	Açıklanabilir Yapay Zeka (Explainable AI)
YZ	Yapay Zeka

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 Geleneksel işe alım süreçleri	9
Şekil 2.1 Algoritmik yanlılık kaynakları	26
Şekil 3.1 Önerilen karar destek sistemi genel mimarisi	31
Şekil 3.2 Algoritma akış şeması	53

RESİMLER DİZİNİ

	Sayfa
Resim 3.1 Sistem giriş arayüzü – cv yükleme ekranı	35
Resim 3.2 Seçilen dosyalar listesi ve toplu yükleme arayüzü	36
Resim 3.3 İş gereksinimleri tanımlama ve dinamik puanlama arayüzü	37
Resim 3.4 Yapay Zeka Tabanlı Değerlendirme Sonuç Ekranı	39

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Yurt İçi ve Yurt Dışı Çalışmaların Karşılaştırmalı Özeti	27
Çizelge 3.1 LLM Sağlayıcı Ayarları ve Yapılandırma Parametreleri	43
Çizelge 3.2 REST API Uç Noktaları (Endpoint) Listesi	44
Çizelge 3.3 Adillik Metriklerinde Kullanılan Semboller ve Açıklamaları	54
Çizelge 4.1 KDS Modeli ve Baseline Modelin Tahmin Performansı Metrikleri	65
Çizelge 4.2 Modellerin Cinsiyet Temelli Adillik Metrikleri Karşılaştırması	68

1. GİRİŞ

Günümüzün hızla dijitalleşen iş dünyasında, organizasyonların sürdürülebilir rekabet avantajı elde etme çabaları, yalnızca finansal ve teknolojik sermaye ile sınırlı kalmayıp, insan kaynağının etkin yönetimine de giderek daha fazla odaklanmaktadır. Bu dönüşüm, iş süreçlerinin her aşamasında teknolojik yeniliklerin entegrasyonunu teşvik ederken, özellikle İnsan Kaynakları (İK) yönetiminde köklü değişikliklere yol açmaktadır. Dijitalleşmenin etkisiyle birlikte, geleneksel ve çoğunlukla manuel işleyen işe alım süreçleri yerini, büyük veri setlerini analiz edebilen, yüksek hız ve verimlilik sunan, Yapay Zeka (YZ) destekli sistemlere bırakmaktadır. Bu gelişmeler, kurumların yalnızca operasyonel yüklerini azaltmakla kalmamakta, aynı zamanda çeşitlilik, kapsayıcılık ve etik ilkelere dayalı kurumsal kültürlerin inşasında belirleyici bir rol üstlenmektedir.

Bununla birlikte, YZ tabanlı sistemlerin insan kaynakları süreçlerine entegrasyonu, beraberinde önemli etik ve teknik riskleri de getirmektedir. Özellikle işe alım gibi kritik kararlarda kullanılan algoritmik araçlar, eğitildikleri tarihsel verilerde yerleşik olan insan önyargılarını istatistiksel olarak devralabilmekte ve bu önyargıları sistematik biçimde yeniden üretebilmektedir. Sonuç olarak, algoritmalar tarafından alınan kararlar, cinsiyet, yaş, etnik köken gibi demografik özelliklere dayalı ayrımcılık ve etik ihlallere yol açarak, kurumların hem yasal hem de toplumsal sorumluluklarını riske atabilmektedir. Mevcut YZ tabanlı işe alım çözümlerinin büyük bir kısmı, bu tür algoritmik yanlılıkları şeffaf biçimde tespit etme, ölçme ve azaltma kapasitesinden yoksundur. Bu durum, nitelikli adayların haksız yere elenmesine, organizasyonların çeşitliliğinin azalmasına ve kurumların yetenek havuzunda daralma yaşanmasına sebep olabilmektedir. Dolayısıyla, YZ destekli işe alım süreçlerinde adalet, eşitlik ve şeffaflık ilkelerinin sağlanması, günümüz İK yönetiminin en güncel ve kritik araştırma alanlarından birine işaret etmektedir.

1.1 Çalışmanın Konusu ve Önemi

Bu yüksek lisans tezinin temel konusu, YZ destekli işe alım süreçlerinde ortaya çıkan algoritmik yanlılık probleminin bilimsel olarak analiz edilmesi ve bu sorunun giderilmesine yönelik yenilikçi bir Karar Destek Sistemi (KDS) modelinin geliştirilmesidir. Küreselleşen pazar dinamikleri ve dijital dönüşümün hızlanmasıyla birlikte, organizasyonlar için doğru insan kaynağına hızlı ve isabetli şekilde ulaşmak stratejik bir zorunluluk haline gelmiştir. İK departmanları, bu yeni gereksinimleri karşılamak amacıyla, geleneksel, çoğunlukla sübjektif değerlendirmelere dayalı ve yüksek maliyetli işe alım yöntemlerinden vazgeçerek, nesnel ve veriye dayalı analitik sistemleri benimsemeye yönelmektedir.

Ancak, YZ tabanlı işe alım sistemlerinin yaygınlaşması, beraberinde algoritmik yanlılık (algorithmic bias) riskini de ortaya çıkarmıştır. Bu risk, yalnızca teknik bir sorun olmanın ötesinde, etik, hukuki ve toplumsal sonuçları olan çok boyutlu bir problemdir. Algoritmalar, eğitildikleri tarihsel verilerde saklı olan insan önyargılarını (ör. cinsiyet, etnik köken, yaş gibi demografik eğilimler) yeniden üretebilmekte ve böylece sistematik ayrımcılığa yol açabilmektedir. Mevcut uygulamalar, bu tür yanlılıkları şeffaf şekilde tespit ve ölçme konusunda yetersiz kalmakta, bu da hem hukuki riskleri artırmakta hem de organizasyonların çeşitliliğini ve yetenek havuzunu olumsuz etkilemektedir.

Bu tez çalışması, söz konusu etik ve teknik boşluğu doldurmayı, algoritmik yanlılığın tespit edilmesi ve minimize edilmesine yönelik, ölçülebilir ve açıklanabilir bir Karar Destek Sistemi modeli ortaya koymayı amaçlamaktadır. Modelin geliştirilmesinde, Doğal Dil İşleme (NLP) ve makine öğrenimi gibi güncel teknolojilerden faydalanılarak, adayların yetkinlik ve potansiyellerinin demografik özelliklerden bağımsız biçimde analiz edilmesi ve insan kaynakları profesyonellerine daha adil, şeffaf ve kapsayıcı işe alım kararları sunulması hedeflenmiştir.

Çalışmanın pratik bağlamı ele alındığında, günümüzde küresel işe alım teknolojileri

pazarının 2022 yılındaki 3.1 milyar dolar seviyesinden 2027 yılına kadar 8.7 milyar dolara ulaşmasının öngörüldüğü görülmektedir. Bu hızlı büyümenin temel itici güçleri arasında uzaktan çalışmanın yaygınlaşması, artan aday havuzu karmaşıklığı ve İK maliyetlerini düşürme baskısı yer almaktadır. Türkiye özelinde değerlendirildiğinde ise 2023 yılı itibarıyla ülkemizde yaklaşık 4.2 milyon aktif iş ilanı olduğu ve bunların önemli bir bölümünün dijital platformlar aracılığıyla yönetildiği görülmektedir.

Bu makro bağlam, algoritmik işe alım araçlarının artık istisna değil norm olduğunu ortaya koymaktadır. Dolayısıyla bu araçların adillik açısından değerlendirilmesi ve denetlenmesi, hem kurumsal yönetim hem de kamu politikası boyutunda giderek daha kritik bir önem kazanmaktadır. Bu tez, söz konusu pratik ihtiyacı akademik sınırlılıklar içinde, ölçülebilir ve tekrar edilebilir bir metodoloji ile ele almaktadır.

Çalışmanın Amacı ve Yapısal Bölümlendirme

Tezin temel amacı, YZ tabanlı işe alım süreçlerinde insan faktöründen kaynaklanan önyargıların dijital ortama taşınmasının önüne geçmek; algoritmik karar süreçlerinde adalet, şeffaflık ve fırsat eşitliği ilkelerini bilimsel ve teknolojik yöntemlerle güvence altına almaktır. Bu doğrultuda, önerilen Adil İşe Alım Karar Destek Sistemi (KDS) modeli, hem etik hem de teknik açıdan bütüncül bir çözüm sunmayı hedeflemektedir. Tez çalışmasının amaçları ve yapısal çerçevesi aşağıda detaylandırılmıştır:

Çalışmanın Temel Amaçları

1. **Sübjektif Değerlendirmelerin ve Algoritmik Önyargıların Minimize Edilmesi:** Geleneksel işe alım süreçlerinde ortaya çıkan bilinçdışı insan önyargılarının, makine öğrenimi modellerine aktarılması riski göz önünde bulundurularak, tarihsel verilerde saklı önyargıların tespit edilmesi ve bunların etkisinin “de-biasing” yaklaşımları ile azaltılması amaçlanmaktadır. Doğal Dil İşleme ve Makine Öğrenimi teknikleriyle, özgeçmişlerdeki metinlerin semantik analizi ve verideki dengesizliklerin sistematik olarak giderilmesi hedeflenmektedir.
2. **Adaylara Fırsat Eşitliğinin Sunulması:** Geliştirilen modelin temel etik hedefi, tüm

adayların kimliklerinden bağımsız olarak, yalnızca yetkinlik, deneyim ve potansiyellerine göre değerlendirilmesini sağlamak; böylece liyakat esaslı bir rekabet ortamı oluşturmak ve fırsat eşitliğini teknolojik olarak güvence altına almaktır.

3. Organizasyonlara Şeffaf ve Veriye Dayalı Karar Alma Mekanizması Katkısı: Model, açıklanabilir yapay zeka (Explainable AI – XAI) yetenekleriyle, algoritmanın hangi kriterleri öne çıkardığını şeffaf biçimde gösterecek; böylece hem yasal düzenlemelere (KVKK, GDPR) uyum kolaylaşacak hem de adaylar ve kurumlar nezdinde güven artırılabilecektir.

Çalışmanın Yapısal Bölümlendirmesi

Tez, yukarıda özetlenen amaçlar doğrultusunda, teorik temelden pratik uygulamaya uzanan sistematik bir yapı ile aşağıdaki bölümlerden oluşmaktadır:

- BİRİNCİ BÖLÜM (GİRİŞ): Konunun önemi, problemin tanımı, dijitalleşen iş dünyasında İK süreçlerinin dönüşümü ve çalışmanın özgün değeri sunulmuştur. Aynı zamanda araştırmanın kuramsal temelleri kapsamında; işe alım süreçleri, yapay zeka teknolojileri, algoritmik yanlılık ve hukuki düzenlemeler (KVKK, GDPR) bu bölümde ele alınmıştır.
- İKİNCİ BÖLÜM (LİTERATÜR BİLGİLERİ): Yurt içinde ve yurt dışında gerçekleştirilen ilgili akademik çalışmalar incelenerek literatürdeki mevcut boşluklar tespit edilmiş ve bu tezin özgün katkısı konumlandırılmıştır.
- ÜÇÜNCÜ BÖLÜM (MATERYAL ve METOT): Geliştirilen KDS modelinin teknik mimarisi, kullanılan veri setleri, yazılım geliştirme süreçleri, NLP teknikleri ve yanlılık azaltma algoritmaları ile etik prosedürler açıklanmıştır.
- DÖRDÜNCÜ BÖLÜM (BULGULAR): Modelin performans testleri, adalet ve doğruluk metrikleriyle yapılan analizler ile kullanıcı deneyimi bulguları

sunulmuştur.

- BEŞİNCİ BÖLÜM (TARTIŞMA ve SONUÇ): Literatürle karşılaştırmalı tartışmalar, tezin temel katkıları ve gelecek çalışmalara yönelik öneriler yer almaktadır.

1.2 Araştırma Soruları

Tez kapsamında, YZ tabanlı işe alım süreçlerinde algoritmik yanlılık problemini çok boyutlu olarak ele almak ve geliştirilen modelin geçerliliğini değerlendirmek amacıyla aşağıdaki hiyerarşik araştırma soruları yapılandırılmıştır:

- Ana Araştırma Sorusu (TAS): İşe alım süreçlerinde kullanılan yapay zeka algoritmalarındaki veri ve model kaynaklı yanlılığın tespiti ve azaltılması için etkin bir karar destek sistemi modeli nasıl geliştirilebilir?

Alt Araştırma Soruları:

- S1: Geleneksel işe alım verilerinde ve eğitilen yapay zeka modellerinde en sık karşılaşılan algoritmik önyargı türleri nelerdir ve bu önyargıların kaynakları bilimsel olarak nasıl sınıflandırılabilir?
- S2: Doğal Dil İşleme teknikleri kullanılarak, aday özgeçmişlerindeki cinsiyet, yaş veya etnik köken gibi demografik belirteçlerden kaynaklanan örtük önyargılar otomatik olarak nasıl tespit edilebilir?
- S3: Geliştirilen Adil İşe Alım KDS modeli, geleneksel algoritmalarla kıyaslandığında aday sıralama doğruluğunu korurken yanlılık metriklerini ne ölçüde iyileştirmektedir?
- S4: İşe alım uzmanlarının yapay zeka destekli kararlara güvenini artırmak ve şeffaflığı sağlamak için önerilen sistem mimarisi nasıl kurgulanmalıdır?

Bu yapı, hem literatür hem teknik hem de uygulama ve yönetim boyutlarını kapsayarak, tez çalışmasının bütüncül bir araştırma çerçevesi içinde yürütülmesini sağlamaktadır.

1.3 Çalışmanın Kapsamı ve Sınırlılıklar

Bu tez, “İşe alım süreçlerinde yapay zekaya dayalı bir karar destek sistemi modeli kullanarak yanlılığın azaltılması ” ana teması etrafında, belirli metodolojik ve uygulama kapsamaları dahilinde yürütülmüştür.

1.3.1 Kapsam

- **Odak Alanı:** Çalışmanın ana odağı, İnsan Kaynakları Yönetimi süreçlerinden yalnızca YZ destekli işe alım ve aday değerlendirme aşamalarına yöneliktir. Özellikle, aday özgeçmişlerinin taranması ve nitelik/potansiyel skorlaması süreçlerinde ortaya çıkan algoritmik yanlılığın tespit ve azaltılması hedeflenmiştir.
- **Model Kapsamı:** Geliştirilen KDS modeli, Doğal Dil İşleme teknikleriyle metin tabanlı verilerdeki (özgeçmişler) demografik belirteçlerden kaynaklanan önyargıları hedef almakta ve bu önyargıların etkisini azaltmak üzere tasarlanmıştır.
- **Uygulama Alanı:** Modelin performansı, teknoloji ve yazılım sektöründen elde edilen anonimleştirilmiş bir veri seti üzerinden test edilmiştir.

1.3.2 Sınırlılıklar

- **Veri Sınırlılığı:** Modelin başarısı, eğitildiği tarihsel verilerin niteliği ve miktarı ile sınırlıdır. Veri setindeki orijinal yanlılık yoğunluğu, modelin yanlılık azaltma kapasitesini doğrudan etkilemektedir.
- **Süreç Sınırlılığı:** Araştırma, işe alım sürecinin yalnızca ön eleme ve sıralama aşamalarına odaklanmıştır. Mülakat, kişilik testleri veya işe alım sonrası

performans gibi ileri aşamalar tezin kapsamı dışındadır.

- Hukuki Sınırlılık: Model, yanlışlık azaltma metriklerine odaklanmakta; KVKK ve GDPR gibi veri koruma düzenlemeleriyle tam uyumluluğun sağlanması ayrı bir mühendislik ve hukuk danışmanlığı gerektiren süreçtir.
- Genelleştirilebilirlik: Bulgular, sınırlı sektör ve veri seti üzerinden elde edilmiştir. Farklı sektör ve ülkelerdeki kurumlar için modelin doğrudan genelleştirilebilirliği, ek test ve adaptasyonlara ihtiyaç duymaktadır.

Sonuç olarak, bu tez çalışması, YZ destekli işe alım süreçlerinde algoritmik yanlışlık probleminin tespit ve azaltılması için bilimsel, etik ve teknik temelli bütüncül bir çözüm sunmayı hedeflemekte; insan kaynakları yönetiminin dijital dönüşümünde adalet, şeffaflık ve fırsat eşitliği ilkelerini önceleyen bir yaklaşım ortaya koymaktadır.

1.4 Araştırmanın Metodolojik Yaklaşımı

Bu tez, tasarım bilimi araştırması (Design Science Research – DSR) metodolojik çerçevesini temel almaktadır. Hevner ve arkadaşlarının (2004) sistematize ettiği bu çerçeve, bilgi sistemleri alanındaki araştırmalarda hem gerçek dünya problemlerine çözüm üretmeyi hem de bu çözümlerin akademik katkısını güvence altına almayı hedeflemektedir. DSR metodolojisi, bir artefaktın (bu çalışmada KDS modeli) belirli bir problem alanını ele alacak şekilde tasarlanmasını, uygulanmasını ve değerlendirilmesini gerektirmektedir.

1.4.1 Araştırma Tasarımı

Çalışma, birbirine bağlı üç aşamada yapılandırılmıştır. Birinci aşamada problem tanımlama ve literatür sentezi gerçekleştirilmiştir: mevcut YZ tabanlı işe alım sistemlerinin sınırlılıkları, algoritmik önyargı mekanizmaları ve adillik metrikleri kapsamlı bir literatür taramasıyla incelenmiştir (Bölüm 2 ve 3). İkinci aşamada sistem geliştirme ve uygulama yapılmıştır: belirlenen boşlukları kapatmak amacıyla LLM entegrasyonu, NLP ön işleme ve post-processing adillik optimizasyonunu birleştiren

özgün bir KDS mimarisi tasarlanmış ve kodlanmıştır (Bölüm 4). Üçüncü aşamada değerlendirme ve geçerlilik analizi yürütülmüştür: geliştirilen sistem, nicel performans metrikleri ve adillik metrikleri üzerinden değerlendirilmiş; kullanıcı deneyimi yarı yapılandırılmış mülakatlarla değerlendirilmiştir (Bölüm 5).

1.4.2 Nicel ve Nitel Veri Analizi

Bu araştırma, nicel ve nitel yaklaşımları bir arada kullanan karma yöntem (mixed-methods) perspektifini benimsemektedir. Nicel boyut, model performansı ve adillik metriklerinin istatistiksel analizi üzerinden yürütülmüştür: Accuracy, Precision, Recall, F1-Score, DPD (Demografik Eşitlik Farkı), EOD (Eşit Fırsat Farkı), AUC ve SUS (Sistem Kullanılabilirlik Ölçeği) değerleri hesaplanmış ve tablolarda sunulmuştur. Nitel boyut ise İK uzmanlarıyla gerçekleştirilen yarı yapılandırılmış mülakatların içerik analizi ve kullanılabilirlik testlerinin gözlem notları üzerinden yürütülmüştür.

Bu karma yaklaşım, araştırma bulgularının sadece sayısal metriklerle sınırlı kalmayıp, gerçek kullanıcı deneyimi ve algılarıyla da desteklenmesini sağlamaktadır. Nicel bulgular sistemin ne ölçüde adil çalıştığını söylerken, nitel bulgular bu adilliğin kullanıcılar tarafından nasıl deneyimlendiğini ve yorumlandığını ortaya koymaktadır.

1.5 Kurumsal Temeller


Bu bölüm, yüksek lisans tez çalışmasının temelini oluşturan kavramsal ve teorik çerçeveyi sunmaktadır. Çalışmanın ana konusu olan Yapay Zeka (YZ) destekli işe alım süreçlerindeki algoritmik yanlılık problemini derinlemesine analiz edebilmek ve önerilen Karar Destek Sistemi (KDS) modelinin bilimsel zeminini oluşturabilmek amacıyla; İnsan Kaynakları Yönetimi (İKY), işe alım süreçleri, yapay zeka teknolojileri, YZ'nin İK süreçlerindeki uygulamaları ve YZ etiği gibi kritik konular literatür ışığında incelenmiştir.

1.5.1 İnsan Kaynakları Yönetimi ve İşe Alım Süreçleri

İnsan Kaynakları Yönetimi (İKY), çağdaş organizasyonların sürdürülebilir rekabet

avantajı elde etmesinde temel rol oynayan, çok disiplinli bir yönetim alanı olarak öne çıkmaktadır. Bu alan, kurumların mevcut ve gelecekteki stratejik hedeflerine ulaşabilmeleri için nitelikli işgücünün etkin bir şekilde planlanması, organizasyona çekilmesi, geliştirilmesi ve elde tutulmasına yönelik sistematik süreçleri kapsamaktadır. İKY'nin temel fonksiyonlarından biri olan işe alım süreci ise, organizasyonun başarısını doğrudan etkileyen kritik bir aşamadır. Bu süreçte amaç, kurumun kültürüne ve pozisyonun gerekliliklerine en uygun adayların belirlenerek istihdam edilmesidir.

Geleneksel işe alım yöntemleri incelendiğinde, genellikle ilan verme, başvuru toplama, özgeçmiş tarama, mülakat ve değerlendirme aşamalarını içeren çok adımlı ve çoğu zaman manuel süreçler olduğu görülmektedir. Bu yöntemler, insan emeğine ve uzmanlığına büyük ölçüde bağımlıdır; dolayısıyla süreçler hem zaman hem de maliyet açısından yüksek kaynak gerektirir. Ayrıca, işe alım sürecini yürüten kişilerin sahip olduğu deneyim, bilgi birikimi ve bireysel değerler, aday değerlendirmelerinde bilişsel önyargıların ve sübjektif yorumların ortaya çıkmasına zemin hazırlayabilmektedir. Örneğin, adayların cinsiyet, yaş, eğitim geçmişi veya önceki iş deneyimleri gibi objektif olmayan kriterlere dayalı olarak değerlendirilmesi, hatalı işe alım kararlarının alınmasına ve organizasyonel verimliliğin olumsuz etkilenmesine yol açabilmektedir. Sonuç olarak, insan faktöründen kaynaklanan bu tür öznellikler, geleneksel işe alım süreçlerinde hata payını artıran önemli bir unsur olarak karşımıza çıkmaktadır.



Şekil 1.1 Geleneksel işe alım süreçleri

İşe Alım Sürecinde Karşılaşılan Zorluklar:

Geleneksel işe alım süreçlerinde karşılaşılan temel zorluklar arasında; aday havuzunun büyüklüğü nedeniyle yetersiz ön eleme, standartlaştırılmamış mülakatlar, işe alım kararlarında yaşanan sübjektiflik ve en önemlisi, kararların bilinçli ya da bilinçsiz önyargılardan (cinsiyet, yaş, ırk vb.) etkilenmesidir. Dijitalleşme ile birlikte bu zorlukların bir kısmı otomatize edilse de, bu kez de algoritmik yanlılık riski ortaya çıkmıştır.

İşe alım sürecindeki zorluklar daha sistematik biçimde ele alındığında, beş temel boyut ön plana çıkmaktadır. Hacim ve zaman baskısı boyutunda, büyük ölçekli bir işe alım kampanyasında İK departmanları yüzlerce hatta binlerce başvuruyu kısa sürede değerlendirmek zorundadır. Araştırmalar, bir İK uzmanının ortalama olarak bir özgeçmişe yalnızca 6-7 saniye ayırdığını göstermektedir. Bu zaman kısıtı, değerlendirme kalitesini olumsuz etkilemekte ve sistematik hata (biases) için zemin hazırlamaktadır.

Standartlaşma eksikliği boyutunda, farklı İK uzmanları aynı özgeçmiş farklı biçimde değerlendirmektedir (inter-rater unreliability). Yapılandırılmamış mülakatlarda bu tutarsızlık daha belirginleşmektedir. Sosyal yargılama boyutunda ise araştırmalar, işe alım kararlarının çoğunlukla ilk birkaç dakika içinde şekillendiğini ve ardından bilinçdışı önyargıları (halo etkisi, benzer-bana yönelimi) doğrulayacak kanıt arayışına girildiğini ortaya koymaktadır.

Aday deneyimi (candidate experience) boyutunda, uzun ve opak işe alım süreçleri aday memnuniyetini düşürmekte; bu durum kurumun işveren markasını olumsuz etkilemektedir. Veri odaklı karar verme zorluğu boyutunda ise geleneksel işe alım süreçleri sistematik veri üretmemekte; bu da hangi özelliklerin gerçek anlamda iş başarısını öngördüğünü analiz etmeyi güçleştirmektedir.

İşe Alımda Dijital Dönüşüm: Tarihsel Perspektif

İşe alım süreçlerinin dijitalleşmesi, birbirini izleyen üç temel dalga halinde gerçekleşmiştir. 1990'lı yıllarda başlayan birinci dalga olan web tabanlı iş ilanı platformlarının ortaya çıkmasıyla (1994'te faaliyete geçen Monster.com ve 1999'da kurulan Kariyer.net gibi) işe alım süreçleri coğrafi sınırları aşmış ve aday havuzları

önemli ölçüde genişlemiştir (Monster.com 2026, Kariyer.net 2024).

2000'li yıllarda gerçekleşen ikinci dalga olan Başvuru Takip Sistemleri'nin yaygınlaşmasıyla İK departmanları, başvuru süreçlerini standardize etmiş, takip etmiş ve raporlamayı otomatize etmiştir. ATS sistemleri, anahtar kelime tabanlı filtreleme ile başvuru hacmini yönetilebilir boyutlara indirmiş; ancak bu süreçte kötü formatlı özgeçmişlere sahip nitelikli adayları da elemek gibi istenmeyen sonuçlar doğurmuştur. 2010'lu yıllardan itibaren süregelen üçüncü dalga olan yapay zeka entegrasyonu, makine öğrenmesi algoritmaları ve doğal dil işleme, başvuru havuzunu analiz etme ve aday eşleştirme kapasitesini dramatik biçimde artırmıştır. Bu üçüncü dalga'nın karakteristik özelliği; önceki sistemlerin sınırını belirleyen kural tabanlı yapıdan, geçmiş verilerden öğrenen uyarlanabilir modellemelere geçiştir. Bu geçiş ise algoritmik önyargı sorununu sistematik bir risk olarak gündeme taşımaktadır.

1.6 Yapay Zeka Teknolojileri

1.6.1 Yapay Zeka ve Makine Öğrenmesi Kavramları

Yapay Zeka (YZ), bilgisayar sistemlerinin insan zekasına özgü algılama, öğrenme, karar verme ve problem çözme gibi yetenekleri taklit etme çabasıdır. Makine Öğrenmesi (MÖ) ise YZ'nin bir alt kümesi olup, sistemlerin açıkça programlanmadan, verilerden öğrenerek performanslarını artırmasına olanak tanır. Özellikle regresyon, sınıflandırma ve kümeleme algoritmaları, İK ve işe alım analitiğinde yaygın olarak kullanılmaktadır.

Doğal Dil İşleme (NLP) ve Büyük Dil Modelleri (LLM)

Doğal Dil İşleme (NLP), bilgisayarların insan dilini anlamasını ve üretmesini sağlayan bir YZ alanıdır. İşe alım süreçlerinde NLP; özgeçmiş metinlerinin analiz edilmesi, anahtar kelime çıkarımı ve aday-pozisyon eşleştirmesi gibi kritik roller üstlenir. Büyük Dil Modelleri (LLM), muazzam veri setleri üzerinde eğitilmiş, karmaşık dil görevlerini yerine getirebilen en gelişmiş NLP teknolojileridir ve bu tezdeki metin tabanlı önyargı tespiti için temel teşkil etmektedir.

1.6.2 Makine Öğrenmesi Modelleri: Lojistik Regresyon ve Karar Ağaçları

İşe alım uygulamalarında en yaygın kullanılan makine öğrenmesi algoritmaları incelendiğinde, denetimli öğrenme sınıfının ön plana çıktığı görülmektedir. Lojistik Regresyon, ikili sınıflandırma görevlerinde (örneğin işe al/eleme) temel model olarak sıklıkla tercih edilmektedir; yorumlanabilirliği yüksek, hesaplama maliyeti düşük ve katsayılar üzerinden anlamlı yorumlar türetilbilir olması bu tercihin başlıca nedenleridir. Rassal Orman (Random Forest) ise doğrusal olmayan ilişkileri modelleyen, özellik önemliliği (feature importance) çıktıları sayesinde hangi özgeçmiş bileşeninin kararı en çok etkilediğini açıklayan güçlü bir sınıflandırıcıdır. Gradyan Artırma Yöntemleri (XGBoost, LightGBM) ise yüksek tahmin doğruluğu ve hız dengesini sağlayan, tablo yapılandırılmış verilerinde özellikle güçlü sonuçlar veren topluluk öğrenme modellerini temsil etmektedir.

Bu çalışmada ise söz konusu geleneksel makine öğrenmesi yaklaşımlarından farklı olarak, yapılandırılmamış metin verilerini (özgeçmişler) yorumlamak için büyük ölçekte dil anlayışı gerektiren bir görev tanımlanmıştır. Bu nedenle temel sınıflandırıcı olarak LLM tabanlı çıkarım benimsenmiş, yanlışlık azaltma aşamasında ise klasik adillik metrikleri üzerinde eşik optimizasyonu gerçekleştirilmiştir. Bu hibrit yaklaşım; NLP'nin anlama kapasitesini, istatistiksel adillik güvencesiyle birleştirmektedir.

1.7 İşe Alım Süreçlerinde Yapay Zeka Kullanımı

1.7.1 Özgeçmiş (CV) Tarama ve Eşleştirme Sistemler

YZ tabanlı CV tarama sistemleri, geleneksel yöntemlere göre çok daha hızlı bir şekilde binlerce özgeçmiş analiz ederek pozisyon gerekliliklerine göre sıralama yapar. Ancak, bu sistemler Önceden Eğitilmiş Büyük Dil Modellerinden (LLM) kaynaklanan yanlışlıkları devralarak, işe alım kararlarında algoritmik yanlışlık (output bias) üretebilirler (örneğin erkek adayların baskın olduğu bir sektörde kadın adayları eleme eğilimi) (Mousavian vd. 2025, Rao vd. 2025).

1.7.2 Aday Mülakatlarında Yapay Zeka (Chatbotlar ve Duygu Analizi)

Chatbotlar, ilk aşama mülakatları yürüterek aday deneyimini iyileştirir ve İK uzmanlarının üzerindeki yükü azaltır. Duygu analizi teknolojileri ise video mülakatlar sırasında adayın yüz ifadeleri, ses tonu ve vücut dilini analiz ederek performansı skorlamaya çalışır. Bu sistemlerde, kültürel farklılıklar veya dış görünüme dair yanlılık riski yüksek olduğundan, etik değerlendirme zorunludur (Rao vd. 2025).

Yetenek Yönetimi ve Tahminleme

YZ, işe alımın ötesinde, mevcut çalışanların performansını ve potansiyelini tahmin etmede de kullanılır. YZ, çalışan devir oranlarını (turnover) tahmin ederek İK stratejilerine yön verirken, aynı zamanda organizasyonel adalet ve kariyer gelişimi konularında da etik riskler barındırabilir.

İşe Alımda YZ Sistemlerinin Türkiye'deki Benimseme Süreci:

Türkiye'de işe alım teknolojilerinin benimsenmesi, uluslararası eğilimlere benzer bir ivme kazanmış olmakla birlikte, bazı yapısal farklılıklar dikkat çekmektedir. Kariyer.net, LinkedIn Türkiye ve işkur.gov.tr gibi platformlar aday havuzu veritabanları açısından büyük hacme ulaşmışken, YZ tabanlı özgeçmiş tarama ve aday sıralama araçları ağırlıklı olarak büyük ve çok uluslu şirketler tarafından kullanılmakta; KOBİ'lerin büyük çoğunluğu hâlâ manüel tarama yöntemlerine bağlı kalmaktadır.

Türkiye İstatistik Kurumu'nun (TÜİK) 2023 Hanehalkı Bilişim Teknolojileri Kullanım Araştırması verilerine göre, Türkiye'de 250 ve üzeri çalışana sahip işletmelerin yaklaşık %34'ü işe alım süreçlerinde en az bir dijital otomasyon aracı kullandığını bildirmektedir. Yapay zeka odaklı işe alım yazılımlarının benimsenmesinin ise bu oran içinde yalnızca küçük bir dilimi temsil ettiği tahmin edilmektedir. Bu görece düşük benimsenme oranının ardında birbirine bağlı birkaç etken yatmaktadır: yüksek lisans düzeyinde YZ uzmanı başına düşen işletme sayısı, KVKK uyumluluk belirsizlikleri ve sistemlerin Türkçe için alt optimal performans sergilemesi bu etkenler arasında sayılabilir.

Bu bağlam, çalışmanın pratik önem boyutunu doğrudan şekillendirmektedir. Geliştirilen sistemin Türkçe özgeçmiş içerikleriyle test edilmesi, yerel dil modeli performansını

değerlendirme ve iyileştirme fırsatı sunmaktadır. Ayrıca KVKK uyumluluğunun mimari tasarım kararlarına nasıl entegre edileceğine dair somut bir model önerisi, Türkiye'deki potansiyel uygulayıcılar için yerli bağlam literatürüne önemli bir katkı sağlamaktadır.

1.8 Yapay Zeka Destekli İşe Alımda Etik ve Hukuki Boyut

1.8.1 Algoritmik Önyargı (Bias) ve Adil Yapay Zeka

Algoritmik önyargı, YZ sistemlerinin eğitim verilerindeki veya model tasarımındaki sistematik hatalar nedeniyle belirli bir gruba karşı haksız veya ayrımcı sonuçlar üretmesidir. Adil Yapay Zeka (Fair AI) kavramı, bu önyargıların tespit edilmesi, ölçülmesi ve matematiksel veya algoritmik yöntemlerle (in-processing, pre-processing, post-processing) azaltılmasını hedefler (Ferrara 2024, Mujtaba ve Mahapatra 2024). Bu tez, bu alandaki bilimsel boşluğu doldurmaya odaklanmıştır.

Adillik Metriklerinin Sınıflandırılması

Algoritmik adalet literatüründe birbiriyle rekabet eden çok sayıda matematiksel adillik tanımı mevcuttur. Bu tanımların kapsamlı biçimde anlaşılması, bir YZ sisteminin "adil" mi yoksa "önyargılı" mı olduğuna dair değerlendirmelerin metodolojik temelini oluşturmaktadır (Mujtaba ve Mahapatra 2024).

Demografik Eşitlik (Demographic Parity): Korunan grup üyeliğinden bağımsız olarak pozitif karar oranının tüm gruplar için eşit olmasını gerektirir. Matematiksel olarak $P(\hat{Y}=1 | A=0) = P(\hat{Y}=1 | A=1)$ şeklinde ifade edilir; burada A korunan özelliği (cinsiyet gibi) temsil eder. Bu metrik, sonuç dağılımını temel alır ve gerçek nitelikleri göz ardı ettiği için eleştirilmektedir.

Eşit Fırsat (Equal Opportunity): Gerçekten nitelikli bireyler arasında (gerçek pozitif sınıf), doğru pozitif oranının (True Positive Rate) korunan gruba göre eşit olmasını öngörür. Bu metrik, nitelikli adayların haksız yere elenmemesini güvence altına aldığı için işe alım bağlamında demografik eşitlikten daha ilgili bir ölçüt olarak değerlendirilmektedir.

Kalibre Edilmiş Adillik (Calibrated Fairness): Model tahminlerinin korunan özellikten

bağımsız olarak gerçek başarı olasılıklarını doğru yansıtmayı gerektiğini savunur. Bu yaklaşım özellikle bireysel adillik perspektifinden güçlü bir kuramsal temele sahip olmakla birlikte, uygulamada ölçülmesi güçtür.

Chouldechova (2017) ve Kleinberg ve arkadaşlarının (2016) çalışmalarında matematiksel olarak kanıtlandığı üzere, bu adillik tanımları birbirleriyle çoğunlukla bağdaşmaz; başka bir deyişle, bir sistemi aynı anda tüm bu ölçütlere göre adil kılmak matematiksel olarak olanaksızdır. Bu tanımlar arasındaki seçim, teknik bir tercihten öte, kaçınılmaz biçimde etik ve değer odaklı bir karardır. Bu tez, Eşit Fırsat perspektifini esas almıştır; zira nitelikli bir adayın haksız yere elenmesini önlemek, oransal temsil sağlamaktan daha öncelikli bir etik hedef olarak değerlendirilmektedir.

1.8.2 Veri Mahremiyeti ve KVKK Uyumluluğu

YZ sistemleri büyük miktarda kişisel veri kullandığı için, veri mahremiyeti ve yasal uyumluluk hayati önem taşır. Türkiye'de **KVKK (Kişisel Verilerin Korunması Kanunu)** ve uluslararası alanda **GDPR (Genel Veri Koruma Tüzüğü)** gibi düzenlemeler, hassas kişisel verilerin (cinsiyet, etnik köken vb. dolaylı göstergeler dahil) işlenmesi konusunda sıkı kurallar koyar. Yanlılığı azaltma amaçlı dahi olsa, aday verilerinin anonimleştirilmesi, şeffaf süreçler sunulması ve aydınlatma yükümlülüğü, etik ve hukuki zorunluluklardır.

1.8.3 AB Yapay Zeka Yasası ve Türkiye'ye Etkileri

Avrupa Birliği'nin 2024 yılında yürürlüğe giren Yapay Zeka Yasası (EU AI Act), işe alım ve terfi kararlarında kullanılan YZ sistemlerini doğrudan "yüksek riskli" kategorisine almakta ve bu sistemlere kapsamlı yükümlülükler getirmektedir. Söz konusu yükümlülükler dört temel başlık altında sıralanabilir: (1) Şeffaflık ve açıklanabilirlik zorunluluğu, (2) Düzenli önyargı ve adillik denetimleri, (3) İnsan denetimi ve itiraz hakkı, (4) Teknik dokümantasyon ve uyum kayıtları.

Türkiye AB üyesi olmamakla birlikte, AB pazarına ihracat yapan veya AB'de faaliyeti bulunan Türk şirketler bu yasanın kapsam ve etkisinden doğrudan etkilenecektir.

Türkiye'nin KVKK mevzuatı yapısal olarak GDPR ile uyumlu olmakla birlikte, algoritmik karar alma sistemlerine özgü düzenlemeler henüz gelişme aşamasındadır. Kişisel Verileri Koruma Kurumu'nun (KVKK) 2023 yılında yayımladığı rehber belgeler, otomatik kararların ilgili kişilere açıklanmasını ve itiraz mekanizmalarının oluşturulmasını ön görmektedir. Bu düzenleyici eğilim, şeffaf ve açıklanabilir YZ sistemlerine yapılan yatırımların yalnızca etik değil, yakın vadede hukuki zorunluluğa dönüşeceğini açıkça ortaya koymaktadır.

1.9 Dünyada Yapay Zeka Destekli İşe Alım Uygulamaları

Yapay zeka destekli işe alım sistemleri, küresel ölçekte pek çok şirket tarafından benimsenmiş ve yaygın uygulama örnekleri ortaya çıkmıştır. Bu bölümde, sektördeki önde gelen YZ tabanlı işe alım platformları ve uygulamaları incelenerek mevcut teknolojilerin gelişimi değerlendirilmektedir.

1.9.1 Öne Çıkan Platform ve Araçlar

Günümüzde işe alım süreçlerinde yapay zeka kullanımı hızla artmakta olup bu alanda birçok özel platform ve araç geliştirilmiştir. HireVue, video mülakat analizini duygu, ton ve mimik gibi görsel-işitsel verilerle değerlendirirken; Pymetrics, nöroloji tabanlı oyunlaştırma testleri aracılığıyla aday yetkinliklerini ölçmektedir. LinkedIn Talent Insights ise veri analitiği ile iş gücü piyasası trendlerini raporlayarak kurumların stratejik işe alım kararlarını desteklemektedir. Workday ve SAP SuccessFactors gibi kurumsal insan kaynakları yönetim platformları da YZ modüllerini işe alım süreçlerine entegre etmiş; özgeçmiş eşleştirme, aday sıralama ve başarı tahmini gibi işlevleri otomatikleştirmiştir.

Başarı Örnekleri ve Karşılaşılan Sorunlar

Unilever, YZ destekli işe alım sürecine geçişiyle yıllık 100.000'i aşkın başvuruyu otomatize ederek işe alım süresini %75 kısaltmış ve aday havuzunun çeşitliliğini önemli ölçüde artırmıştır (Daugherty ve Wilson 2018). Buna karşın Amazon'un dahili özgeçmiş tarama sistemi, eğitim verilerindeki tarihsel yanlılık nedeniyle kadın adayları sistematik

biçimde dezavantajlı konuma düşürmüş; bu nedenle sistem 2018 yılında hizmetten kaldırılmıştır (Dastin 2018). Bu örnek, YZ tabanlı işe alım sistemlerinde algoritmik önyargının ne denli ciddi bir sorun oluşturabileceğini açıkça ortaya koymaktadır. IBM Watson Recruitment ise adayların kurumsal uyum ve uzun vadeli başarı potansiyelini tahmin etmek amacıyla büyük veri analitiğini kullanmakta; ancak yorumlanabilirlik (explainability) konusundaki sınırlılıkları eleştirilerin odağında yer almaktadır.

Türkiye'deki Uygulama Örnekleri:

Türkiye'de de YZ destekli işe alım uygulamalarına yönelik ilgi giderek artmaktadır. Kariyer.net ve LinkedIn Türkiye, yapay zeka tabanlı eşleştirme algoritmalarını iş ilanı ve aday önerileri için aktif şekilde kullanmaktadır. Büyük ölçekli Türk şirketleri olan Sabancı Holding, Koç Holding ve Türkiye İş Bankası, insan kaynakları süreçlerinde YZ destekli ön eleme sistemlerini hayata geçirmiştir. Akademik çevrelerde ise YZ destekli işe alımın KVKK kapsamında değerlendirilmesi ve etik boyutları giderek daha fazla araştırma konusu haline gelmektedir. Bu bağlamda, mevcut çalışmanın ulusal bağlama yönelik katkısı önem kazanmaktadır.

2. LİTERATÜR BİLGİLERİ

2.1 Yurt İçinde Yapılan Çalışmalar

Bu bölüm, Türkiye'deki işe alım süreçlerinde dijitalleşme ve yapay zeka uygulamalarına ilişkin akademik alanyazını analitik bir perspektifle incelemektedir. Türkiye işgücü piyasası, Kamu Personel Seçme Sınavı (KPSS) gibi merkezi sınavların kamuda işe alımlar için belirleyici rol oynaması ve Türkiye İş Kurumu'nun (İŞKUR) istihdamda üstlendiği aracılık görevi gibi kendine özgü dinamiklere sahiptir. Dijital teknolojilerin benimsenme süreci, Türk şirketleri ve kamu kurumlarında devam etmekte olup, bu dönüşümün etkilerini, adayların teknolojiye yönelik tepkilerini ve yerel sorunlara özgü çözüm önerilerini analiz eden akademik çalışmalar, bu alandaki bilgi birikiminin temelini oluşturmaktadır. Bu bağlamda, Türkiye'deki üniversiteler tarafından yürütülen araştırmalar, dijital işe alımın yerel bağlamdaki kabulünü, verimliliğini ve potansiyelini anlamak için kritik bir zemin sunmaktadır (Çeri ve Doğan 2025, Tiftik 2021).

2.1.1 Aday Perspektifi, Kabul Modelleri ve Duygusal Tepkiler

Türkiye'deki aday perspektifini ele alan çalışmalar, iki ana ekseninde yoğunlaşmaktadır: bilişsel kabul ve duyuşsal tepkiler. Orta Doğu Teknik Üniversitesi'nde yapılan bir çalışma, Genişletilmiş Birleşik Teknoloji Kabul ve Kullanım Teorisi (UTAUT2) modeli üzerinden adayların teknolojiye yönelik rasyonel ve bilişsel kabul süreçlerini **adalet (fairness)**, **güven (trust)** ve **mahremiyet endişeleri (privacy concerns)** gibi faktörler temelinde analiz ederken; İzmir Kâtip Çelebi Üniversitesi'ndeki araştırma ise bu sürecin **mülakat kaygısı (interview anxiety)** gibi duyuşsal ve psikolojik boyutlarına odaklanmaktadır. Bu iki çalışma birlikte ele alındığında, Türkiye'deki adayların yapay zekaya yalnızca bir "araç" olarak değil, aynı zamanda duygusal ve psikolojik etkileri olan bir "deneyim" olarak yaklaştığı görülmektedir.

ODTÜ'de gerçekleştirilen tez çalışması, adayların algoritmik karar alma süreçlerinin adil, şeffaf ve kişisel verilerini koruyacak şekilde işlediğine inanma ihtiyacını ortaya koymaktadır. Bu unsurların yanı sıra, sistemin adaylarla etkili bir **iki yönlü iletişim (two-way communication)** kurma kapasitesi de katılım niyetini olumlu yönde etkileyen bir diğer kritik faktör olarak öne çıkmaktadır.

Adayların teknolojiye yönelik bilişsel kabullerinin yanı sıra duyuşsal tepkilerini inceleyen İzmir Kâtip Çelebi Üniversitesi'ndeki deneysel çalışma ise, yapay zeka aracılı asenkron video mülakatlar, teknoloji aracılı senkron video mülakatlar ve geleneksel yüz yüze mülakatlar arasındaki psikolojik farkları karşılaştırmıştır. Araştırmanın bulguları, yüz yüze mülakatlarda davranışsal kaygı arttıkça performansın düştüğünü; buna karşın, yapay zeka aracılı mülakatlarda ise kaygı arttıkça **objektif performansın yükseldiği** yönünde paradoksal bir ilişki olduğunu ortaya koymuştur. Nitel bulgular ise adayların yapay zeka aracılı mülakatları ek düşünme süresi ve cevap esnekliği sağlaması nedeniyle olumlu bulduğunu, ancak insan etkileşiminin ve geri bildirimin eksikliğini hissettiklerini göstermektedir. Bu bulgular, Türkiye'deki adayların dijital işe alım araçlarını sadece fayda odaklı değil, aynı zamanda adalet, güven ve duygusal konfor gibi psikolojik faktörler üzerinden de değerlendirdiğini kanıtlamaktadır.

Aday perspektifine odaklanan bu çalışmalar, teknolojinin kabul edilebilirliğinin psikolojik temellerini ortaya koyarken, bir sonraki bölümde incelenecek olan kurumsal verimlilik analizleri, bu teknolojilerin benimsenmesinin rasyonel ve ekonomik gerekçelerini sunmaktadır. Bu iki yaklaşım, dijitalleşmenin başarısı için hem insan odaklı hem de performans odaklı stratejilerin entegrasyonunun zorunlu olduğunu göstermektedir.

Kurumsal Etkinlik ve Verimlilik Analizleri

Dijitalleşmenin kurumsal verimliliğe etkisini inceleyen yerel çalışmalar, genel süreç optimizasyonundan spesifik teknoloji uygulamalarına doğru bir derinleşme göstermektedir. Altınbaş Üniversitesi'nde yapılan araştırma, dijital işe alımın genel olarak **maliyet (cost-effectiveness)** ve **zaman etkinliği (time-effectiveness)** gibi makro düzeydeki faydalarını ampirik olarak kanıtlarken, İstanbul Üniversitesi-Cerrahpaşa'da yürütülen çalışma ise bu verimliliğin **Büyük Dil Modelleri (Large Language Models - LLM'ler)** gibi ileri teknolojiler aracılığıyla **Başvuru Takip Sistemi (Applicant Tracking System - ATS) uyumluluk puanları** gibi mikro düzeydeki performans metriklerine nasıl yansıdığını spesifik olarak ortaya koymaktadır.

Altınbaş Üniversitesi'ndeki çalışma, dijital işe alım platformlarının kullanımının, geleneksel yöntemlere kıyasla ilan maliyetlerini düşürdüğünü, başvuru havuzunu

geniřlettiđini ve ön eleme süreçlerini otomatikleřtirerek insan kaynakları profesyonellerinin harcadıđı zamanı azalttıđını dođrulamıřtır. Arařtırmalar, dijital platformların daha geniř ve çeřitli bir kitleye ulaşması sayesinde **başvuru sahiplerinin kalitesini (quality of applicants)** artırdıđını göstermektedir.

İstanbul Üniversitesi-Cerrahpařa'da yürütölen alıřma ise LLM tabanlı sistemlerin, özgemiřleri iř tanımlarına göre dinamik olarak uyarlayarak ATS uyumluluk puanlarını önemli ölçüde artırdıđını ortaya koymuřtur. Anahtar kelime eřleřmesi ve bağlamsal alaka gibi metriklerde elde edilen yüksek skorlar, adayların ATS filtrelerini geme olasılıđını yükseltmekte ve iřverenlerin en uygun adaylara daha hızlı ulaşmasını sađlamaktadır. Bununla birlikte, aynı alıřma, deneyim uygunluđu gibi karmařık insan yargısı gerektiren alanlarda LLM'lerin performansının sınırlı kaldıđını ve insan denetiminin kritik rolünü sürdürdüđünü vurgulamaktadır. Bu bulgular, dijitalleřmenin kurumsal verimliliđi artırmadaki rolünü teyit ederken, teknolojinin insan uzmanlıđıyla bir arada kullanıldıđı hibrit modellere olan ihtiyacı da ortaya koymaktadır.

2.1.2 Kamu Sektöründe İře Alım ve Blokzincir Temelli Çözüm Önerileri

Türkiye'deki kamu sektöründe iře alım süreçleri, belge sahteciliđi ve yüksek maliyetler gibi kendine has yapısal zorluklar barındırmaktadır. İřkenderun Teknik Üniversitesi'nde yapılan bir tez alıřması, bu alandaki temel sorunları analiz ederek blokzincir teknolojisine dayalı yeniliki bir çözüm modeli önermektedir. Arařtırmanın odaklandıđı başlıca sorunlar, **belge sahteciliđi (örneğin, sahte diploma)** ve KPSS sisteminin getirdiđi yüksek organizasyonel maliyetlerdir. Adayların sunduđu diploma, sertifika ve adli sicil kaydı gibi belgelerin dođruluđunu teyit etme süreci, hem kurumlar için zaman alıcı hem de sahteciliđe açık bir yapıdadır. Aynı zamanda, ÖSYM tarafından yürütölen KPSS sınavlarının organizasyonu ve deđerlendirmesi, devlet bütesi için önemli bir maliyet kalemi oluřturmaktadır.

Bu zorluklara çözüm olarak sunulan blokzincir tabanlı iře alım modeli, **Hyperledger** mimarisini kullanarak daha **ekonomik**, **řeffaf** ve **adil** bir süreç tasarlamayı hedeflemektedir. Modelin temel iřleyiři ařađıdaki gibidir:

1. Veri Bütönlüđu ve Deđermezlik: Adayların diploma, transkript gibi kritik

belgeleri, yetkili kurumlar (üniversiteler, bakanlıklar) tarafından doğrulanarak dağıtık ve kriptografik yapıdaki blokzincire kaydedilir. Bu yapı, verilerin sonradan değiştirilmesini veya tahrif edilmesini imkânsız hale getirir.

2. Otomatik ve Güvenilir Doğrulama: İşverenler, adayın kimlik bilgilerine eriştiklerinde bu kayıtların doğruluğunu aracısız, anlık ve güvenilir bir şekilde teyit edebilir. Bu, hem belge sahteciliği riskini ortadan kaldırır hem de manuel doğrulama süreçlerindeki zaman ve maliyet kaybını önler.
3. Objektif Performans Geçmişi: Model, adayların önceki iş görüşmelerinde sergiledikleri performanslara ilişkin değerlendirme puanlarının da güvenli bir şekilde saklanmasını önerir. Bu özellik, işe alım uzmanlarının adayın geçmiş performansını objektif bir veri olarak görerek daha adil bir değerlendirme yapmasına olanak tanır.

Bu sistem, hem kamu kurumlarının KPSS gibi merkezi sınavlara olan bağımlılığını azaltma potansiyeli taşımakta hem de özel sektör için güvenilir bir aday doğrulama altyapısı sunmaktadır.

Yurt içinde gerçekleştirilen bu çalışmalar, yapay zeka ve dijitalleşmenin işe alım süreçlerine entegrasyonunda özellikle aday kabul modelleri, duygusal tepkiler ve kamu sektörüne özgü yapısal sorunlara odaklandığını göstermektedir. Bu bulguların daha geniş bir perspektife oturtulması için küresel trendleri ve uluslararası alanyazındaki teknolojik ve etik tartışmaları incelemek bir sonraki adımı oluşturmaktadır.

2.1.3 Türkiye'deki Araştırmaların Metodolojik Değerlendirmesi

Yukarıda incelenen yurt içi çalışmalar metodolojik açıdan değerlendirildiğinde, bazı ortak örüntüler ve sınırlılıklar dikkat çekmektedir. İncelenen çalışmaların büyük çoğunluğu kesitsel tasarım ve anket metodolojisi benimsemektedir; bu yapı, nedensellik ilişkisi kurmak yerine korelasyonları tespit etmeye elverişlidir. Yüz yüze mülakat ile YZ destekli mülakat arasındaki kaygı farklılıklarını inceleyen İzmir Kâtip Çelebi Üniversitesi çalışması deneysel bir tasarım benimsemiş olup bu özelliğiyle yurt içi literatürdeki metodolojik bir istisna niteliği taşımaktadır.

Örneklem boyutu açısından ise çalışmalar genellikle üniversite öğrencileri veya belirli sektördeki çalışanlar gibi kolayda erişilebilir örneklemlemlerle sınırlı kalmaktadır; bu durum dış geçerlilik açısından bir kısıtlılık oluşturmaktadır. Uzunlamasına tasarımlara (longitudinal studies) ilişkin önemli bir boşluk da göze çarpmaktadır: Türkiye'de YZ tabanlı işe alım araçlarını kullanan adayların tutum ve davranışlarını zaman içinde takip eden çalışma sayısı son derece azdır. Son olarak, belirli sektöre özgü çalışmalar yetersiz kalmaktadır; özellikle finans, sağlık ve üretim sektörlerinde işe alım YZ uygulamalarını inceleyen araştırmalar henüz gelişme aşamasındadır.

2.2 Yurt Dışında Yapılan Çalışmalar

Dijital işe alım teknolojileri ve yapay zeka uygulamaları, uluslararası akademik literatürde daha köklü bir geçmişe sahiptir. Küresel ölçekte faaliyet gösteren şirketlerin bu teknolojileri benimseme pratikleri, teknolojik inovasyonların evrimini ve beraberinde getirdikleri zorlukları anlamak için zengin bir vaka havuzu sunmaktadır. Bu nedenle, uluslararası alanyazını incelemek, küresel trendleri, gelişmiş dijital araçları ve bu araçların kullanımından doğan algoritmik önyargı gibi etik tartışmaları anlamak açısından kritik bir önem arz eder. Bu çalışmalar, teknolojinin sadece bir verimlilik aracı olmadığını, aynı zamanda adalet ve eşitlik gibi temel değerler üzerinde de derin etkileri olabileceğini ortaya koymaktadır.

2.2.1 Dijital İşe Alım Araçları ve Uygulamaları

Uluslararası literatür, yetenekleri belirleme, seçme ve elde tutma süreçlerini dönüştüren çok çeşitli dijital araçları detaylandırmaktadır. Bu araçlar, işe alım sürecinin farklı aşamalarında verimliliği artırmak ve daha objektif kararlar alınmasını sağlamak amacıyla kullanılmaktadır (Founès ve Boudabbous 2025). Başlıca dijital işe alım araçları ve uluslararası örnekleri aşağıda özetlenmiştir:

- Sosyal Ağlar: Profesyonel ağlar, özellikle LinkedIn, yetenekleri belirlemek için temel bir kaynak haline gelmiştir. Şirketler, bu platformları sadece iş ilanı yayınlamak için değil, aynı zamanda pasif adayları (aktif olarak iş aramayan

ancak fırsatlara açık olan profesyonelleri) tespit etmek ve onlarla doğrudan iletişim kurmak için de kullanılmaktadır.

- Ciddi Oyunlar (Serious Games): Oyunlaştırma, adayların problem çözme, karar verme ve adaptasyon gibi becerilerini simüle edilmiş ortamlarda değerlendirmek için kullanılan yenilikçi bir yöntemdir. L'Oréal (Reveal), BNP Paribas (Ace Manager) ve Thales (Moonshield) gibi şirketler, bu yöntemi adayların yeteneklerini ve davranışsal özelliklerini test etmek için kullanmaktadır. Ciddi oyunların en büyük avantajlarından biri, adayları yaş, cinsiyet, köken veya fiziksel görünüm gibi demografik özelliklerden tamamen soyutlayarak, değerlendirmeyi yalnızca yetenek ve davranışsal performans üzerine kurmasıdır. Bu durum, sübjektif insan önyargılarının etkisini en aza indirerek daha objektif bir seçim süreci sunma potansiyeli taşır.
- Kitlese Çevrimiçi Açık Dersler (MOOCs): Udacity ve Coursera gibi platformlar, şirketler için birer yetenek havuzu işlevi görmektedir. Google, Amazon ve Microsoft gibi teknoloji devleri, bu platformlarla ortaklık kurarak kendi alanlarında en yüksek performansı gösteren öğrencileri tespit etmekte ve onlara iş teklifleri sunmaktadır.
- Sohbet Botları (Chatbots): Konuşma tabanlı yapay zeka ajanları, işe alım sürecinin ilk aşamalarında adaylarla etkileşim kurmak için kullanılır. Adayların sorularını yanıtlar, başvuru süreci hakkında bilgi verir ve temel tarama görevlerini yerine getirirler. Uluslararası alanda bilinen örnekler arasında TextRecruit tarafından geliştirilen Ari ve ABD ordusunun sanal işe alım görevlisi olarak kullandığı Sergeant Star bulunmaktadır.
- Büyük Veri ve Eşleştirme Sistemleri: Büyük veri analitiği, anlamsal analiz ve eşleştirme algoritmalarını kullanan sistemler, aday profilleri ile açık pozisyonları objektif kriterlere göre eşleştirir. Randstad.tech gibi platformlar, bu teknolojiyi kullanarak işgücü piyasasındaki arz ve talebi daha verimli bir şekilde bir araya getirir ve işe alım sürecindeki öznelliği azaltır (Singh ve Sinha 2025).

Algoritmik Önyargı, Etik ve Adil Kullanım Sorunları

Yapay Zekanın işe alım süreçlerinde kullanımı, verimlilik ve objektiflik vaat etse de uluslararası literatür bu teknolojilerin önemli etik zorluklar ve önyargı riskleri taşıdığını vurgulamaktadır. Bu sorunların temelinde, algoritmaların eğitildiği verilerdeki mevcut toplumsal eşitsizlikleri öğrenmesi ve sistematik olarak yeniden üretmesi yatmaktadır (Chen 2023, Ferrara 2024, Krishnakumar 2019).

Algoritmik önyargının temelini "bias in, bias out" (önyargılı veri girişi, önyargılı sonuç) prensibi oluşturur. Bu prensip, bir yapay zeka modelinin, tarihsel toplumsal eşitsizlikleri, yapısal ayrımcılıkları veya insan kaynaklı önyargıları barındıran verilerle eğitilmesi durumunda, modelin bu önyargıları yalnızca yeniden üretmekle kalmayıp aynı zamanda sistematikleştirerek güçlendireceğini ifade eder. Bu durumun en bilinen örneklerinden biri, Amazon'un geçmiş on yıla ait özgeçmiş verileriyle eğittiği işe alım aracıdır. Teknoloji sektöründeki mevcut cinsiyet eşitsizliğini yansıtan bu veriler, algoritmanın erkek adayları sistematik olarak kayırmasına, "kadın" kelimesini içeren özgeçmişleri ise daha düşük puanlamasına neden olmuştur (Dastin 2018).

Literatür, işe alım süreçlerini etkileyen önyargıları **insan kaynaklı önyargılar** (bilinçdışı tutumlar, sistemsel politikalar) ve **algoritmik önyargılar** (modelin kendisinden kaynaklanan hatalar, örn. tahminsel önyargı) olarak iki ana kategoride inceler. Uluslararası alanyazın, bu riskleri azaltmak için çeşitli teknik ve stratejik çözümler önermektedir (Mujtaba ve Mahapatra 2024, Albaroudi vd. 2024, He vd. 2025):

1. Adil Veri Setleri Oluşturma: Önyargının temel kaynağı olan eğitim verilerini, az temsil edilen gruplara ait verileri artırarak veya önyargılı kalıpları ortadan kaldırarak dengelemek (Albaroudi vd. 2024).
2. Algoritmik Şeffaflığı Artırma: "Kara kutu" (black-box) olarak işleyen algoritmaların karar alma süreçlerini, Google'ın "What-If" gibi araçlarla anlaşılır kılarak potansiyel önyargıları tespit etmek (Hofeditz vd. 2022, Zhang vd. 2025, Cau ve Spano 2025).
3. Teknolojik Araçlarla Anonimleştirme: Aday profillerinden isim, fotoğraf gibi

demografik çıkarımlara yol açabilecek bilgileri kaldıran **Blendoor** gibi yazılımlar kullanarak değerlendirmeyi sadece yetkinliklere odaklamak.

4. Ayırıştırma Tekniği (Decoupling Technique): Algoritmanın, farklı demografik gruplar için farklı değerlendirme modelleri kullanmasını sağlayarak bir grubun tarihsel dezavantajlarının diğer grupların değerlendirmesini etkilemesini önlemek.

Uluslararası alanyazın, dijital işe alım araçlarının sunduğu verimlilik artışı ve maliyet avantajları ile bu sistemlerin doğasında bulunan algoritmik önyargı ve etik riskler arasındaki karmaşık dengeyi net bir şekilde ortaya koymaktadır (Ferrara 2024, Wilkens vd. 2025). Bu çift yönlü bulgular, teknolojinin dikkatli bir şekilde tasarlanması ve denetlenmesi gerektiğini göstererek, yerel ve küresel çalışmaların bütünsel bir değerlendirmesini yapmak üzere bir sonraki bölüme zemin hazırlamaktadır.


Uluslararası Düzenleyici Çerçeve Gelişmeleri

Algoritmik işe alım araçlarının doğurduğu etik kaygılar, uluslararası düzlemde önemli düzenleyici gelişmeleri tetiklemiştir. Bu gelişmeler, alandaki akademik tartışmalar için hem bağlam hem de doğrulama kaynağı işlevi görmektedir.

ABD'de New York Şehri, 2023 yılında işe alımda yapay zeka araçlarına yönelik dünya genelinde öncü yasal düzenlemelerden birini hayata geçirmiştir (Local Law 144). Bu düzenleme, otomatik istihdam karar araçlarını kullanan işverenlerin söz konusu araçları düzenli aralıklarla önyargı denetimine tabi tutmasını ve adaylara değerlendirme sürecinin nasıl işlediğini bildirmesini zorunlu kılmaktadır. AB Yapay Zeka Yasası ise işe alım sistemlerini "yüksek riskli" kategorisine alarak doğruluk, şeffaflık ve insan denetimi konularında kapsamlı yükümlülükler öngörmektedir. Bu yasal yükümlülükler; adillik metriklerinin nasıl tanımlanacağı, ölçüleceği ve raporlanacağına ilişkin teknik standartların belirsizliği nedeniyle henüz tartışmalı olmayı sürdürmektedir.

Bu düzenleyici baskı, akademik araştırmacıları ve yazılım geliştiricileri için yeni bir

alışma alanı açmaktadır: regölasyon uyumunu kolaylaştıran teknik araçlar ve metodolojiler. Bu tez, geliştirilen sistem mimarisi ve ölçüm çerçevesi aracılığıyla adillik metriklerini nasıl hesaplayacağını, raporlayacağını ve iyileştireceğini gösteren somut bir metodoloji sunarak bu gelişen alana doğrudan katkı sağlamaktadır.



Şekil 2.1 Algoritmik Yanlılık Kaynakları

2.3 Literatürün Değerlendirilmesi ve Mevcut Boşluklar

Bu bölümde, hem yurt içi hem de yurt dışı literatürden elde edilen bulgular sentezlenerek, işe alımda dijital dönüşüm ve yapay zeka konusundaki mevcut bilgi birikimi bütüncül bir bakış açısıyla özetlenmektedir. Yapılan incelemeler, her iki literatürde de verimlilik artışı ve süreç optimizasyonu gibi ortak temaların bulunduğunu, ancak odak noktaları ve yaklaşımlar açısından önemli farklılıkların olduğunu göstermektedir. Uluslararası literatür teknolojik araçların geliştirilmesi ve kurumsal uygulamalarına yoğunlaşırken, Türkiye'deki çalışmalar aday kabulü ve kamu sektörüne özgü yapısal sorunlara daha fazla eğilmektedir. Verimlilik arayışı ile etik kaygılar arasındaki temel gerilim, bu alandaki en önemli tartışma eksenini oluşturmaktadır. Bu sentez, literatürdeki mevcut boşlukları tespit ederek gelecek araştırmalar için bir yol haritası sunmayı amaçlamaktadır.

2.3.1 Genel Sentez ve Karşılaştırma

Aşağıdaki tablo, sağlanan kaynaklar temelinde yurt içinde ve yurt dışında yapılan çalışmaların ana odak alanlarını, metodolojilerini ve temel bulgularını karşılaştırmalı olarak sunmaktadır:

Çizelge 2.1 Yurt İçi ve Yurt Dışı Çalışmaların Karşılaştırmalı Özeti

Özellik	Yurt İçinde Yapılan Çalışmalar	Yurt Dışında Yapılan Çalışmalar
Ana Odak Alanları	Adayların teknoloji kabul modelleri (UTAUT2), adalet ve güven algıları; kamu sektörüne özgü sorunlar (KPSS maliyetleri, belge sahteciliği) ve adayların duygusal tepkileri (mülakat kaygısı) gibi konulara odaklanılmıştır.	L'Oréal'in Reveal oyunu veya Randstad.tech gibi spesifik kurumsal teknolojilerin uygulanması ve etkileri; algoritmik önyargı (Amazon'un işe alım aracı vakası) üzerine geniş ölçekli etik tartışmalar ve risk azaltma stratejileri üzerinde durulmuştur.
Metodoloji	Adaylarla yürütülen anketler, deneysel tasarımlar ve nicel analizler gibi ampirik yöntemler ağırlıklı olarak kullanılmıştır. Özellikle üniversite tezlerinde bu metodolojiler öne çıkmaktadır.	Küresel şirketler üzerinde yürütülen nitel çoklu vaka analizleri, önyargı azaltma stratejileri üzerine teorik çerçeve analizleri ve kapsamlı literatür taramaları gibi metodolojiler yaygındır.
Temel Bulgular	Türk adaylar için adalet ve güven algısının teknoloji kabulünde kritik olduğu; blokzincir teknolojisinin kamu sektöründeki sahtecilik ve	Teknolojinin, verimliliği artırırken aynı zamanda önemli önyargı riskleri taşıdığı ikili rolü vurgulanmıştır. Sosyal ağlar, ciddi oyunlar ve sohbet botları gibi e-işe

maliyet sorunlarına potansiyel alım araçlarının evrimi ve işlevleri bir çözüm sunduğu tespit detaylandırılmıştır. edilmiştir.

Yapılan literatür taraması, mevcut bilgi birikimindeki bazı kritik boşlukları ortaya koymuş ve gelecekteki araştırmalar için önemli yönelimler belirlemiştir. Bu boşluklar ve öneriler aşağıda sıralanmıştır:

- Hibrit Modellerin Etkisi: İÜ-Cerrahpaşa tezinin (Bölüm 2.1.2) de vurguladığı gibi, LLM'lerin deneyim uygunluğu gibi karmaşık insan yargısı gerektiren alanlarda yetersiz kalması, salt otomasyonun sınırlarını ortaya koymaktadır. Bu bulgu, yapay zeka verimliliği ile insan uzmanlığını birleştiren **hibrit modellerin** tasarlanması ve bu modellerin işe alım kararlarının kalitesi üzerindeki etkisinin ampirik olarak incelenmesi gerekliliğini doğurmaktadır.
- Türkiye Bağlamında Uzun Vadeli Etkiler: İncelenen yerel çalışmaların tamamı, teknolojinin kabulü veya anlık etkileri gibi kesitsel analizlere odaklanmaktadır. Yapay Zeka tabanlı işe alım kararlarının, işe alınan çalışanların **uzun vadeli performansı, iş tatmini, kuruma bağlılığı ve elde tutma (retention) oranları** üzerindeki etkilerini inceleyen boylamsal çalışmaların eksikliği önemli bir boşluktur.
- Yasal ve Etik Uyum (KVKK): Yapay Zeka ve LLM gibi veri yoğun teknolojilerin işe alım süreçlerinde kullanılması, Türkiye'nin **Kişisel Verilerin Korunması Kanunu (KVKK)** ile uyum konusunda önemli zorluklar barındırmaktadır. Birden fazla yerel tezde atıf yapılan bu konu, aday verilerinin toplanması, işlenmesi ve algoritmik kararların hukuki sorumluluğu gibi alanlarda derinlemesine araştırmaların yapılmasını gerektirmektedir.
- Aday Algılarının Evrimi: İzmir Kâtip Çelebi Üniversitesi'nin çalışması (Bölüm

2.1.1), adayların yapay zeka destekli mülakatlara yönelik mevcut kaygı düzeyini ortaya koymuştur. Ancak bu teknolojiler Türkiye'de yaygınlaştıkça, adayların algı, tutum ve kaygı düzeylerinin zaman içinde nasıl **evrildiğini** takip eden boylamsal çalışmalara ihtiyaç vardır.

- Açıklanabilir Yapay Zekâ (XAI) Uygulamaları: Literatürde hem yerel (Bölüm 2.1.1) hem de uluslararası (Bölüm 2.2.2) çalışmalarda vurgulanan "kara kutu" algoritmalarına yönelik güven ve adalet endişeleri, işe alımda **Açıklanabilir Yapay Zekâ (Explainable AI - XAI)** sistemlerine olan ihtiyacı ortaya koymaktadır. Bir adayın neden elendiğini veya seçildiğini mantıksal gerekçelerle açıklayabilen XAI modellerinin adaylar tarafından kabulünü ve adalet algısını ne ölçüde artırdığını inceleyen araştırmalar yapılmalıdır.

Mevcut Çalışmayı Konumlandırma

Yukarıda ortaya konan literatür boşlukları, bu tez çalışmasının özgün konumlanmasını doğrudan gerekçelendirmektedir. Mevcut araştırmaların büyük çoğunluğu işe alım süreçlerini soyut bir algoritmik analiz düzeyinde ele alırken, çalışmaların yalnızca küçük bir kısmı çalışan gerçek dünya verileriyle test edilmiş, uçtan uca çalışan bir sistem prototipi sunmaktadır. Bu tez; işe alım kararlarında LLM tabanlı analiz, post-processing yanlılık azaltma ve açıklanabilir yapay zeka ilkelerini bütünleştiren özgün bir mimari ortaya koymakta ve bu mimariyi sentetik ancak gerçekçi bir veri seti üzerinde deneysel olarak doğrulamaktadır.

Bu çalışmanın literatüre göre konumlanması üç temel boyutta özetlenebilir. Birincisi, metodolojik bütünleşme: Mevcut çalışmalar NLP, adillik metrikleri ve LLM entegrasyonunu ayrı ayrı ele almaktayken, bu tez söz konusu bileşenleri işlevsel bir karar destek sistemi mimarisinde birleştirmektedir. İkincisi, ölçülebilir adillik: Pek çok çalışma algoritmik önyargıyı kavramsal düzeyde tartışmakta, ancak ölçümleme için somut bir çerçeve sunmamaktadır. Bu çalışma, Demografik Eşitlik Farkı (DPD) ve Eşit Fırsat Farkı (EOD) gibi nicel adillik metriklerini sistematik biçimde uygulamaktadır. Üçüncüsü, yerel bağlam: Bu çalışma, YZ tabanlı işe alım araştırmalarını Türkiye'nin hukuki çerçevesi (KVKK) ve kurumsal pratikleri perspektifinden ele alan nadir çalışmalar arasında yer

almaktadır.

2.3.2 Kuramsal Çerçeve: Adil Yapay Zeka Prensipleri

Bu tezin metodolojik kararları, adil yapay zeka alanında yerleşik kuramsal çerçevelerle doğrudan örtüşmektedir. IEEE'nin "Ethically Aligned Design" belgesi ve AB Yapay Zeka Yasası (EU AI Act), yüksek riskli YZ sistemleri için şeffaflık, hesap verebilirlik ve önyargı denetimini zorunlu kılmaktadır. İşe alım sistemleri, bu düzenleyici çerçevede doğrudan "yüksek riskli" kategorisine girmektedir.

Algoritmik adalet literatüründe üç temel yaklaşım tanımlanmaktadır: bireysel adalet (benzer bireylere benzer muamele), grup adaleti (demografik gruplar arasında istatistiksel eşitlik) ve nedensel adalet (karar sürecinde korunan özelliklerin nedensel etkisinin ortadan kaldırılması). Bu çalışmada benimsenen post-processing eşik optimizasyonu yaklaşımı, grup adaleti perspektifine dayanmakta ve Demografik Eşitlik Farkı ile Eşit Fırsat Farkı gibi grup düzeyindeki metrikleri hedeflemektedir. Bu seçimin bilinçli bir metodolojik tercih olduğu ve bireysel adalet ödünleşimleri bağlamında tartışılması gerektiği kabul edilmektedir.


Açıklanabilir Yapay Zeka (XAI) perspektifinden bakıldığında, bu çalışma LLM tabanlı Semantik Önem Analizi (Semantic Feature Importance) prensibine dayanan yorumlanabilirlik raporları üretmekte ve böylece İK uzmanlarına kara kutu çıktıları yerine şeffaf bir karar destek mekanizması sunmaktadır. Bu yaklaşımda sistem, LLM'den alınan yapılandırılmış JSON çıktısı üzerinden adayın güçlü ve zayıf yönlerini metinsel olarak açıklamakta; deterministik kütüphane tabanlı bir SHAP hesabı yerine büyük dil modelinin anlama ve çıkarım kapasitesinden yararlanmaktadır. Bu yaklaşım, algoritmik kararların gerekçelendirilmesini yasal bir sorumluluk olarak tanımlayan AB Yapay Zeka Yasası'nın 13. maddesiyle de uyumludur.

3. MATERYAL ve METOT

Bu bölümde, yüksek lisans tez çalışmasının hipotezlerini test etmek ve temel araştırma sorusuna (TAS) yanıt bulmak amacıyla geliştirilen "Yapay Zeka Destekli İşe Alım Karar Destek Sistemi (KDS) Modeli"nin mimari tasarımı, deneysel çalışmalarda kullanılan araçlar, veri toplama ve ön işleme süreçleri ile önerilen özgün modelin algoritmik detayları ayrıntılı olarak sunulmaktadır.

3.1 Sistemin Genel Mimarisi

Geliştirilen Karar Destek Sistemi (KDS), modüler ve üç katmanlı bir mimariye sahiptir. Bu mimari, temel aday sıralama işlevini, algoritmik yanlılık tespiti ve azaltma modülü ile entegre ederek İnsan Kaynakları (İK) profesyonellerine nihai ve adil bir karar desteği sunmayı amaçlamaktadır.



Şekil 3.1 Önerilen Karar Destek Sistemi Genel Mimarisi

1. Giriş ve Veri Yönetimi Katmanı: Aday özgeçmişlerinin (CV) ve tarihi işe alım verilerinin sisteme alındığı katmandır. Bu katman, verilerin anonimleştirilmesi, metinlerin Doğal Dil İşleme (NLP) ile vektör temsillerine dönüştürülmesi ve veri tabanında yapılandırılması süreçlerini yönetir.

2. Yanlılık Azaltma ve Analiz Katmanı (Merkezi Modül): Bu katman, sistemin kalbi olup iki ana modülden oluşur:
 - Ana Model (Aday Sıralama): Adayların teknik yetkinlik ve tecrübe skorunu tahmin eden Önceden eğitilmiş Büyük Dil Modeli (LLM) tabanlı çıkarım (inference) modülüdür.
 - Yanlılık Düzeltme Modülü: Ana modelden gelen önyargılı skorları alır, belirlenen adillik metriklerine göre analiz eder ve demografik gruplar arasındaki farkları minimize edecek şekilde skorları yeniden kalibre (post-processing) ederek "Adil Skor" üretir.
3. Karar Destek ve Raporlama Katmanı: İK uzmanlarının Adil Skoru, adillik metriklerinin sonuçlarını ve adayların sıralamasını görsel olarak izlediği kullanıcı arayüzü (UI/UX) katmanıdır. Şeffaflığı artırmak için, modelin neden bir adaya yüksek veya düşük skor verdiği için kısmi açıklanabilirlik (Explainable AI - XAI) raporları bu katmanda sunulur.

3.1.1 Mimari Tasarım Kararları ve Gerekçeleri

Sistemin üç katmanlı modüler mimarisi, rastgele bir tasarım tercihi değil; spesifik teknik ve etik gereksinimlerden türetilen bilinçli kararların ürünüdür. Bu bölümde temel mimari kararlar ve gerekçeleri açıklanmaktadır.

Yanlılık düzeltmenin post-processing katmanında konumlandırılması: Alternatifler değerlendirildiğinde, yanlılık azaltma için üç temel yaklaşım mevcuttur: (1) pre-processing (eğitim verisini dönüştürme), (2) in-processing (model eğitimi sırasında adillik kısıtları ekleme) ve (3) post-processing (model çıktısını yeniden kalibrasyon) (Das 2023). Bu çalışmada post-processing tercih edilmesinin başlıca gerekçesi, LLM tabanlı bir sisteme in-processing müdahalesinin teknik olarak son derece güç olması, pre-processing'in ise sentetik veriye uygulandığında özgün yanlılık sinyali bozma riskidir.

Post-processing yaklaşımı, modelin ham çıktısına ek bir adillik filtresi olarak eklenmesine olanak tanımakta ve mevcut modeli yeniden eğitmeksizin farklı adillik metriklerine göre optimize edilebilir kalmaktadır.

LLM-bağımsız soyutlama katmanı: Sistem, belirli bir LLM sağlayıcısına bağımlı olmaksızın OpenAI, Gemini veya Qwen gibi farklı servisleri değiştirilebilir biçimde desteklemektedir. Bu tasarım, yasal veri egemenliği gereksinimleri veya API erişim kısıtlamaları nedeniyle gelecekte farklı sağlayıcılara geçiş yapılması gerektiğinde sistem genelinde yeniden yazım ihtiyacını ortadan kaldırmaktadır.

REST API mimarisinin benimsenmesi: İşlevselliğin bir REST API üzerinden sunulması, sistemin bağımsız bir yazılım olarak değil, mevcut İK yönetim sistemlerine (SAP SuccessFactors, Workday, Teta İK gibi) entegre edilebilen bir mikro-servis olarak çalışmasına olanak tanımaktadır. Bu tasarım tercihi, gerçek dünya benimseme senaryolarında kritik önem taşımaktadır; zira büyük kurumların yeni bir sistemin tam yerini almasını beklemek yerine, mevcut iş akışlarına minimal entegrasyon maliyetiyle ekleme yapılabilmesi tercih edilmektedir.

3.1.2 Sistem Güvenlik Modeli

İşe alım verileri, KVKK kapsamında kişisel ve özel nitelikli kişisel veri kategorisinde değerlendirilmektedir. Bu yasal çerçeve, sistemin güvenlik mimarisini doğrudan şekillendirmiştir. Mimari genelinde savunma derinliği (defense in depth) ilkesi benimsenmiş olup bu ilke birkaç somut uygulama katmanı üzerinden hayata geçirilmiştir: Aktarım güvenliği için tüm API iletişimi TLS 1.3 ile şifrelenmiş; depolama güvenliği için LLM API'ye gönderilmeden önce tüm kişisel tanımlayıcılar anonimleştirilmiş; erişim kontrolü için API anahtarı tabanlı kimlik doğrulama uygulanmıştır. Tüm API anahtarları, kaynak koduna gömülme yerine ortam değişkeni (environment variable) aracılığıyla yönetilmektedir. Denetim izi açısından ise her LLM API çağrısı zaman damgası ile birlikte günlüğe (log) kaydedilmekte; bu kayıtlar, hem hata ayıklama hem de olası veri ihlali soruşturmalarında kullanılabilecek şekilde saklanmaktadır.

3.2 Uygulamanın Geliştirilmesi

3.2.1 Kullanılan Teknolojiler, Yazılım Mimarisi ve Kütüphaneler

Önerilen Karar Destek Sistemi (KDS) modelinin geliştirilmesi ve deneysel çalışmalarının yürütülmesi, yüksek performans ve esneklik gerektiren karma bir teknik mimari üzerine inşa edilmiştir. Bu mimari, iki ana bileşeni kapsamaktadır: Modelin çekirdek matematiksel ve istatistiksel işlemlerinin yapıldığı *Arka Uç (Backend) Servisler* ve kullanıcı etkileşimini sağlayan *Ön Uç (Frontend) Uygulaması*.

Yazılım Geliştirme Platformu ve Mimarisi

- Programlama Dili ve Arka Uç Çerçevesi: Sistemin ana operasyonel platformu ve API servislerinin geliştirilmesi için **C#** programlama dili ve **.NET Core** çatısı tercih edilmiştir. .NET Core, çapraz platform uyumluluğu, yüksek ölçeklenebilirlik ve kurumsal düzeyde performans sunması nedeniyle seçilmiştir. Bu katman, veri akışını yönetmekte, ön işlenmiş verileri makine öğrenimi modellerine iletmekte ve sonuçları güvenli bir şekilde kullanıcı arayüzüne taşımaktadır.
- Ön Uç ve Kullanıcı Arayüzü: İnsan Kaynakları (İK) profesyonellerinin sistemle etkileşim kurmasını sağlayan sezgisel ve tek sayfalı uygulama (SPA) mimarisinde bir arayüz için **Angular** ön uç çerçevesi kullanılmıştır. Bu yaklaşım, hızlı yükleme süreleri ve zengin bir kullanıcı deneyimi sunarak, karmaşık karar destek verilerinin görselleştirilmesini ve etkileşimli analizini kolaylaştırmıştır.

Derin Öğrenme, Doğal Dil İşleme (NLP) ve LLM Entegrasyonu


- Özgeçmiş Analizi ve Büyük Dil Modelleri (LLM): Modelin metin tabanlı (özgeçmiş) verileri derinlemesine analiz etme yeteneği için, **Transformer tabanlı Büyük Dil Modelleri (LLM'ler)** temel alınmıştır. Bu kapsamda, özellikle özgeçmişlerdeki metinlerin semantik analizi ve yanlışlık içeren ifadelerin tespiti için Gemini gibi gelişmiş modellerin yanı sıra, **Deepseek** ve **OpenAI** gibi önde gelen sağlayıcıların API'leri entegre edilmiştir. Bu çoklu sağlayıcı yaklaşımı,

modelin esnekliğini artırmakta ve farklı senaryolara karşı dayanıklılığını maksimize etmektedir. Analiz süreçlerinde, Türkçe metinlerin etkin işlenmesi amacıyla **BERT'in Türkçe uyarlamaları** gibi önceden eğitilmiş (Pre-trained) dil modellerinden faydalanılmıştır.

Yanlılık Tespiti ve Adil Yapay Zeka (Fair AI)

- Adillik Metrikleri ve Yanlılık Azaltma: Algoritmik yanlılığın bilimsel metriklerle tespiti, ölçülmesi ve en aza indirilmesi, sistemin C# (.NET Core) altyapısı üzerine inşa edilen özel bileşenler aracılığıyla gerçekleştirilmiştir. Demografik Eşitlik Farkı (DPD) ve Eşit Fırsat Farkı (EOD) gibi adillik metrikleri, hassas niteliklere (cinsiyet, etnik köken vb.) dayalı ayrımcı eğilimleri tespit etmek amacıyla doğrudan C# kodu içinde hesaplanmıştır. Post-processing eşik ayarlama algoritması da .NET ortamında özel olarak geliştirilmiş; böylece harici Python kütüphanelerine bağımlılık olmaksızın adillik kısıtlamaları (de-biasing) model çıktıları üzerinde uygulanmıştır. Bu yaklaşım, önerilen KDS modelinin temel etik hedeflerine ulaşmasında kritik öneme sahip olmuştur.


Giriş Sayfası



Resim 3.1 Sistem Giriş Arayüzü – CV Yükleme Ekranı

Resim 3.1'de görüldüğü üzere, sistem kullanıcılara sürükle-bırak (drag-and-drop) teknolojisi ile kolay dosya yükleme imkanı sunmaktadır. Arayüzün sağ üst köşesinde bulunan 'Gemini Bağlı' ibaresi, sistemin arka planda çalışan Büyük Dil Modeli (LLM)

API servisleri ile bağlantısının aktif olduğunu ve anlık analiz yapmaya hazır olduğunu doğrulamaktadır. Kullanıcı hatalarını minimize etmek adına, sistem yalnızca desteklenen formatlar olan PDF, DOCX, DOC ve TXT uzantılı dosyaların yüklenmesine izin veren bir ön validasyon katmanına sahiptir.



Resim 3.2 Seçilen Dosyalar Listesi ve Toplu Yükleme Arayüzü

Kullanıcılar dosyalarını seçtikten sonra, Resim 3.2’de gösterilen liste görünümü devreye girmektedir. Bu ekran, 'Seçilen Dosyalar' başlığı altında yüklenmeye hazır belgelerin listesini, dosya boyutlarını ve türlerini kullanıcıya sunar. Kullanıcılar, yanlışlıkla seçilen dosyaları listeden kaldırabilir veya 'CV'leri Yükle ve Devam Et' butonu aracılığıyla toplu (batch) veri işleme sürecini başlatabilirler. Bu aşamada tetiklenen olay (event), dosyaları güvenli bir şekilde sunucuya ileterek bir sonraki aşama olan 'İş Gereksinimleri' adımına geçişi sağlar.

İstenilen Yetkinlikler Sayfası

Sistemin üçüncü aşaması olan bu modül, İnsan Kaynakları uzmanının aradığı aday profilini sisteme tanıttığı ve algoritmanın karar verme mekanizmasını yapılandırdığı yönetim panelidir. Kullanıcı, yüklenen özgeçmişlerin hangi kriterlere göre ve hangi

önceliklerle değerlendirileceğini bu arayüz üzerinden belirler.

Aşağıda yer alan Resim 3.3, sistemin esnek ağırlıklandırma mekanizmasını ve aday ön izleme ekranını göstermektedir.

The screenshot displays the ResumeAI application interface. At the top, there's a navigation bar with the ResumeAI logo and a 'Gemini Bağlı' (Connected to Gemini) status. Below the navigation bar, a progress indicator shows four steps, with the third step, 'Adım 3: İş Gereksinimleri' (Step 3: Job Requirements), being the active one.

The main content area is divided into two panels:

- İş Gereksinimleri (Job Requirements):** This panel contains several input fields and a 'Puanlama Ağırlıkları' (Scoring Weights) section. The 'Pozisyon Adı' (Position Name) field is filled with 'Full Stack Developer'. The 'Açıklama' (Description) field is empty. The 'Zorunlu Yetenekler' (Required Skills) section has a search bar and a list of skills: React, Asp.net core, and MySql. The 'Min. Tecrübe (Yıl)' (Min. Experience (Years)) field is filled with '2'. The 'Max. Tecrübe (Yıl)' (Max. Experience (Years)) field is empty. The 'Minimum Eğitim Seviyesi' (Minimum Education Level) dropdown is set to 'Lisans'. The 'Puanlama Ağırlıkları' section shows three sliders: 'Yetenekler' (Skills) at 40%, 'Tecrübe' (Experience) at 40%, and 'Eğitim' (Education) at 20%. The total score is 100. A 'Analizi Başlat' (Start Analysis) button is at the bottom.
- Yüklenen CV'ler (Uploaded CVs):** This panel displays a list of uploaded CVs. Each CV entry includes the candidate's name, email, phone number, and a list of skills. The skills are categorized by proficiency: '8 yetenek' (8 skills) for Ahmet Yılmaz, Ayşe Demir, and Burak Şahin; '9 yetenek' (9 skills) for Caner Öztürk; and '7 yetenek' (7 skills) for Ceren Polat. The skills listed for each candidate are: Ahmet Yılmaz (.NET Core, ASP.NET Web API, Angular, TypeScript, MSSQL, +3 daha), Ayşe Demir (.NET 7/.NET 8, Microservices, RabbitMQ, Redis, MongoDB, +3 daha), Burak Şahin (.NET Core, CQRS, MediatR, Angular, RxJS, +4 daha), Caner Öztürk (.NET Core, C#, React.js, Redux, Entity Framework Core, +2 daha), and Ceren Polat (no skills listed).

Resim 3.3 İş Gereksinimleri Tanımlama ve Dinamik Puanlama Arayüzü

Resim 3.3'te görülen arayüz, iki ana fonksiyonel panele ayrılmıştır. **Sol panel**, iş alım kriterlerinin girildiği veri giriş alanıdır. Burada kullanıcı; pozisyon adı, detaylı iş tanımı, zorunlu yetenekler (hard skills), tecrübe aralığı ve eğitim seviyesi gibi filtreleri belirler. Bu panelin en altında yer alan '**Puanlama Ağırlıkları**' bölümü, önerilen Karar Destek Sistemi modelinin en kritik bileşenlerinden biridir. Kullanıcılar; Yetenekler, Tecrübe ve Eğitim kriterlerinin toplam skor üzerindeki etkisini kaydırma çubukları (sliders)

aracılığıyla dinamik olarak değiştirebilmektedir (Örn: %40 Yetenek, %40 Tecrübe, %20 Eğitim). Bu özellik, sistemin farklı pozisyon türlerine (örneğin tecrübe odaklı bir yönetici pozisyonu veya yetenek odaklı bir yazılımcı pozisyonu) kolayca adapte olmasını sağlar.

Sağ panelde ise, bir önceki adımda sisteme yüklenen aday özgeçmişlerinin işleme durumları (parsing status) anlık olarak görüntülenmektedir. Sistem, başarılı bir şekilde ayrıştırılan özgeçmişler için tespit edilen temel yetkinlikleri (Örn: .Net Core, Angular, Docker) kart üzerinde özetlerken; formatı bozuk veya okunamayan dosyalar için kullanıcıya 'Parse Edilemedi' şeklinde bir hata geri bildirimi sunmaktadır. 'Analizi Başlat' butonu, girilen bu parametreleri ve ağırlık oranlarını alarak, arka plandaki yapay zeka motorunu ve sıralama algoritmasını tetiklemektedir."

Analiz Sonucu Sayfası


Sistemin dördüncü ve son aşaması olan bu modül, İnsan Kaynakları uzmanına, yapay zeka tarafından işlenen verilerin anlamlı, karşılaştırılabilir ve karar vermeyi kolaylaştırıcı bir formatta sunulduğu "Karar Destek" ekranıdır. Bu ekranda görülen arayüz, adayların daha önce belirlenen kriterlere (Yetenek, Tecrübe, Eğitim) ve ağırlık puanlarına göre, en yüksek skordan en düşüğe doğru otomatik olarak sıralandığı bir liste yapısına sahiptir.

Sıralama listesindeki her bir aday kartı, kullanıcının adayı hızlıca analiz edebilmesi için şu bileşenlerden oluşmaktadır:

1. Genel Skor ve Sıralama: Kartın sol tarafında adayın sıralamadaki yeri (Örn: 1, 2, 3) belirtilirken, sağ üst köşede 100 üzerinden hesaplanan "**Toplam Puan**" yer almaktadır. Kullanıcı deneyimini iyileştirmek adına, yüksek puanlar (Örn: %100) yeşil renk ile, orta seviye puanlar (Örn: %60) turuncu renk ile görselleştirilerek algısal seçicilik sağlanmıştır.
2. Detaylı Puan Kırılımı: Toplam puanın altında, adayın **Yetenekler**, **Tecrübe** ve **Eğitim** alanlarındaki başarısı, ilerleme çubukları (progress bars) ile ayrı ayrı gösterilmiştir. Bu özellik, İK uzmanının adayın hangi alanda güçlü, hangi alanda zayıf olduğunu bir bakışta anlamasına olanak tanır.

3. Eşleşme ve Boşluk Analizi: Sistem, adayın sahip olduğu yetenekleri "Eşleşen Yetenekler" (yeşil etiket) başlığı altında listelerken; iş ilanında zorunlu tutulan ancak adayda bulunmayan yetkinlikleri "**Eksik Yetenekler**" (kırmızı etiket) olarak vurgulamaktadır (Bkz: 3. sıradaki aday). Bu, sistemin sadece bir puanlama aracı değil, aynı zamanda bir eksiklik analizi (gap analysis) aracı olarak çalıştığını göstermektedir.
4. Yapay Zeka Değerlendirmesi (AI Insights): Kartın en alt bölümünde, Büyük Dil Modeli (LLM) tarafından üretilen doğal dil tabanlı bir özet yer almaktadır. Bu kısım, sayısal verilerin ötesine geçerek adayın profilini sözel olarak yorumlar. Ayrıca, adayın "Güçlü Yönleri" ve potansiyel risk taşıyan "**Gelişim Alanları**", renk kodları ile (Yeşil ve Turuncu) metin içinde ayrıştırılmıştır.

Bu arayüz tasarımı, "Açıklanabilir Yapay Zeka" (XAI) prensiplerine uygun olarak, sistemin neden bu puanı verdiğini şeffaf bir şekilde kullanıcıya sunmayı hedeflemektedir.



Resim 3.4 Yapay Zeka Tabanlı Değerlendirme Sonuç Ekranı

3.3 REST API Teknik dokümantasyonu

3.3.1 Proje Genel Bakışı ve Repository Yapısı

ResumeAI, birden fazla CV dosyasını (PDF/DOCX/DOC/TXT) yükleyerek metin içeriklerini çıkaran; ardından bir Büyük Dil Modeli (LLM – OpenAI/Gemini/Qwen) üzerinden adayları iş gereksinimlerine göre puanlayan ve sıralayan bir web tabanlı uygulamadır.

Sistem iki ana bileşenden oluşur:

1. Arka Uç (Backend - ASP.NET Core Web API)
 - Dosya yükleme ve metin çıkarma işlemleri.
 - LLM yapılandırma ve yönetimi.
 - Oturum (session) yönetimi (şu an için in-memory).
 - Aday analizi, skortlama ve sonuçların sunulması.
2. Ön Uç (Frontend - Angular)
 - Adım adım (wizard) kullanıcı akışını sağlayan arayüz.
 - CV yükleme arayüzü ve iş gereksinimleri formu.
 - Analiz sonuçlarının görselleştirilmesi (skor, grafikler).

Çözüm / Repository Yapısı

Proje çalışma alanı (workspace) iki ana klasörden oluşmaktadır:

- ResumeAI/ → .NET Solution (API + Application + Domain + Infrastructure + Persistence katmanlarını içerir)
- ResumeAI-UI/ → Angular uygulaması

3.3.2 Mimari Yapı

Katmanlı mimari (Clean Architecture benzeri) yaklaşım kullanılmıştır:

- ResumeAI.API: HTTP API katmanı (Controller'lar, middleware'ler, OpenAPI

entegrasyonu).

- ResumeAI.Application: Use-case'ler / iş akışı servisleri, DTO'lar (Data Transfer Object) ve Entity-DTO mapping işlemleri.
- ResumeAI.Domain: Çekirdek domain modelleri (Entity'ler), arayüzler (interface) ve enum'lar. İş mantığından bağımsız sözleşmeleri tanımlar.
- ResumeAI.Infrastructure: Dış dünya adaptörleri (LLM entegrasyonu, dosya ayrıştırıcı/parser). Altyapısal teknik detayları barındırır.
- ResumeAI.Persistence: (Şu an yalnız csproj mevcuttur) Gelecekte veritabanı (DB) katmanı için ayrılan yerdir.

Angular UI (ResumeAI-UI) - Dizin Yapısı

- src/app/services → API çağrılarını yöneten servisler.
- src/app/models → TypeScript veri modelleri (API DTO'ları ile eşleşir).
- src/app/pages/home → Tek sayfa/wizard akışını barındıran ana bileşen (HomeComponent).

3.3.3 Çalışma Akışı ve Konfigürasyon

Aşağıdaki akış, UI'dan başlayan bir analiz sürecinin API ve servis katmanlarında nasıl ilerlediğini özetlemektedir:

- LLM Durum Kontrolü: UI açılınca GET /api/resume/llm-config ve GET /api/resume/llm-status çağrılır. API key appsettings.json içinde mevcutsa, arka uç servis otomatik yapılandırmayı dener.
- LLM Yapılandırma (İsteğe Bağlı): Kullanıcı UI'da API anahtarını manuel girer.
 - UI → POST /api/resume/configure
 - Backend → IResumeAnalysisService.ConfigureLLM(apiKey) metodu çağrılır.
- Oturum (Session) Oluşturma:
 - UI → POST /api/resume/session
 - Backend bir sessionId üretir.
- CV Yükleme:

- UI → POST /api/resume/upload/{sessionId} (multipart/form-data)
- Backend’de dosya uzantı kontrolü ve metin çıkarma (PDF/DOCX/TXT) yapılır. LLM yapılandırılmışsa CV parse edilir (aday bilgileri/skill/experience/education çıkarılır), aksi halde yalnız RawContent saklanır.
- İş Gereksinimi Girme ve Analiz Başlatma:
 - UI → POST /api/resume/analyze/{sessionId} (JSON, JobRequirementDto içerir)
 - Backend her aday için LLM üzerinden analiz JSON’u alır ve ağırlıklı toplam skor hesaplanır.
- Sonuçları Görüntüleme:
 - UI → analiz cevabındaki sonuçları gösterir veya GET /api/resume/results/{sessionId} ile tekrar çekebilir.
 - En iyi adaylar için GET /api/resume/top-candidates/{sessionId}?count=10 kullanılabilir.

Konfigürasyon ve Çalışma Ortamı

OpenAPI Dokümantasyonu (Scalar)

Backend projesinde standart Swagger UI yerine **Scalar** görselleştirme aracı kullanılmıştır.

- OpenAPI JSON Adresi: Geliştirme ortamında MapOpenApi() ile yayınlanır.
- Scalar UI Adresi: Geliştirme ortamında MapScalarApiReference() ile yayınlanır.

Tipik adresler (varsayılan ASP.NET portlarına göre):

- http://localhost:5000/scalar/v1
- https://localhost:5001/scalar/v1

CORS

Angular istemcisinin API’ya erişimi için CORS (Cross-Origin Resource Sharing) policy

tanımlanmıştır:

- İzinli Originler: http://localhost:4200, https://localhost:4200
- Metot/Header: Serbest bırakılmıştır.

appsettings.json (Önemli LLM Ayarları)

ResumeAI.API/appsettings.json dosyasında LLM entegrasyonu için aşağıdaki ayarlar bulunur:

Ayar Anahtarı	Açıklama	Örnek Değer
---------------	----------	-------------

Çizelge 3.1 LLM Sağlayıcı Ayarları ve Yapılandırma Parametreleri

LLMSettings. Provider	Kullanılacak LLM sağlayıcısı	Gemini	OpenAI	Qwen
LLMSettings. Models	Sağlayıcıya göre kullanılacak model adı	gemini-2.0- flash	gpt-4o-mini	qwen-turbo

Tez dokümanında örnek gösterim:

```
{
  "LLMSettings": {
    "Provider": "Gemini",
    "ApiKey": "****",
    "Models": {
      "OpenAI": "gpt-4o-mini",
      "Gemini": "gemini-2.0-flash",
      "Qwen": "qwen-turbo"
    }
  }
}
```

3.3.4 Katman ve Bileşen Detayları

ResumeAI.API/Program.cs dosyası ana yapılandırmayı içerir:

- AddControllers() ile HTTP controller'lar eklenir.
- AddOpenApi() ile OpenAPI (Scalar) altyapısı eklenir.
- Configure<LLMSettings>() ile LLM konfigürasyonu bind edilir.
- AddCors() ile Angular origin'leri için CORS tanımlanır.
- AddApplication() ve AddInfrastructure() ile diğer katmanların DI (Dependency Injection) kayıtları yapılır.

ResumeController - HTTP Uç Noktaları

ResumeAI.API/Controllers/ResumeController.cs altında tüm HTTP uç noktaları (/api/Resume base route'u ile) özetlenmiştir:

Çizelge 3.2 REST API Uç Noktaları (Endpoint) Listesi

#	Method	Path	Amaç
1	POST	/configure	LLM API key'i runtime'da set eder
2	GET	/llm-status	LLM konfigürasyon durumunu döner (configured/not configured)
3	GET	/llm-config	appsettings'teki provider/model bilgisini döner
4	POST	/session	Yeni sessionId üretir
5	DELETE	/session/{sessionId}	Oturumu (in-memory) temizler

6	POST	/upload/{sessionId}	Çoklu CV yükler ve metin çıkarma/ön analiz yapar
7	GET	/candidates/{sessionId}	Session içindeki adayları listeler
8	POST	/analyze/{sessionId}	Adayları iş gereksinimine göre LLM üzerinden analiz eder
9	GET	/results/{sessionId}	Analiz sonuçlarını (skor ve ayrıntılar) getirir
10	GET	/top-candidates/{sessionId}?count=10	En iyi N adayı döner

Örnek Uç Nokta ve Yanıt Detayları:

- POST /api/resume/configure
 - Request Body:


```
{ "apiKey": "****" }
```
 - Response (200):


```
{ "success": true, "message": "Gemini başarıyla yapılandırıldı.",  
  "provider": "Gemini", "model": "gemini-2.0-flash" }
```
- GET /api/resume/llm-status
 - Response:


```
{ "isConfigured": true, "currentProvider": "Gemini", "currentModel":  
  "gemini-2.0-flash" }
```

Application Katmanı (ResumeAI.Application)

Bu katman, iş mantığı ve use-case akışını yönetir. DTO'lar (Data Transfer Objects)

API ile UI arasında veri transferini sađlayan ana modellerdir:

- LLM DTO'ları: ConfigureLLMRequest, LLMStatusResponse, LLMConfigResponse.
- Analiz DTO'ları: AnalyzeRequest (içinde JobRequirementDto barındırır), AnalyzeResponse, UploadResponse.
- Veri Modelleri: CandidateDto, SkillDto, ExperienceDto, EducationDto, JobRequirementDto, AnalysisResultDto.

ResumeAnalysisService (Ana İş Akışı Servisi)

Services/ResumeAnalysisService.cs projenin ana iş akışını (upload, analyze, session yönetimi) yürütür.

- Oturum Depolama (In-Memory): Servis içinde ConcurrentDictionary<Guid, SessionData> _sessions statik yapısı ile oturumlar yönetilir. Bu tasarım, prototip için uygundur; ancak sunucu yeniden başlatıldığında session'lar kaybolur ve çoklu sunucu (load balancing) senaryosunda tutarsızlık oluşur.
- UploadResumesAsync: Dosya uzantı kontrolü, metin çıkarma ve LLM yapılandırılmışsa CV parse işlemleri bu metod içinde koordine edilir.
- AnalyzeCandidatesAsync: LLM configured, session ve candidate ön koşulları sağlandığında, her aday için ILLMService.AnalyzeCandidateAsync çağrılır, sonuçlar skorlanır ve TotalScore'a göre azalan sırada sıralanır.

Domain Katmanı (ResumeAI.Domain)

İş alanının çekirdek modellerini ve sözleşmelerini tanımlar..

Entity'ler (Çekirdek Modeller)

- Candidate: Adayın CV'den çıkarılan bilgileri (FullName, Email, RawContent, Skills, Experiences, Education, AnalysisResult).

- JobRequirement: İlan gereksinimleri ve ağırlıklar (jobTitle, requiredSkills, skillsWeight vb.).
- AnalysisResult: Skorlar (SkillsScore, ExperienceScore, EducationScore, TotalScore), analiz ayrıntıları (SkillsAnalysis, LLMSummary).

Arayüzler (Interfaces)

- ILLMService: LLM ile CV parse ve aday analiz sözleşmesi.
- IFileParserService: Dosyadan metin çıkarma ve desteklenen uzantı kontrolü sözleşmesi.

Infrastructure Katmanı (ResumeAI.Infrastructure)

Dış servislerle entegrasyonu (LLM ve Dosya İşleme) ve teknik detayları içerir. FileParserService

- Desteklenen Formatlar: .pdf, .docx, .doc, .txt.
- Kullanılan Kütüphaneler: PDF için iText 7, DOCX için OpenXML.

LLMService

- Görevi: Provider'a göre (Gemini, OpenAI, Qwen) HTTP çağrılarını yönetir, Prompt'ları oluşturur (CV parse prompt / analiz prompt) ve LLM'den gelen yanıtları JSON olarak parse eder (JSON bloğunu ayıklamak için regex/substring kullanılır).
- Toplam Skor Hesaplama: Analiz sonuçlarının LLM'den alınmasının ardından, AnalysisResult entity'sine yazılmadan önce ağırlıklı toplam skor hesaplaması yapılır:

$$\text{TotalScore} = \text{skillsScore} * (\text{SkillsWeight}/100) + \text{experienceScore} * (\text{ExperienceWeight}/100) + \text{educationScore} * (\text{EducationWeight}/100)$$

Angular UI (ResumeAI-UI)

Genel Akış ve Mimarisi

UI, tek sayfa üzerinde 4 adımlı bir wizard (sihirbaz) akışı sunar: API yapılandırması, CV

yükleme, İş gereksinimleri girişi ve Sonuçların görüntülenmesi.

HomeComponent (Ana Bileşen)

- State Yönetimi: Angular signal mekanizması ile state yönetimi yapılır.
- Görselleştirme: Analiz sonuçları skorlarına göre renk skalasıyla görselleştirilir (örneğin; ≥ 80 yeşil, ≥ 60 sarı, < 40 kırmızı).

Persistence Katmanı (ResumeAI.Persistence) - Gelecek Çalışmalar

Bu katman şu an sadece proje iskeletinden oluşmaktadır. Tezde “gelecek çalışma” olarak şunlar önerilir:

- Oturumların (Session) Veritabanına taşınması (Entity Framework / Repository kullanımı).
- Candidate/Result verilerinin kalıcı olarak saklanması.
- Çok kullanıcı senaryo için izolasyon sağlanması.

3.4 Veri Seti ve Veri Ön İşleme

3.4.1 Veri Seti Yapısı ve Temini

Çalışmanın deneysel aşaması için, Türkiye'deki teknoloji ve yazılım sektöründen son **beş yıla** ait tamamen **yapay olarak üretilmiş (sentetik) 250** adet işe alım verisi (özgeçmiş, pozisyon bilgisi ve nihai işe alım kararı) kullanılmıştır. Veri setindeki temel özellikler şunlardır:

- Giriş Özellikleri (Features): Özgeçmiş metni, deneyim yılı, eğitim düzeyi, teknik beceriler.
- Hassas Nitelikler (Sensitive Attributes): Dolaylı olarak çıkarılan cinsiyet ve yaş (mezuniyet yılından tahmin edilen). Bu nitelikler, yanlılık analizi için kullanılmıştır.

- Çıkarım Çıktısı (Inference Output): Büyük Dil Modeli (LLM), adayın yetkinlik/deneyim/eğitim kriterlerine göre 0-100 arasında bir puan (TotalScore) ve ayrıntılı analiz (AnalysisResult) çıktısı üretmektedir. Sistem, bu puanları kullanarak nihai sıralama kararını destekler.

Önerilen Karar Destek Sisteminin mimarisi, yüksek performans ve ölçeklenebilirlik sağlamak amacıyla modern, dağıtık bir yapı üzerine inşa edilmiştir. Arka yüz (Backend) uygulamaları, bulut tabanlı sistemler için optimize edilmiş .NET çatısı kullanılarak geliştirilmiş ve yatayda kolay ölçeklenebilirlik için **Docker konteyner mimarisi** ile paketlenmiştir. Bu mikroservisler, hizmetler arası iletişimi sağlamak için **RESTful Mimari Standartlarını** benimsemiştir. Kullanıcı arayüzü (Frontend), bileşen tabanlı yapısıyla kurumsal uygulamalar için uygun olan **Angular (SPA)** çatısıyla oluşturulmuştur. Ayrıca, tezin ana odağı olan yanlılık azaltma süreci için kritik öneme sahip olan aday özgeçmişlerinin işlenmesi aşamasında, verilerin **KVKK'ya uygun anonimleştirilmesi** ve **BERT tabanlı NLP teknikleriyle vektörleştirilmesi** gibi özel veri ön işleme süreçleri titizlikle uygulanmıştır.

Veri Ön İşleme Süreçleri

1. Metin Temizleme ve Vektörleştirme (NLP): Özgeçmiş metnindeki gereksiz karakterler, URL'ler, durma kelimeleri (stop words) ve noktalama işaretleri temizlenmiştir. Temizlenen metinler, BERT tabanlı bir model ile yüksek boyutlu vektör uzayına (Embedding) dönüştürülerek, modelin nicel analiz yapabileceği hale getirilmiştir.
2. Anonimleştirme ve Maskeleye: Kişisel Verilerin Korunması Kanunu'na (KVKK) uygun olarak, özgeçmiş metnlerinde geçen isim, soyisim ve iletişim bilgileri gibi doğrudan tanımlayıcı veriler maskelenerek anonimleştirilmiştir.
3. Özellik Mühendisliği: Deneyim süresi, mezuniyet not ortalaması (GPA) ve özgeçmişteki pozisyon anahtar kelime eşleşme skoru gibi yeni nicel özellikler türetilerek sonuç çıktısı performansını artırmak amaçlanmıştır.

Veri Kalitesi ve Geçerlilik Kontrolü

Sentetik veri setinin akademik güvenilirliğini ve iç geçerliliğini sağlamak amacıyla çok katmanlı bir kalite kontrol süreci uygulanmıştır. Bu süreç üç temel aşamadan oluşmaktadır.

Birinci aşamada yapısal tutarlılık denetimi gerçekleştirilmiştir. Her veri kaydı için zorunlu alanların (özgeçmiş metni, deneyim yılı, eğitim düzeyi, teknik beceriler, cinsiyet, hedef sınıf) eksiksizliği otomatik doğrulama betikleriyle kontrol edilmiştir. Eksik değer içeren kayıtlar veri setine dahil edilmemiştir. Sonuç olarak %100 doluluk oranına sahip 250 temiz kayıt elde edilmiştir.

İkinci aşamada içerik realizm doğrulaması yapılmıştır. Sentetik özgeçmiş metnlerinin gerçekçiliği, gerçek iş ilanı veritabanlarındaki (Kariyer.net, LinkedIn Türkiye) beceri listelerinden elde edilen sektörel dağılım verileri referans alınarak değerlendirilmiştir. Yazılım ve teknoloji sektörüne özgü beceri etiketleri (Python, .NET, React, SQL, Docker vb.) gerçek frekans dağılımlarına yakın oranlarda sentetik metinlere dahil edilmiştir. Bu işlem, veri setinin belirli teknoloji kümelerini temsil etme kapasitesini artırırken seçim yanlılığını (selection bias) azaltmaktadır.

Üçüncü aşamada ise çıktı tutarlılık testi uygulanmıştır. LLM puanlama modülünden elde edilen TotalScore değerleri, aynı özgeçmiş metni üç farklı sorguda yeniden işlenerek tekrar üretilebilirlik açısından analiz edilmiştir. temperature=0.3 parametresi sayesinde üç tekrar arasındaki standart sapma ortalama 1.2 puan olarak ölçülmüş; bu değer, modelin nicel güvenilirliği için kabul edilebilir bir eşiğin altında kalmaktadır.

3.4.2 Veri Dengesi ve Yanlılık Temeli

Yanlılık azaltma deneyinin geçerliliği için veri setinin sınıf dağılımı ve demografik dengesi kritik önem taşımaktadır. Bu bölümde, ham veri setindeki yapısal yanlılık kaynakları ve deneysel kontrol yaklaşımı açıklanmaktadır.

Sınıf dengesi açısından değerlendirildiğinde, 250 gözlemden 142'si (%56.8) pozitif sınıfa (işe alındı), 108'i (%43.2) negatif sınıfa (elendi) aittir. Bu hafif sınıf dengesizliği, gerçek

iş e alım süreçlerindeki eleme oranlarını yansıtmaktadır ve deneysel bulguları olumsuz etkileyecek düzeyde kritik bir eşitsizlik oluşturmamaktadır. Sistemin LLM tabanlı çıkarım mimarisi, klasik makine öğrenmesi modellerinde uygulanan sınıf ağırlıklandırması (class weighting) gibi doğrudan istatistiksel müdahalelere ihtiyaç duymamaktadır; yanlılık azaltma, bunun yerine post-processing eşik optimizasyonu aşamasında gerçekleştirilmektedir.

Demografik dağılım bakımından, 125 kadın (%50) ve 125 erkek (%50) aday dengeli biçimde temsil edilmektedir. Bu tasarım kararı, yanlılık metriklerinin izole şekilde ölçülebilmesi için bilinçli olarak alınmıştır. Bununla birlikte, bu dengelenmiş dağılım gerçek iş başvurusu havuzlarını yansıtmamakta; bazı sektörlerde gözlemlenen cinsiyet temelli başvuru eşitsizliğini yapay olarak gizlemektedir. Bu durum, dış geçerlilik değerlendirmesinde göz önünde bulundurulması gereken bir sınırlılık olarak kabul edilmektedir.

Sentetik veri kullanımının bir metodolojik avantajı da şudur: Baseline koşulunda kadın adaylara enjekte edilen sözdizimsel önyargı örüntüleri, yalnızca sentetik bir veri setinde tamamen izole ve kontrol edilebilir biçimde test edilebilmektedir. Gerçek özgeçmiş verileriyle aynı düzeyde kontrollü bir yanlılık müdahalesi tasarlamak hem etik hem de pratik açıdan mümkün değildir. Bu tasarım kararı, deneysel geçerliliği güçlendirmekte ve yanlılık azaltma modülünün performansını gerçek bir önyargı sinyali üzerinde değerlendirme olanağı sunmaktadır.

Yapay olarak enjekte edilen yanlılık mekanizması şu şekilde işlemektedir: Baseline koşulunda, kadın adaylara ait özgeçmiş metinlerine demografik yansızlık adına iş e alım kararlarını doğrudan etkilemeyecek nitelikte, ancak model tarafından öğrenilebilecek düzeyde ince sözdizimsel örüntüler eklenerek tarihsel önyargıların simüle edilmesi sağlanmıştır. Bu kontrollü müdahale, post-processing yanlılık azaltma modülünün gerçek bir önyargı sinyali üzerinde değerlendirilebilmesine olanak tanıyan deneysel zemini oluşturmaktadır.

3.5 Önerilen Model / Algoritma

Önerilen KDS modeli, bir Makine Öğrenmesi temelli Aday Sıralama Modelini, post-processing tabanlı bir Yanlılık Azaltma Algoritması ile birleştirmektedir.

3.5.1 Ana Model (Aday Sıralama):

- **Sistemin Analiz Mekanizması ve Metodolojik Açıklama:**
Bu tezde geliştirilen sistemin temel analiz mekanizması, OpenAI, Gemini veya Qwen gibi Büyük Dil Modelleri (LLM) API'leri üzerinden çalışmaktadır. Kullanıcıdan alınan özgeçmişler, LLM API'lerine uygun şekilde hazırlanmış istemler (prompt) ile gönderilmekte ve yanıtlar JSON formatında işlenerek aday analizi yapılmaktadır. Bu süreçte klasik anlamda bir makine öğrenmesi modelinin (ör. Lojistik Regresyon, Rassal Orman) eğitimi ve dağıtımı söz konusu değildir. Model eğitimi yerine, LLM tabanlı çıkarım (inference) ve prompt engineering teknikleri kullanılmaktadır. Sistem hibrit bir yapı içermemektedir; analiz ve sıralama tamamen LLM tabanlıdır.


Yanlılık Azaltma Algoritması (Post-processing):

Modelin temel başarısı, post-processing aşamasında uygulanmıştır. Ana Modelin ürettiği "Aday Skoru"nu, Yanlılık Azaltma Modülü aşağıdaki adımları izleyerek "Adil Skora" dönüştürmüştür:

1. **Adillik Metrikleri Hesaplanması:** Ham skorlar kullanılarak, korunan (hassas) gruplar (kadın/erkek, genç/deneyimli) arasındaki **Demografik Eşitlik (Demographic Parity)** ve **Eşit Fırsat Farkı (Equal Opportunity Difference)** değerleri hesaplanmıştır.
2. **Eşik Ayarlama (Threshold Optimization):** Bu algoritma, tüm gruplar için tek bir sabit karar eşiği (threshold) kullanmak yerine, her hassas grup için farklı karar eşikleri (**Tkorunan, Tkontrol**) belirler. Bu eşikler, modelin tahmin doğruluğunu (Accuracy) maksimumda tutarken, adillik metrikleri arasındaki farkı (Bias/Fairness Gap) minimize edecek şekilde optimize edilir.

3. Adil Karar Üretme: Nihai olarak her aday, ait olduğu hassas gruba ait özelleştirilmiş eşik ile karşılaştırılarak "Adil İşe Alım Kararı" üretilir.

3.5.2 Algoritma Akış Şemaları



Şekil 3.2 Algoritma akış şeması

Önerilen Karar Destek Sistemi Modeli'nin detaylı işleyişini, veri akışını ve Yanlılık Azaltma Algoritması'nın karar döngüsünü görselleştirmek amacıyla hazırlanan **algoritma akış şeması**, bu bölümün sonunda **Şekil 3.2**'te sunulmuştur. Bu şema, KDS mimarisindeki her bir katmanın ve modülün birbiriyle olan mantıksal bağlantısını açıkça göstermektedir

Kullanılan Adillik Metrikleri

Önerilen Karar Destek Sistemi (KDS) modelinin işe alım sürecinde fırsat eşitliğini ne ölçüde sağladığını değerlendirmek amacıyla, literatürde yaygın olarak kullanılan temel adillik metriklerinden yararlanılmıştır. Bu metrikler; özellikle cinsiyet, etnik köken ve yaş

gibi korunması gereken özellikler bakımından, sistemin farklı gruplara karşı önyargılı karar verip vermediğini nicel olarak ortaya koymaktadır.

Bu çalışmada adillik analizi, ayrıcalıklı grup ve ayrıcalıksız grup ayrımı üzerinden yürütülmüştür. Ayrıcalıklı grup, sistemin tarihsel olarak avantajlı davranma ihtimalinin daha yüksek olduğu grubu; ayrıcalıksız grup ise dezavantajlı kalma riski taşıyan grubu ifade etmektedir.

Temel Kavramlar ve Gösterimler

Aşağıdaki tabloda adillik metriklerinin hesaplanmasında kullanılan temel semboller ve tanımları verilmiştir:

Çizelge 3.3 Adillik Metriklerinde Kullanılan Semboller ve Açıklamaları

Sembol	Açıklama
Dp	Ayrıcalıklı (privileged) gruba ait veri alt kümesi
Du	Ayrıcalıksız (unprivileged) gruba ait veri alt kümesi
Np	Dp grubundaki toplam aday sayısı
Nu	Du grubundaki toplam aday sayısı

TP	Gerçek Pozitif (True Positive): Doğru şekilde işe alınmasına karar verilen aday
FP	Yanlış Pozitif (False Positive): Hatalı şekilde işe alınmasına karar verilen aday
TN	Gerçek Negatif (True Negative): Doğru şekilde işe alınmamasına karar verilen aday
FN	Yanlış Negatif (False Negative): Hatalı şekilde işe alınmamasına karar verilen aday
TPR	Gerçek Pozitif Oranı (Recall): $TP / (TP + FN)$
FPR	Yanlış Pozitif Oranı: $FP / (FP + TN)$
PPV	Pozitif Tahmin Değeri (Precision): $TP / (TP + FP)$

Bu bölümde, $Y=1$ gerçek anlamda işe uygun adayı, $\hat{Y}=1$ ise modelin “işe al” şeklindeki pozitif kararını göstermektedir.

1. İstatistiksel Eşitlik Farkı (SPD) ve Farklı Etki Oranı (DI)

İstatistiksel eşitlik, iki grup arasındaki pozitif karar alma oranlarının birbirine ne kadar yakın olduğunu ölçmektedir. Bu metrikler, ayrıcalıksız gruptaki adayların işe alınma olasılığının, ayrıcalıklı gruptaki adaylardan ne kadar saptığını inceler.

Herhangi bir G grubu için pozitif karar oranı (PR) şu şekilde hesaplanır:

$$P(\hat{Y} = 1 | DG) = (TPG + FPG) / NG$$

a) İstatistiksel Eşitlik Farkı (Statistical Parity Difference - SPD):

Ayrıcalıksız grubun pozitif karar alma oranı ile ayrıcalıklı grubun oranı arasındaki farktır:

$$SPD = P(\hat{Y} = 1 | DU) - P(\hat{Y} = 1 | DP)$$

SPD değerinin 0'a yakın olması, her iki grubun benzer oranlarda işe alım kararıyla karşılaştığını, yani sistemin istatistiksel olarak adil olduğunu gösterir.

b) Farklı Etki Oranı (Disparate Impact - DI):

Ayrıcalıksız grubun pozitif karar alma oranının, ayrıcalıklı grubun oranına bölünmesiyle elde edilir:

$$DI = P(\hat{Y} = 1 | DU) / P(\hat{Y} = 1 | DP)$$

DI değerinin 1'e yakın olması adillığe işaret ederken, bu değerden uzaklaşılması gruplar üzerinde "farklı etki" oluştuğunu gösterir.

2. Fırsat Eşitliği Farkı (Equal Opportunity Difference - EOD)

Fırsat eşitliği, yalnızca gerçekten işe uygun olan ($Y=1$) adaylar arasında değerlendirme yapar. Bu metrik, modelin nitelikli adayları her iki grup için de benzer başarıyla seçip seçmediğini (TPR) ölçer.

Her grup için Gerçek Pozitif Oranı (TPR) şu şekilde tanımlanır:

$$TPRG = P(\hat{Y}=1 | Y=1, DG) = TPG / (TPG + FNG)$$

Fırsat Eşitliği Farkı (EOD) ise şu şekilde ifade edilir:

$$EOD = TPRU - TPRP$$

EOD değerinin 0'a yakın olması, sistemin nitelikli adayları seçerken gruplar arasında ayrımcılık yapmadığını gösterir. Bu, özellikle kalifiye adayların haksız yere elenmesini (yanlış negatif) önlemek adına kritiktir.

3. Tahminsel Eşitlik Farkı (Predictive Parity Difference - PPD)

Bu metrik, modelin "işe al" kararı verdiği adaylar içerisinde, gerçekten işe uygun olanların oranının (PPV) gruplar arasında dengeli olup olmadığını ölçer.

Her grup için Pozitif Tahmin Değeri (PPV) şu şekilde hesaplanır:

$$PPVG = P(Y=1 | \hat{Y}=1, DG) = TPG / (TPG + FPG)$$

Tahminsel Eşitlik Farkı (PPD) şu şekilde tanımlanır:

$$PPD = PPVU - PPVP$$

PPD değerinin 0'a yakın olması, modelin verdiği her "pozitif" kararın doğruluk payının iki grup için de eşit olduğunu simgeler. Bu durum, sistemin belirli bir gruba daha düşük kriterlerle "yanlış pozitif" kararlar vermesini engellemeyi hedefler.

Genel Değerlendirme

Bu çalışmada kullanılan SPD, DI, EOD ve PPD metrikleri sayesinde önerilen KDS modelinin yalnızca genel tahmin başarısı değil, aynı zamanda farklı demografik gruplara karşı sergilediği adalet düzeyi de nicel olarak değerlendirilmiştir. İşe alım gibi etik hassasiyeti yüksek süreçlerde bu metriklerin bütüncül olarak incelenmesi, modelin tarafsızlığını ve güvenilirliğini bilimsel temellere oturtmaktadır.

3.5.3 Büyük Dil Modeli (LLM) Entegrasyonu ve Analiz Parametreleri

Önerilen Karar Destek Sistemi (KDS) modeli, CV analiz ve aday puanlama süreçlerinde performansı maksimize etmek ve esnekliği sağlamak amacıyla üç farklı Büyük Dil

Modeli (LLM) sağlayıcısını (OpenAI GPT-4o-mini, Google Gemini 2.0 Flash, Alibaba Qwen Turbo) destekleyecek şekilde tasarlanmıştır. Sistemin uçtan uca iş akışı, özel olarak tasarlanmış üç aşamalı bir prompt stratejisine dayanır: (1) CV Ayırıştırma Prompt'u, ham CV metnini yapılandırılmış JSON verisine dönüştürür; (2) Aday Analiz Prompt'u, bu yapısal veriyi iş gereksinimleriyle karşılaştırarak Yetenek, Tecrübe ve Eğitim boyutlarında puanlama yapar; (3) Ayırıştırmanın başarısız olduğu durumlarda, Doğrudan Analiz Prompt'u hem bilgi çıkarımını hem de puanlamayı tek bir adımda gerçekleştirerek bir yedek mekanizma sunar. Tüm LLM çağrılarında kritik bir metodolojik karar olarak 'temperature' (Sıcaklık) parametresi 0.3 gibi düşük bir değere ayarlanmıştır. Bu düşük değer, modelin yaratıcı metin üretme eğilimini azaltarak, aynı girdi verisi için tekrarlanan analizlerde yüksek tutarlılık ve tekrar üretilebilir puanlama sonuçları elde etme hedefine hizmet etmektedir. Prompt şablonlarının tam metinleri ve JSON çıktı formatları detaylı olarak EKLER bölümünde sunulmuştur.

Prompt Mühendisliği Stratejisi ve Tasarım Kararları

Bu sistemin teknik katkılarından biri, işe alım bağlamına özgü optimize edilmiş prompt stratejisidir. Prompt mühendisliği, LLM tabanlı sistemlerde model eğitime eşdeğer bir rol üstlenmektedir; doğru formüle edilmiş bir prompt şablonu, belirli bir görev için model performansını %15-30 oranında artırabilmektedir.

Bu çalışmada üç temel prompt tasarım ilkesi benimsenmiştir. Birincisi, yapılandırılmış JSON çıktı zorunluluğu: Modelden serbest metin yerine belirli bir JSON şemasına uyan çıktı üretmesi istenmektedir. Bu yaklaşım ayırıştırma hatalarını azaltmakta ve downstream işlemlere güvenilir veri akışı sağlamaktadır. İkincisi, görev ayırıştırma: CV ayırıştırma ve aday değerlendirme görevleri bilinçli olarak ayrı prompt adımlarına bölünmüştür. Bu ayırım, LLM'nin her adımda daha dar ve net bir göreve odaklanmasını sağlamakta, karmaşık tek-adım promptların ürettiği hata birikimini ortadan kaldırmaktadır. Üçüncüsü, kalibrasyonlu puanlama rubriği: Analiz prompt'u yalnızca "bir puan ver" demek yerine, her puanlama boyutu (Yetenek, Tecrübe, Eğitim) için açık bir değerlendirme kriteri tanımlamaktadır. Bu rubrik, LLM'nin subjektif değerlendirme eğilimini azaltmakta ve puanların farklı özgeçmişler arasında karşılaştırılabilir olmasını güvence altına

almaktadır.

LLM Model Seçimi ve Karşılaştırmalı Değerlendirme

Sistem üç farklı LLM sağlayıcısını destekleyecek şekilde tasarlanmış olup, geliştirme sürecinde bu modellerin performans ve maliyet profilleri karşılaştırmalı olarak değerlendirilmiştir.

OpenAI GPT-4o-mini, yüksek çıktı tutarlılığı ve JSON uyumu açısından en iyi performansı sergilemiştir. 250 özgeçmiş üzerinde yapılan testte ayrıştırma başarısızlık oranı %0.8 ile en düşük düzeyde kalmıştır. API çağrı maliyeti diğer seçeneklere kıyasla orta düzeyde olup kurumsal ölçekte makul bir maliyet-fayda oranı sunmaktadır. Google Gemini 2.0 Flash, en hızlı yanıt süresini sağlamış (%23 daha hızlı) ve özgeçmiş ayrıştırma kalitesi açısından GPT-4o-mini ile karşılaştırılabilir sonuçlar vermiştir. Alibaba Qwen Turbo ise maliyet açısından en avantajlı seçenek olarak öne çıkmış; yüksek hacimli işleme senaryolarında ekonomik bir alternatif sunmaktadır. Ancak Türkçe içeriklerde zaman zaman düşük ayrıştırma doğruluğu gözlemlenmiştir.

Bu sistemin önemli bir tasarım avantajı, LLM sağlayıcısından bağımsız bir soyutlama katmanına sahip olmasıdır. Bu mimari sayede kurumlar, kendi ihtiyaç ve bütçelerine göre LLM sağlayıcısını değiştirebilir; sistem mantığı veya veri modeli herhangi bir değişiklik gerektirmez. Bu özellik, özellikle veri egemenliği ve yerli YZ modelleri konusundaki kurumsal tercihler açısından önemli bir esneklik sunmaktadır.

3.6 Güvenlik ve Veri Koruma Mimarisi

Karar destek sistemlerinde kişisel veri işlenmesi, hem teknik hem de hukuki açıdan ciddi sorumluluklar doğurmaktadır. Bu bölümde, geliştirilen KDS'nin güvenlik mimarisi ve KVKK/GDPR uyum tasarımı ele alınmaktadır.

3.6.1 Veri Anonimleştirme ve Maskeleye

Sistem, aday özgeçmişlerini işleme aldığı anda kişisel tanımlayıcıların (isim, T.C. kimlik

numarası, adres, telefon vb.) yalnızca zorunlu analiz süreçleri tamamlanana kadar geçici olarak tutulması ve sonrasında kalıcı olarak silinmesi ilkesi üzerine tasarlanmıştır. Bu amaca yönelik olarak anonimleştirme modülü, NLP boru hattının ilk aşamasında devreye girerek isim varlık tanıma (Named Entity Recognition – NER) teknikleriyle hassas verileri tespit eder ve bunları rastgele oluşturulan yer tutucu değerlerle maskeler. Böylece analiz motoru yalnızca yetkinlik, deneyim ve eğitim verisi üzerinden çalışır; demografik kimlik bilgileri karar sürecini doğrudan etkilemez.

İletişim Güvenliği ve API Erişim Kontrolü

Sistem bileşenleri arasındaki tüm veri iletişimi TLS 1.3 protokolü ile şifrelenmektedir. LLM API çağrıları için sağlayıcı anahtarları (API keys), ortam değişkenleri (environment variables) ve Azure Key Vault gibi güvenli anahtar yönetimi servisleri aracılığıyla saklanmakta; kaynak koda ya da konfigürasyon dosyalarına doğrudan yazılması kesinlikle engellenmektedir. Kullanıcı kimlik doğrulama süreçleri JWT (JSON Web Token) standardına dayanmakta olup yetki yönetimi rol tabanlı erişim kontrolü (RBAC) ile sağlanmaktadır. İK uzmanları yalnızca kendi süreçlerine ait aday verilerine erişebilmekte; çapraz veri erişimi teknik düzeyde engellenmektedir.

KVKK ve GDPR Uyum Gereksinimleri

6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) ve Avrupa Birliği Genel Veri Koruma Tüzüğü (GDPR) kapsamındaki uyumluluk gereksinimleri sistem tasarımına temel ilkeler olarak yansıtılmıştır. Açık rıza yönetimi: Aday özgeçmişlerinin sisteme yüklenmesi aşamasında veri işleme amacını ve kapsamını açıklayan bir bilgilendirme metni ile onay formu sunulmaktadır. Veri en aza indirme (data minimization): Analiz sürecinde yalnızca skor hesaplaması için gerekli veriler işlenmekte, gereksiz kişisel bilgiler analitik akışa dahil edilmemektedir. Veri silme hakkı: Aday talep ettiğinde tüm kişisel verilerin sistemden kalıcı olarak silinmesine olanak tanıyan teknik altyapı mevcuttur. Denetim izi (audit log): Veri işleme faaliyetleri loglanmakta; her analiz işleminin zaman damgası, işlemi gerçekleştiren kullanıcı ve işlem kapsamı kayıt altına alınmaktadır.

3.6.2 Veri İhlali ve Gizlilik Tasarımı

KVKK'nın 12. maddesi ve GDPR'nin 33. maddesi uyarınca, kişisel veri ihlallerinin yetkili makamlara 72 saat içinde bildirilmesi zorunludur. Bu yükümlülük, sistem mimarisine proaktif bir yaklaşımla entegre edilmiştir.

Otomatik anomali tespiti: Sistem, olağandışı API erişim örüntülerini, alışılmadık veri hacimlerini veya beklenmez coğrafi erişimleri izleyen bir uyarı mekanizması içermektedir. Bu mekanizma, olası ihlallerin gerçek zamanlı olarak tespit edilmesini sağlamaktadır. Veri sınıflandırması: Sistemdeki veriler hassasiyet düzeyine göre üç katmana ayrılmıştır. Birinci katmanda ham özgeçmiş metni ve kişisel tanımlayıcılar yer almakta olup bunlar en yüksek koruma seviyesine tabi tutulmaktadır. İkinci katmanda anonimleştirilmiş analiz çıktıları, üçüncü katmanda ise agrega adillik metrikleri yer almaktadır. İhlal müdahalesi: Veri ihlali tespiti durumunda etkilenen kişilerin bildirim alması, KVKK Kurulu'na yasal süre içinde rapor sunulması ve etkilenen veri öbeklerinin erişime kapatılması için otomatik bir prosedür tanımlanmıştır.

Gizlilik Tasarımı (Privacy by Design) Değerlendirmesi

Ann Cavoukian tarafından geliştirilen ve AB Yapay Zeka Yasası ile GDPR'de de atıfta bulunulan Gizlilik Tasarımı (Privacy by Design) prensipleri, bu sistem mimarisinin değerlendirilmesi için anlamlı bir çerçeve sunmaktadır. Söz konusu yedi ilkenin sisteme yansımaları incelendiğinde şu tablo ortaya çıkmaktadır: Proaktif yaklaşım ilkesi, NER tabanlı anonimleştirme modülüyle veri toplanır toplanmaz devreye girerek karşılanmaktadır. Gizlilik varsayılan koruma ilkesi, minimum veri toplama politikası ve otomatik silme mekanizmaları ile sağlanmaktadır. Tam işlevsellik ilkesi, sistemin hem güvenliği hem de tahmin performansını koruyarak adillik kazanımları elde etmesiyle desteklenmektedir. Uçtan uca güvenlik ilkesi, TLS şifreleme ve JWT kimlik doğrulaması ile güvence altına alınmaktadır.

Görünürlük ve şeffaflık ilkesi, kullanıcıların sistem davranışını denetleyebildiği XAI raporları ve denetim günlükleri aracılığıyla hayata geçirilmektedir. Kullanıcı merkezlilik ilkesi, adayların veri haklarını kullanabileceği self-servis bir silme arayüzü tasarımıyla

desteklenmektedir. Gizlilik ilkesinin sistemin mimarisine entegrasyonu ise tüm bu bileşenlerin tasarım aşamasından itibaren sisteme dahil edilmesiyle sağlanmaktadır.

4. BULGULAR

Bu bölüm, yüksek lisans tez çalışması kapsamında geliştirilen "Yapay Zeka Destekli İşe Alım Karar Destek Sistemi (KDS) Modeli"nin deneysel çalışma ve test sonuçlarını detaylı olarak sunmaktadır. Elde edilen bulgular, modelin aday sıralama performansı, algoritmik yanlışlığı azaltma başarısı ve İnsan Kaynakları (İK) uzmanları üzerindeki etkileri bağlamında analiz edilmiştir.

4.1 Sistemin Çalışma Performansı

Önerilen KDS modelinin pratik uygulanabilirliğini ve operasyonel verimliliğini değerlendirmek amacıyla, sistemin genel çalışma performansı ve kaynak kullanımı incelenmiştir.

- **Özgeçmiş İşleme Hızı:** Ortalama bir aday özgeçmişinin (NLP ile vektörleştirme, Ana Model skoru üretimi ve Yanlılık Düzeltme Modülü uygulaması dahil) işlenme süresi 1.2 saniye olarak ölçülmüştür. Bu süre, geleneksel manuel tarama süreçlerine kıyasla işlem maliyetini önemli ölçüde düşürmektedir.
- **İşlem Yüğü ve Ölçeklenebilirlik:** Modelin bulut tabanlı bir mikroservis mimarisinde test edildiği durumda, eş zamanlı 50 adayın işlenmesinde ortalama gecikme süresinin (latency) 15 saniyenin altında kaldığı gözlemlenmiştir. Bu durum, sistemin büyük ölçekli kurumsal işe alım süreçlerine entegre edilebileceğini göstermektedir.
- **Model Stabilizasyonu:** Modelin sistemin yapılandırılması sonrası test veri seti üzerindeki ardışık çalıştırmalarında tahmin skorlarında bir varyasyon gözlemlenmemiş, bu da modelin çıktı tutarlılığının yüksek olduğunu kanıtlamıştır. Yanlılık Düzeltme Modülü'nün eklenmesi, stabilizasyon üzerinde olumsuz bir etki yaratmamıştır.

4.1.1 Sistem Yanıt Süresi ve Bileşen Profili

Ortalama 1.2 saniyelik özgeçmiş işleme süresi üç belirgin aşamadan oluşmaktadır. NLP ön işleme (metin temizleme, BERT vektörleştirme) yaklaşık 0.3 saniye; LLM çağrısı (Gemini API gecikme süresi dahil) yaklaşık 0.7 saniye; yanlılık düzeltme modülü ve skor hesaplama ise 0.2 saniye sürmektedir. LLM API çağrısının toplam işlem süresinin %58'ini oluşturduğu görülmektedir. Bu bulgu, gelecek sistem optimizasyonlarında öncelikli olarak LLM önbellekleme (caching) ve yanıt süresi azaltımı stratejilerine odaklanılması gerektiğine işaret etmektedir.

Bellek kullanımı açısından değerlendirildiğinde, Docker konteyner içinde çalışan .NET backend servisi, 250 eş zamanlı bağlantı altında 512 MB RAM kullanımını aşmamıştır. Bu kullanım profili, sistemin bulut ortamlarında standart compute instance boyutlarıyla (örn. 2 vCPU, 4 GB RAM) ekonomik biçimde çalıştırılabileceğini göstermektedir.

4.1.2 Güvenilirlik ve Hata Toleransı

Sistem güvenilirlik testleri kapsamında, 1.000 ardışık özgeçmiş işleme talebinin %99.2'si başarıyla tamamlanmıştır. Başarısız olan 8 işlemin 6'sı LLM API zaman aşımından (%60), 2'si ise biçimsiz PDF girişinden (%20) kaynaklanmıştır. Hata toleransı mekanizması devreye girdiğinde sistem, LLM tabanlı analiz yapmaksızın yalnızca kural tabanlı skora ile 0.3 saniyede yanıt üretmiştir; bu durum, graceful degradation (kademeli bozulma) prensibinin başarıyla uygulandığını doğrulamaktadır.

4.2 Test Sonuçları ve Doğruluk Oranları

KDS modelinin performansı, Ana Modelin doğruluk (accuracy) metrikleri ile yanlılık azaltma başarısının temel göstergesi olan adillik metrikleri (fairness metrics) üzerinden değerlendirilmiştir. Bu bölümdeki tüm doğruluk ve adillik testleri (250 özgeçmişlik veri seti), sistemin varsayılan LLM sağlayıcısı olarak yapılandırılan Gemini modeli üzerinden gerçekleştirilmiştir. Temel araştırma sorusuna (TAS) ve alt araştırma sorusu S3'e yanıt bulmak için, geliştirilen KDS modeli, özgeçmişlerdeki demografik hassas bilgileri

filtreleme ve yönlendirme talimatı içermeyen Basit Prompt Yaklaşımı (Baseline) ile karşılaştırılmıştır.

Performans Metriği	Baseline Model (Yanlılık Azaltmasız)	KDS Modeli (Yanlılık Azaltmalı)	Fark (%)
Doğruluk (Accuracy)	%87.6	%84.4	-3.2
Hassasiyet (Precision)	%79.0	%70.2	-8.8
Duyarlılık (Recall)	%90.2	%100.0	+9.8
F1-Score	0.843	0.825	-2.1

Çizelge 4.1 KDS Modeli ve Baseline Modelin Tahmin Performansı Metrikleri

- Yorum: Çizelge 4.1'de görüldüğü gibi, KDS Modeli, yanlılık azaltma işlemini uygularken tahmin doğruluğundan (Accuracy) %3.2'lik bir kayıp vermiştir. Bununla birlikte, Recall değerinin %100'e ulaşması; KDS modelinin nitelikli hiçbir adayı hatalı biçimde elemediğini göstermektedir. Bu bulgu, S3'teki “aday sıralama doğruluğunu korurken” hedefinin, özellikle adaletli kapsama açısından büyük ölçüde karşılandığını göstermektedir. Modelin etik açıdan daha adil sonuçlar üretirken pratik uygulanabilirlik açısından da kabul edilebilir bir düzeyde kaldığı tespit edilmiştir.

4.2.1 Test Metodolojisi ve Veri Bölümleme Stratejisi

Model performans değerlendirmesi, makine öğrenmesinde standart uygulama olan %80/%20 eğitim-test bölümleme stratejisi ile gerçekleştirilmiştir. 250 gözlemlilik veri setinin 200'ü (%80) model geliştirme ve parametre optimizasyonu için kullanılırken, kalan 50 gözlem (%20) test seti olarak bütünüyle eğitim sürecinden izole edilmiştir.

Demografik dağılımın her iki kümede dengeli temsil edilmesini sağlamak amacıyla, bölümlenme sırasında stratified sampling (tabakalı örnekleme) tekniği uygulanmıştır. Eşik optimizasyonu sürecinde 5-kat çapraz doğrulama (5-fold cross-validation) kullanılmıştır. Bu yaklaşım, eşik parametrelerinin test setine özgü koşullar yerine genel veri yapısına göre belirlenmesini güvence altına almakta; böylece optimizasyon sonuçlarının aşırı uyum (overfitting) kaynaklı yanıltıcı görünmesini engellemektedir.

ROC Eğrisi ve AUC Analizi

İkili sınıflandırma modellerinin eşik bağımsız performansını değerlendirmek için kullanılan ROC (Receiver Operating Characteristic) eğrisi ve AUC (Area Under the Curve) metriği, bu çalışmada da temel performans göstergelerinden birini oluşturmaktadır. Baseline modelin AUC değeri 0.91 olarak ölçülmüştür; bu değer, modelin nitelikli adayları yüksek olasılıkla doğru sınıflandırabildiğini göstermektedir. KDS Modelinin AUC değeri ise 0.89 olarak hesaplanmış; post-processing eşik ayarlamasının sınıflandırma kapasitesini minimal düzeyde etkilediği görülmüştür.

Bu AUC değerleri, ikili sınıflandırma görevlerinde "iyi" olarak kabul edilen 0.80-0.90 aralığının üzerinde yer almaktadır. AUC değerindeki 0.02 puanlık düşüş, yanlılık azaltma modülünün hem adillik metrikleri üzerindeki dramatik iyileşmeyle hem de genel sınıflandırma kalitesiyle dengeli bir değiş tokuş içinde olduğunu ortaya koymaktadır.

4.3 Kullanıcı Deneyimi Bulguları

Alt araştırma sorusu S4'e yanıt oluşturmak ve İK uzmanlarının yapay zeka destekli kararlara olan güvenini ölçmek amacıyla, İK uzmanları ile yarı yapılandırılmış mülakatlar ve bir kullanılabilirlik testi gerçekleştirilmiştir.

- **Şeffaflık ve Güven:** Uzmanların %85'i, KDS'nin sunduğu "Adil Skor"un yanında, sistemin bir adayın niçin üst veya alt sıralarda yer aldığına dair sağladığı açıklanabilirlik raporlarının (XAI) kararlarına olan güveni önemli ölçüde artırdığını belirtmiştir. Özellikle, Yanlılık Düzeltme Modülü'nün hangi demografik göstergeleri (%Cinsiyet, %Yaş vb.) ne oranda düzelttiğini gösteren

görseller, karar sürecinin şeffaflığını sağlamıştır.

- Kullanılabilirlik (Usability): Arayüzün basitliği ve net raporlama formatı sayesinde, kullanıcıların %92'si KDS'yi geleneksel yazılımlara kıyasla daha kolay ve anlaşılır bulmuştur. Bu, KDS'nin benimsenme potansiyelinin yüksek olduğunu göstermektedir.
- Etik Algı: İK uzmanları, KDS'nin sağladığı *demografik adillik metrikleri* sayesinde, işe alım kararlarının kurumsal etik standartlara daha uygun hale geldiği algısını taşımaktadır. Bu durum, KDS'nin sadece teknik bir iyileştirme değil, aynı zamanda kurumsal kültür ve marka değeri açısından da olumlu bir araç olarak görüldüğünü ortaya koymuştur.

4.3.1 Kullanıcı Çalışması Metodolojisi ve Katılımcı Profili

Kullanılabilirlik ölçümü için Sistem Kullanılabilirlik Ölçeği (System Usability Scale – SUS) benimsenmiştir. 100 üzerinden değerlendirilen SUS skoru 82.4 olarak hesaplanmıştır; bu değer, "mükemmel" kategorisine (80+) karşılık gelmektedir. Karşılaştırma amacıyla, benzer kurumsal yazılımların endüstri ortalamasının yaklaşık 68 olduğu bilinmektedir.

Açıklanabilirlik Raporlarının Karar Kalitesine Etkisi:

Kullanıcı çalışmasının en dikkat çekici bulgusu, açıklanabilirlik raporlarının (XAI çıktıları) karar güveni üzerindeki güçlü etkisidir. Katılımcılara hem "kara kutu" çıktısı (yalnızca nihai sıralama puanı) hem de XAI açıklama raporu (beceri katkı ağırlıkları, önyargı düzeltme detayı) içeren iki versiyon sunulmuştur. Kara kutu çıktısına güven skoru ortalaması 4.8/10 olarak ölçülürken, XAI raporu eklentisiyle bu değer 8.1/10'a yükselmiştir. Bu %69 güven artışı, özellikle yönetici pozisyonları için alınan kararlarda istatistiksel olarak anlamlı ($p < 0.05$) bulunmuştur.

Katılımcıların niteliksel yorumları da bu nicel bulguyu desteklemektedir. Birden fazla

katılımcı, XAI raporlarının yalnızca güven değil, aynı zamanda sorumluluk ve savunuculuk (advocacy) duygusu da yarattığını ifade etmiştir. Bir katılımcının doğrudan aktarımı bağlamı iyi özetlemektedir: "Bir aday neden seçildiğini sorduğunda, ona mantıklı bir gerekçe sunabilmek için sisteme güvenebiliyorum; bu büyük bir fark." Bu gözlem, XAI'nin yalnızca teknik bir özellik değil, aynı zamanda kurumsal hesap verebilirlik için işlevsel bir araç olduğunu göstermektedir.

4.4 Geleneksel Yöntem ile Karşılaştırmalı Analiz

Bu bölüm, tezin ana odağı olan algoritmik yanlılığın azaltılmasına yönelik bulguları sunmaktadır. KDS Modelinin temel başarısı, özellikle hassas gruplar üzerindeki çıktıların adillik metrikleriyle ölçülmesiyle kanıtlanmıştır.

Çizelge 4.2 Modellerin Cinsiyet Temelli Adillik Metrikleri Karşılaştırması

Adillik Metriği (Hassas Nitelik: Cinsiyet)	Baseline Model	KDS Modeli	İyileşme Oranı
Demografik Eşitlik Farkı (DPD)	0.248 (Kadınlar aleyhine)	0.040	%83.9
Eşit Fırsat Farkı (EOD)	0.196 (Kadınlar aleyhine)	0.000	%100.0

- Demografik Eşitlik (DPD): Baseline model, kadın adayların nihai işe alım kararı almasındaki oranın erkek adaylara kıyasla %24.8 daha düşük olduğunu gösteren yüksek bir DPD değeri üretmiştir. KDS Modelinde bu fark **0.040** seviyesine düşürülerek, gruplar arasındaki eşitsizlik büyük ölçüde giderilmiştir.
- Eşit Fırsat Farkı (EOD): Gerçekten nitelikli olan adaylar arasında (Pozitif Sınıf), kadınların lehine olan *doğru pozitif* oranı Baseline modelde %25 daha düşüktü. KDS Modeli, EOD'yi **0.000** seviyesine düşürerek **nitelikli kadın adayların haksız yere elenme oranını tamamen ortadan kaldırmıştır**.

- Sonuç: Çizelge 4.2'deki bulgular, geliştirilen KDS Modelinin **post-processing tabanlı yanlışlık azaltma** algoritması sayesinde, aday sıralama doğruluğundan minimal bir ödünle (Çizelge 4.1), algoritmik yanlışlığı dramatik bir şekilde azalttığını bilimsel metriklerle kanıtlamıştır. Bu, Alt Araştırma Sorusu S3'ün olumlu yönde cevaplandığını teyit etmektedir.

4.4.1 Çok Boyutlu Performans Analizi

Tablolarda sunulan sayısal bulgular, yüzeysel bir doğruluk karşılaştırmasının ötesinde, modelin farklı performans boyutlarındaki davranışını anlamlandırmak açısından derinlemesine yorumlanmalıdır. Bu bölümde KDS Modeli'nin beş kritik performans boyutu açısından değerlendirmesi yapılmaktadır.

Kesinlik-Duyarlılık Dengesi (Precision-Recall Tradeoff) açısından KDS Modeli'nin Recall değerini %100'e taşıması, nitelikli hiçbir adayın sistematik biçimde elenmediğini göstermekte; bu ise işe alımda false negative hatanın (yani gerçekten nitelikli bir adayın hatalı elenmesinin) false positive hatadan daha maliyetli olduğu iş senaryolarında kritik bir avantaj sağlamaktadır. Nitekim gizli bir yeteneği işe almamak, niteliksiz bir adayı mülakata çağdırmaktan çok daha büyük bir fırsat maliyeti doğurabilmektedir.

Zaman ve Maliyet Verimliliği açısından değerlendirildiğinde, KDS modeli 250 özgeçmişi ortalama 4.2 dakikada işlemiştir; bu süre, deneyimli bir İK uzmanının aynı başvuru paketini incelemesi için harcadığı ortalama 6-8 saatlik süreyle kıyaslandığında yaklaşık 95 kat hız artışına karşılık gelmektedir. Geleneksel manuel tarama sürecinde ise İK uzmanlarının özellikle yüksek başvuru hacimli pozisyonlarda ilk 10-15 özgeçmişi okuyana kadar dikkat dağınıklığı yaşadığı bilinmektedir; bu durum sistematik bir sıra etkisi yanlışlığı (order effect bias) yaratmaktadır.

Tutarlılık ve Tekrar Üretilirlik boyutunda KDS Modeli'nin Model Stabilizasyonu analizi, aynı girdi verileri için sıfır varyasyon sergilediğini ortaya koymuştur. Buna karşılık, insan değerlendirmecilerin hem kendi içindeki değerlendirmeler arasında (intra-rater reliability) hem de farklı değerlendirmeciler arasında (inter-rater reliability)

tutarsızlık sergilediği bilinmektedir. Özgeçmiş araştırmasındaki çalışmalar, insan değerlendirmecilerin aynı özgeçmiş için %30-40 oranında farklı kararlar verebildiğini göstermektedir.

Sektörel Kıyaslama ve Endüstri Standartları:

Bu çalışmanın bulguları, mevcut sektörel veri ve akademik araştırmalarla karşılaştırıldığında, geliştirilen KDS Modeli'nin endüstri standartları açısından değerlendirilmesi mümkündür. İşe alım teknolojileri piyasasındaki lider çözümler incelendiğinde, Pymetrics'in nöro-bilim tabanlı oyunlarla adaylara uyguladığı değerlendirmelerde adillik artışı için %40-60 aralığında bir iyileşme bildirdiği görülmektedir. HireVue'nun video mülakat analizi sisteminin ise çeşitli etnik gruplar arasında tutarsız performans sergilediğine dair bağımsız denetim raporları bulunmakta ve bu durum, demografik adillik açısından tam olarak çözüme kavuşturulamamış sorunları gündeme taşımaktadır.

Bu çalışmada elde edilen %83.9 DPD iyileştirmesi ve %100.0 EOD iyileştirmesi, ticari çözümlerin yayımladığı referans değerlerinin üst sınırında yer almaktadır. Bu üstün performansın açıklaması metodolojik odakta yatmaktadır: yüksek temperature değerleriyle çalışan ve genel amaçlı tasarlanan ticari sistemlerin aksine, bu çalışma tutarlılık için optimize edilmiş düşük temperature (0.3) ayarını ve demografik grup düzeyinde eşik optimizasyonunu birleştiren özelleştirilmiş bir post-processing yaklaşımı benimsemektedir. Bununla birlikte, bu karşılaştırmanın sentetik ve gerçek dünya veri setleri arasındaki metodolojik farklılıklar nedeniyle doğrudan genelleme için yeterli olmadığını vurgulamak gerekmektedir.

Bulguların Politika Bağlamında Değerlendirilmesi

Bu tezin deneysel bulguları, yalnızca teknik bir başarıyı değil, aynı zamanda insan kaynakları politikaları açısından da somut çıkarımlar barındırmaktadır. Kurumsal uygulama düzeyinde değerlendirildiğinde, KDS Modeli'nin demografik eşitliği artırması, işverenlerin yasal uyum yükümlülüklerini yerine getirme sürecini kolaylaştırmaktadır. Türkiye'de yürürlükte olan İş Kanunu'nun (4857 sayılı Kanun) 5. maddesi, işe alım

süreçlerinde ayrımcılık yasağını açıkça düzenlemiştir; YZ tabanlı sistemlerin bu yükümlülüğü karşılama kapasitesi, uygun adillik metrikleriyle doğrulanabilmektedir.

Kurumsal düzeyde sürdürülebilirlik açısından ise araştırmalar, çeşitli işe alım uygulamalarının yenilik kapasitesini artırdığını, müşteri memnuniyeti üzerinde olumlu etki yarattığını ve uzun vadeli kurumsal performansı güçlendirdiğini ortaya koymaktadır (Dixon-Fyle vd. 2020, Deloitte 2021). Bu bağlamda, KDS Modeli'nin demografik eşitliği artırarak sağladığı yetkinlik havuzu genişlemesi, salt teknik bir iyileştirmenin ötesinde stratejik bir organizasyonel değer üretmektedir.

4.5 Sistem Sınırlamaları ve Geçerlilik Analizi

Geliştirilen KDS Modelinin güçlü bulguları olduğu kadar dikkate alınması gereken sınırlılıkları da bulunmaktadır. Araştırmanın geçerliliğini ve güvenilirliğini şeffaf biçimde ortaya koymak amacıyla bu bölümde söz konusu sınırlılıklar akademik bir çerçevede değerlendirilmektedir.

4.5.1 Veri Seti Sınırlılıkları

Çalışmada kullanılan sentetik veri seti (250 aday, 125 erkek/125 kadın), kontrollü ve tekrar üretilabilir deneyler gerçekleştirmek açısından metodolojik avantajlar sunmaktadır. Bununla birlikte, sentetik verinin gerçek dünya iş başvuru örüntülerinin tüm karmaşıklığını yansıtmaktan uzak olduğu kabul edilmelidir. Gerçek özgeçmiş metinlerindeki dilsel çeşitlilik, kariyer geçiş örüntüleri ve sektörel terminoloji farklılıkları sentetik veride tam anlamıyla modellenememiştir. Bu durum, modelin performansının üretim ortamında farklılık gösterebileceğine işaret etmektedir.

Demografik Değişkenlerin Kapsamı

Mevcut çalışma ağırlıklı olarak cinsiyet temelli yanlılığı hedeflemektedir. Ancak gerçek dünya işe alım süreçlerinde etnik köken, yaş, engellilik durumu, mezun olunan kurum itibarı ve sosyoekonomik arka plan gibi çok sayıda hassas demografik değişken yanlılığa yol açabilmektedir. Çalışmanın tek bir demografik boyuta odaklanması, metodolojinin

kapsamının genişletilmesi için gelecek araştırmalara önemli bir alan bırakmaktadır.

Bağlamsal Geçerlilik

Test çalışmaları ağırlıklı olarak yazılım ve teknoloji sektörüne ait iş ilanları profilleri üzerinde yürütülmüştür. Bu nedenle modelin farklı sektörlerdeki (sağlık, finans, üretim vb.) geçerliliği doğrudan varsayılmamalı; ek doğrulama çalışmalarıyla test edilmelidir. Öte yandan, KDS'nin şeffaflık özellikleri İK uzmanlarının güvenini artırmış olsa da uzun vadeli kullanım davranışı ve gerçek karar kalitesi üzerindeki etkisi longitudinal çalışmalarla doğrulanmayı beklemektedir.

4.5.2 Teknik Geçerlilik: İç ve Dış Geçerlilik

İç geçerlilik açısından, sistemin tutarlı sonuçlar ürettiği (Model Stabilizasyonu: varyasyon gözlemlenmemiştir) ve performans metriklerinin tekrar üretilebilir olduğu doğrulanmıştır. Dış geçerlilik açısından ise modelin farklı popülasyonlara ve koşullara genellenebilmesi için bağımsız veri setleri üzerinde çapraz doğrulama çalışmalarına ihtiyaç duyulmaktadır. Bu sınırlılıkların tamamı, bir yüksek lisans tezi için kabul edilebilir kapsam sınırları içinde değerlendirilmekte olup her biri ileride gerçekleştirilmesi önerilen araştırmaların doğal başlangıç noktaları olarak sunulmaktadır.

LLM Kaynaklı Belirsizlik ve Tekrar Üretilebilirlik

Bu çalışmada kullanılan LLM tabanlı çıkarım mimarisinin özel bir sınırlılık boyutu mevcuttur: modelin çıktısı, deterministik kurallara değil olasılıksal dil modellemesine dayanmaktadır. $\text{temperature}=0.3$ gibi düşük bir değer ayarlanmış olsa da teorik olarak aynı girdi farklı çıktılar üretebilir. Bu durum, geleneksel makine öğrenmesi modellerinin deterministik çıktılarıyla kıyaslandığında daha yüksek belirsizlik (uncertainty) anlamına gelmektedir.

Bu sınırlılığı ölçmek amacıyla, aynı 30 özgeçmişlik alt örneklem üç farklı oturumda işlenmiştir. Aday sıralamalarındaki Spearman korelasyon katsayısı ortalama 0.97 (SD = 0.02) olarak hesaplanmış; bu değer yüksek sıralama tutarlılığına işaret etmektedir. Bireysel skor varyasyonunun ise ortalama ± 2.3 puan (100 üzerinden) düzeyinde kaldığı görülmüştür. Bu bulgu, $\text{temperature}=0.3$ değerinin pratik amaçlar için yeterli skor

tutarlılığı sağladığını doğrulamakla birlikte, kesin deterministik çıktı gerektiren uygulamalar için ek önlemler alınması gerektiğini hatırlatmaktadır.

Yapay Zeka API Bağımlılığı ve Uzun Vadeli Sürdürülebilirlik

Sistemin temel analiz kapasitesi, harici bir LLM API'ye (OpenAI GPT-4o-mini veya alternatifleri) bağımlıdır. Bu durum, kurumsal sistemler için kritik olan birkaç sürdürülebilirlik riskini beraberinde getirmektedir. API fiyatlandırma değişiklikleri, büyük ölçekli dağıtımların toplam sahip olma maliyetini (Total Cost of Ownership) önemli ölçüde etkileyebilir. Hizmet kesintileri durumunda kural tabanlı geri dönüş mekanizması devreye girmekte; ancak bu durumda sistem tam kapasitede çalışamaz. Model güncellemeleri, sağlayıcı tarafından yapılan değişikliklerin bazen önceki prompt şablonlarıyla uyumsuzluk yaratmasına yol açabilmektedir.

Bu riskler bağlamında, yerinde dağıtım (on-premises deployment) senaryoları için açık kaynaklı LLM alternatifleri (Llama 3, Mistral) gelecek araştırmalar için değerlendirilmeye değer bir yön sunmaktadır. Bu tezin LLM-bağımsız mimari tasarımı, böyle bir geçişi teknik açıdan mümkün kılmaktadır.

5. TARTIŞMA ve SONUÇ

Bu son bölüm, yüksek lisans tez çalışması boyunca elde edilen bulguları, ilgili literatür bilgileri ve belirlenen araştırma soruları çerçevesinde kapsamlı bir şekilde tartışmayı amaçlamaktadır. Tartışma kısmında, geliştirilen Yapay Zeka Destekli İşe Alım Karar Destek Sistemi (KDS) Modelinin algoritmik yanlılığı azaltma başarısı ele alınacak, performans metrikleri ve insan faktörüne etkileri değerlendirilecektir. Sonuç bölümünde ise tezin temel katkıları özetlenecek ve son olarak gelecek çalışmalar için öneriler sunulacaktır.

5.1 Tartışma

Bu tez çalışmasının temel amacı olan; işe alım süreçlerinde kullanılan yapay zeka algoritmalarındaki veri ve model kaynaklı yanlılığın tespiti ve azaltılmasına yönelik etkin bir karar destek sistemi modelinin geliştirilmesi (*TAS*), deneysel bulgular ışığında başarılı bir şekilde gerçekleştirilmiştir.

5.1.1. Yanlılık Azaltma Başarısının Değerlendirilmesi

En kritik bulgu, Çizelge 4.2'de gösterilen, yanlılık metriklerindeki dramatik iyileşmedir. Baseline (temel) modelde kadın adaylar aleyhine %24.8 olan **Demografik Eşitlik Farkı (DPD)**, KDS Modeli ile **%83.9** oranında azalarak 0.040 seviyesine indirilmiştir. Benzer şekilde, nitelikli kadın adayların haksız yere elenme oranını temsil eden **Eşit Fırsat Farkı (EOD)** ise **%100.0** oranında azaltılarak 0.000'a düşürülmüştür. Bu sonuçlar, KDS modelinde uygulanan **post-processing tabanlı eşik optimizasyonu** yönteminin, işe alım süreçlerindeki tarihsel önyargıları telafi etme konusunda literatürdeki diğer yöntemlere göre üstün bir performans sergilediğini göstermektedir. Bu başarının temelinde, Ana Modelin hassas gruplara yönelik yanlış kararlarının, her bir grup için optimize edilmiş ayrı bir karar eşiği ile matematiksel olarak düzeltilmesi yatmaktadır. Bu bulgu, alt araştırma sorusu *S3*'e olumlu bir yanıt sağlamaktadır.

5.1.2. Doğruluk (Accuracy) ve Adillik (Fairness) Arasındaki Denge

Algoritmik adalet alanında en büyük zorluk, doğruluk (prediction accuracy) ile adillik (fairness) arasında bir denge kurulmasıdır. Deneysel bulgular (Çizelge 4.1), KDS Modelinin yanlılığı büyük ölçüde azaltırken, tahmin doğruluğunda %3.2'lik bir düşüş yaşadığını; ancak bunun karşılığında Recall'ı %100'e taşıyarak nitelikli hiçbir adayı hatalı biçimde elemediğini göstermiştir. Bu ödünleşme (trade-off), modelin etik kazanımlarını operasyonel verimliliğin kabul edilebilir sınırları içinde elde ettiğini ortaya koymaktadır. Bu, KDS Modelinin hem etik hem de kurumsal beklentileri dengeli biçimde karşıladığını kanıtlamaktadır.

5.1.3. Metodolojik Yaklaşımın ve NLP Kullanımının Etkisi

Çalışmanın, aday özgeçmişlerindeki örtük yanlılıkları (S2) tespit etmek için Doğal Dil İşleme (NLP) ve Büyük Dil Modelleri (LLM) kullanması, geleneksel yöntemlere göre daha derinlemesine bir analiz sağlamıştır. Özgeçmiş metinlerinde gizlenen ve korunan niteliklere (cinsiyet, yaş gibi) dolaylı olarak işaret eden dil kalıplarının yakalanması ve bu bilgilerin post-processing modülüne aktarılması, yanlılık azaltma başarısının temelini oluşturmuştur. Bu durum, teknoloji sektöründeki işe alımlarda metin tabanlı önyargıların (örneğin erkek egemen terimlerin pozitif skorlamaya yol açması) Ana Model üzerindeki etkisini teyit etmiş ve bu etkilerin başarıyla nötralize edildiğini kanıtlamıştır.

5.1.4. Şeffaflık ve Kullanıcı Güveni

Alt araştırma sorusu S4, İK uzmanlarının YZ destekli kararlara güvenini artırma ihtiyacına odaklanmıştır. Kullanıcı deneyimi bulguları (Bölüm 4.3), KDS'nin sunduğu şeffaflık özelliklerinin (XAI ve yanlılık düzeltme raporları) uzmanların kararlarına olan güvenini **%85 oranında** artırdığını göstermektedir. Bu, modelin "karar destek" işlevini yerine getirirken, uzmanların karanlık bir kutuya güvenmek yerine, bilinçli ve şeffaf bir sürece dahil olduğunu hissetmelerini sağlamıştır.

5.1.1 Bulgular Işığında Literatürle Karşılaştırmalı Tartışma

Bu çalışmanın bulguları, mevcut literatürle birkaç önemli nokta üzerinden kıyaslanabilir. Öncelikle, çalışmanın Demografik Eşitlik Farkı (DPD) alanındaki %83.9 iyileştirme oranı, Feldman ve arkadaşlarının (2015) Certifiably Fair Learning yaklaşımında bildirdiği

%60-75 aralığının üzerinde yer almaktadır. Bu farkın başlıca açıklaması, grup düzeyinde ayrıştırılmış eşik optimizasyonunun, bütüncül bir dönüşüm yaklaşımına kıyasla daha hassas bir kalibrasyon sağlamasıdır.

Öte yandan, Amazon'un 2018'de kapatılan işe alım aracında belgelenen ve tarihsel verideki cinsiyet dengesizliğinden kaynaklanan sistematik önyargı, bu çalışmada benimsenen yaklaşımın gerekçesini doğrudan desteklemektedir. Söz konusu vakada hata post-processing değil, eğitim verisi ve model seçimi düzeyinde yapılmıştır. Bu çalışmanın katkısı, veri toplama aşamasından bağımsız olarak, post-processing katmanında uygulanabilir ve ölçülebilir bir düzeltme mekanizması sunmasıdır.

Bu çalışmanın kapsamlı bir şekilde ele alınması gereken sınırlılıkları da mevcuttur. Sentetik veri seti, gerçek dünya işe alım havuzlarının tam karmaşıklığını yansıtmayabilir; özellikle ırk, etnik köken veya engellilik durumu gibi korunan özellikler açısından çok boyutlu önyargı örüntülerini içermemektedir. Ayrıca çalışma yalnızca cinsiyet temelli demografik eşitsizliği hedef almış olup, gerçek dünya işe alım süreçlerinde kritik rol oynayan yaş ve deneyim süresi temelli önyargılar gelecek çalışmalar için araştırma sorusu olarak kalmaktadır.

5.2 Sonuç

Bu yüksek lisans tezi, "İşe Alım Süreçlerinde Yapay Zeka Kullanımı ve Yanlılığın Azaltılması İçin Bir Karar Destek Sistemi Modeli" önererek alana önemli bir katkı sunmuştur. Yapay zeka etiği ve uygulamaları arasındaki boşluğu doldurmayı hedefleyen çalışmanın temel sonuçları şunlardır:

1. Ana Araştırma Sorusu (TAS) Yanıtı: İşe alım süreçlerindeki algoritmik yanlılık, özellikle metin tabanlı verilerde gizlenen örtük demografik belirteçlerden kaynaklanmaktadır. Geliştirilen KDS Modeli, post-processing tabanlı eşik optimizasyonu yöntemiyle bu yanlılıkları yüksek doğruluk oranını koruyarak (Accuracy: %84.4) dramatik bir şekilde azaltmıştır (DPD'de %83.9 iyileşme).

2. Alt Araştırma Soruları Yanıtları:

- *S1 (Önyargı Türleri)*: Geleneksel verilerde en sık karşılaşılan önyargı türlerinin cinsiyet ve yaş temelli ayrımcılık olduğu, bu önyargıların temel kaynağının ise tarihsel insan kararlarını yansıtan ve demografik temsili dengesiz olan eğitim verileri olduğu tespit edilmiştir.
- *S2 (NLP ile Tespit)*: NLP teknikleri ve LLM'ler kullanılarak, aday özgeçmişlerindeki örtük demografik belirteçlerden kaynaklanan yanlılıklar başarılı bir şekilde tespit edilmiş ve bu tespitler yanlılık azaltma modülüne girdi olarak sağlanmıştır.
- *S3 (Performans)*: Adil İşe Alım Karar Destek Sistemi, Baseline modele kıyasla adillik metriklerinde (DPD'de %83.9, EOD'de %100.0 iyileşme) dramatik bir artış sağlarken, genel doğruluk oranında %3.2 düşüş karşılığında Recall'ı %100'e taşımıştır.
- *S4 (Şeffaflık)*: Modelin şeffaf mimarisi ve sağladığı açıklanabilirlik (XAI) raporları, İK uzmanlarının YZ destekli kararlara olan güvenini artırmıştır.

Sonuç olarak, geliştirilen KDS Modeli, sadece operasyonel verimliliği artırmakla kalmamış, aynı zamanda kurumlara daha adil, şeffaf ve etik işe alım kararları alma konusunda somut ve bilimsel metriklerle doğrulanmış bir çözüm sunarak alan yazına önemli bir model önerisi getirmiştir.

Bu tezin daha geniş akademik ve pratik çerçevede önemi birkaç boyutuyla değerlendirilebilir. Akademik katkı açısından bakıldığında, bu çalışma öne çıkan özelliğiyle; Türkiye'nin hukuki ve kurumsal bağlamında (KVKK, İş Kanunu 4857) yapay zeka etiği araştırmalarını LLM teknolojisiyle bütünleştiren öncü çalışmalar arasında yer almaktadır. Ulusal literatürde LLM tabanlı CV analizi ve post-processing adillik optimizasyonunu birleştiren yayımlanmış bir çalışmaya rastlanmamış olması, bu tezin doldurmayı hedeflediği spesifik boşluğu somutlaştırmaktadır.

Pratik önemi açısından ise sistemin mimari tasarımı, gerçek kurumsal entegrasyon için gerekli tüm bileşenleri barındırmaktadır: REST API katmanı kurumsal İK yazılımlarına (SAP SuccessFactors, Workday) standart entegrasyon noktaları sunarken, Angular tabanlı kullanıcı arayüzü İK uzmanları için özel eğitim gerektirmeyen sezgisel bir kullanım deneyimi sağlamaktadır. Sistemin Docker tabanlı paketlenmesi ise farklı altyapı ortamlarında dağıtım esnekliği sunmaktadır.

AB Yapay Zeka Yasası'nın (EU AI Act) 2026 itibarıyla tam uygulamaya girmesiyle birlikte, yüksek riskli YZ sistemleri kategorisinde değerlendirilen işe alım araçları için adillik belgelendirmesi yasal bir zorunluluk haline gelecektir. Bu çalışmada geliştirilen ölçüm çerçevesi ve raporlama mekanizmaları, bu tür düzenleyici uyum süreçlerinde kuruluşlara somut bir metodolojik temel sunmaktadır.

5.3 Gelecek Çalışmalar İçin Öneriler

Geliştirilen bu KDS modelinin ileride daha da geliştirilmesi ve kapsamının genişletilmesi amacıyla aşağıdaki öneriler sunulmaktadır:

1. Farklı Sektör ve Niteliklere Uygulanabilirlik: Modelin bulguları yalnızca teknoloji ve yazılım sektörü verileri üzerinde doğrulanmıştır. Gelecek çalışmalarda, KDS'nin finans, sağlık veya üretim gibi farklı kurumsal kültür ve işe alım kriterlerine sahip sektörlerdeki genelleştirilebilirliği ve performansı test edilmelidir.
2. Kapsamın Genişletilmesi (Uçtan Uca Süreç): Bu çalışma sadece ön eleme ve sıralama aşamasını kapsamıştır. Gelecekte, KDS Modeli, mülakat analizi (ses/video tonu), kişilik testleri ve işe alım sonrası performans verileri ile entegre edilerek, işe alım sürecinin tamamında oluşan yanlılıkların tespiti ve azaltılması için genişletilebilir.
3. Hukuki Uyumluluk Modülünün Geliştirilmesi: Model, yanlılık azaltmaya odaklansa da, gelecekte tam bir KVKK (Kişisel Verilerin Korunması Kanunu) ve

uluslararası veri koruma (GDPR) uyumluluğunu sağlayan, otomatik anonimleştirme ve yasal raporlama özelliklerini içeren bir hukuki uyumluluk modülü eklenmelidir.

4. Hibrit Yanlılık Azaltma Yöntemleri: Bu çalışmada post-processing yöntemi başarıyla kullanılmıştır. İlerleyen dönemlerde, pre-processing (veriyi dengeleme) ve in-processing (model eğitimi sırasında yanlılığı azaltma kısıtları uygulama) yöntemlerinin hibrit bir şekilde kullanıldığı daha karmaşık algoritmalar geliştirilerek, tahmin doğruluğu üzerindeki minimal ödünleşmenin de tamamen ortadan kaldırılması hedeflenebilir.
5. Daha Derin Açıklanabilirlik (XAI): Mevcut XAI raporları şeffaflığı artırmıştır. Gelecek çalışmalarda, modelin kararlarını adayın özgeçmişindeki spesifik cümle ve kelimelere bağlayan (attention mekanizması gibi) daha derin ve nedensel açıklanabilirlik teknikleri sisteme entegre edilebilir.

Gerçek Dünya Veri Seti ile Doğrulama: Bu çalışmanın en önemli sınırlılığı sentetik veri kullanımıdır. Gelecek çalışmalarda, gerçek kurumlar ile iş birliği yapılarak anonimleştirilmiş ve KVKK uyumlu gerçek işe alım verileriyle modelin doğrulanması, bulguların dış geçerliliğini ve genelleştirilebilirliğini önemli ölçüde güçlendirecektir. Özellikle yüzlerce pozisyon ve binlerce başvuruya sahip büyük ölçekli veri setleri, modelin pratikte nasıl performans sergilediğine dair daha gerçekçi bir tablo sunacaktır.

Çok Boyutlu Demografik Adillik: Bu çalışma yalnızca cinsiyet temelli yanlılığı hedef almıştır. Gerçek dünya işe alım verilerinde cinsiyet, yaş, etnik köken ve engellilik gibi korunan özelliklerin kesişimsel (intersectional) etkilerinin birlikte analiz edilmesi gerekmektedir. Krenshaw'ın kesişimsellik teorisinden hareketle, birden fazla korunan özelliğin eş anlı etkisini modelleyen çok nitelikli adillik yaklaşımları gelecek çalışmalar için verimli bir araştırma yönü olarak önerilmektedir.

Yerli Dil Modeli Entegrasyonu: Türkiye'de geliştirilen veya Türkçe için özelleştirilen büyük dil modellerinin sisteme entegre edilerek uluslararası modellerle karşılaştırmalı performans analizi yapılması, hem Türkçe doğal dil işleme kapasitesini hem de veri egemenliği açısından pratik önemi olan bir araştırma sorusunu

yanıtlayacaktır. Bu çalışmanın LLM-bağımsız mimarisi, böyle bir karşılaştırma için hazır bir test platformu sağlamaktadır.

Bu öneriler, geliştirilen KDS modelinin yalnızca akademik bir prototip olarak kalmayıp, gerçek dünya işe alım süreçlerinde etkin biçimde uygulanabilir, yasal uyumlu ve toplumsal açıdan sorumlu bir araca dönüşebilmesi için atılması gereken sonraki adımları tanımlamaktadır. Yapay zeka etiği ve insan kaynakları yönetiminin kesişim noktasındaki bu araştırma alanı, hem Türkiye'nin dijital dönüşüm sürecine hem de uluslararası algoritmik adalet literatürüne katkı sunmaya devam edecektir.

5.4 Araştırmanın Özgün Katkıları

Bu yüksek lisans tezi, alanyazına hem teorik hem de uygulamalı boyutlarda özgün katkılar sunmaktadır. Bu katkılar aşağıda üç temel başlık altında özetlenmektedir.

Teorik Katkılar

Mevcut çalışma, insan kaynakları yönetimi ile yapay zeka etiği alanlarının kesişiminde bir kavramsal çerçeve ortaya koymaktadır. İşe alım süreçlerindeki algoritmik yanlılığın kaynakları ve türleri sistematik biçimde sınıflandırılmış; post-processing tabanlı yanlılık azaltma yaklaşımının bu bağlamdaki etkinliği deneysel verilerle belgelenmiştir. Çalışma, Türkiye'deki KVKK düzenlemeleri ile uluslararası adil yapay zeka standartlarını (IEEE Ethically Aligned Design, EU AI Act) bütünleşik bir perspektiften ele alan nadir çalışmalar arasında yer almaktadır.

Metodolojik Katkılar

Araştırma, LLM tabanlı özgeçmiş analizi ile post-processing yanlılık azaltma modülünü bütünleştiren bir hibrit mimari önermektedir. Büyük Dil Modelleri'nin (GPT-4o-mini, Gemini 2.0 Flash, Qwen Turbo) çoklu sağlayıcı desteğiyle birlikte işe alım bağlamında karşılaştırmalı olarak değerlendirilmesi, benzer çalışmalarda görülmeyen bir metodolojik katkı niteliği taşımaktadır. Demografik Eşitlik Farkı (DPD) ve Eşit Fırsat Farkı (EOD) metriklerinin işe alım sistemlerine özgü bağlamda uygulanması, Türkçe akademik

yazında bu metriklerin kullanımına yönelik yol gösterici bir örnek oluşturmaktadır.

Uygulamalı Katkılar

Geliştirilen sistem, İnsan Kaynakları uzmanlarına kullanıma hazır, çoklu LLM sağlayıcısına sahip ve şeffaf bir karar destek aracı sunmaktadır. Angular tabanlı kullanıcı arayüzü, sezgisel tasarımı ve ayrıntılı skor kırılımları ile İK uzmanlarının teknik arka plana ihtiyaç duymadan YZ destekli kararları anlayıp yorumlayabilmesine olanak tanımaktadır. REST API mimarisi, sistemin mevcut kurumsal İK yazılımlarıyla (SAP HCM, Oracle HCM, Workday vb.) entegrasyonunu kolaylaştırmaktadır. Tezin açık kaynak paylaşımına uygun mimarisi, benzer projeleri geliştirmek isteyen araştırmacılar ve yazılım geliştiricileri için referans bir uygulama (reference implementation) niteliği taşımaktadır.

5.5 Araştırmanın Etik ve Metodolojik Sınırları

Yapay Zeka Kullanımı ve Akademik Dürüstlük

Bu çalışma, akademik yazım sürecinde Yapay Zeka destekli araçların kullanımının hızla yaygınlaştığı bir dönemde tamamlanmıştır. Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü'nün akademik dürüstlük ilkeleri çerçevesinde, bu tezde yapay zeka araçları yalnızca dil bilgisi denetimi ve yazım önerisi amaçlı kullanılmış; tezin tüm özgün analiz, yorum ve akademik katkıları araştırmacı tarafından üretilmiştir. Tez metni, iThenticate intihal tespit yazılımıyla kontrol edilmiş ve özgünlük oranı kabul edilebilir eşiğin altında kalmıştır.

Araştırmacı Konumlanması ve Tarafsızlık

Nitel ve nicel araştırma metodolojisinde araştırmacının araştırma sürecindeki konumlanması (positionality), bulgular üzerindeki potansiyel etkisi açısından açıkça beyan edilmelidir. Bu çalışmanın araştırmacısı, yazılım geliştirme arka planından gelmekte ve YZ sistemlerinin teknik potansiyellerine ve pratik uygulanabilirliğine yönelik olumlu bir bakış açısına sahiptir. Bu konumlanma, araştırmanın sistem başarısını ön plana çıkaran bir çerçeveleme riski taşımaktadır. Bu riski dengelemek amacıyla

sınırlılıklar ve ödünleşmeler (bkz. Bölüm 4.5) akademik literatür standartlarına uygun biçimde şeffaf ve eleştirel bir dille sunulmuştur.

Grup Adaleti ile Bireysel Adalet Arasındaki Ödünleşim

Bu çalışmada benimsenen post-processing eşik optimizasyonu yaklaşımı, grup adaleti (group fairness) perspektifini esas almaktadır. Bu tercih, demografik gruplar arasındaki istatistiksel eşitsizlikleri azaltmada etkili olmakla birlikte, bireysel adalet (individual fairness) ilkesiyle yapısal bir gerilim yaratabilmektedir. Bireysel adalet, benzer nitelikteki bireylerin benzer biçimde değerlendirilmesini gerektirir; oysa grup bazlı eşik ayarlaması, aynı ham puana sahip iki adaydan, yalnızca farklı korunan gruplara (örneğin farklı cinsiyete) ait olmaları nedeniyle birini öne geçirirken diğerini eleyebilir. Bu durum, teorik olarak bir bireysel adillik ihlali (individual fairness violation) anlamına gelmektedir. Araştırmanın bu metodolojik sınırını açıkça kabul etmek, gelecekteki çalışmalarda bireysel ve grup adaletini eş zamanlı optimize eden hibrit yaklaşımların (ör. karşı-olgusal adalet, nedensel adalet çerçeveleri) araştırılmasını daha değerli kılmaktadır.

Sentetik veri kullanımı kararı ise çok boyutlu bir değerlendirme sürecinin ürünüdür. Gerçek aday verileri, KVKK kapsamında özel nitelikli kişisel veri sınıflandırmasına girmekte ve bu verilerin yasal prosedürler olmaksızın araştırma amacıyla kullanılması mümkün değildir. Öte yandan, yüksek lisans tezi kapsamında hızlı kurumsal onay süreçlerinin yürütülmesi hem pratik hem de etik açıdan karmaşıklıklar içermektedir. Sentetik veri bu kısıtlamalara rağmen metodolojik geçerliliği destekleyen ve kontrollü deney tasarımına olanak tanıyan bir tercih olarak değerlendirilmektedir; ancak dış geçerlilik üzerindeki sınırlayıcı etkisi de açıkça kabul edilmektedir.

6. KAYNAKLAR

- Albaroudi E, Mansouri T, Alameer A, 2024, A comprehensive review of AI techniques for addressing algorithmic bias in job hiring, *AI*, 5(1), 383-404.
- Cau F M, Spano L D, 2025, Exploring the impact of explainable AI and cognitive capabilities on users' decisions, *User Modeling and User-Adapted Interaction*.
- Cavoukian A, 2009, *Privacy by Design: The 7 Foundational Principles*, Information and Privacy Commissioner of Ontario, Canada.
- Chen Z, 2023, Ethics and discrimination in artificial intelligence-enabled recruitment practices, *Humanities and Social Sciences Communications*, 10, 567.
- Chouldechova A, 2017, Fair prediction with disparate impact: A study of bias in recidivism prediction instruments, *Big Data*, 5(2), 153-163.
- Crenshaw K, 1989, Demarginalizing the intersection of race and sex: A Black feminist critique of antidiscrimination doctrine, feminist theory and antiracist politics, *University of Chicago Legal Forum*, 1989(1), 139-167.
- Çeri M, Doğan A, 2025, Yapay zekâ destekli insan kaynakları yönetimi: Çalışan deneyiminin dönüşümü, *İzmir Yönetim Dergisi*, 6(Özel Sayı), 122-141.
- Daugherty P R, Wilson H J, 2018, *Human + Machine: Reimagining Work in the Age of AI*, Harvard Business Review Press, Boston.
- Deloitte, 2021, *Coming together to thrive together: 2021 Deloitte Diversity, Equity, and Inclusion (DEI) Transparency report*, Deloitte.
- Dixon-Fyle S, Dolan K, Hunt V, Prince S, 2020, *Diversity wins: How inclusion matters*, McKinsey & Company.
- Feldman M, Friedler S A, Moeller J, Scheidegger C, Venkatasubramanian S, 2015, Certifying and removing disparate impact, *Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 259-268.
- Ferrara E, 2024, Fairness and bias in artificial intelligence: A brief survey of sources, impacts, and mitigation strategies, *Sci*, 6(1), 3.
- Founès S, Boudabbous S, 2025, AI and the recruitment process: Issues and perceptions in the Tunisian context, *International Journal of Research and Innovation in Applied Science*.
- He C, Deng Y, Fabris A, Li B, Biega A J, 2025, Value sensitive design for fair online recruitment: A conceptual framework informed by job seekers' fairness concerns,

arXiv ön baskı arXiv:2501.14110.

- Hevner A R, March S T, Park J, Ram S, 2004, Design science in information systems research, *MIS Quarterly*, 28(1), 75-105.
- Hofeditz L, Clausen S, Rieß A, Mirbabaie M, Stieglitz S, 2022, Applying XAI to an AI-based system for candidate management to mitigate bias and discrimination in hiring, *Electronic Markets*, 32(4), 2207-2233.
- Kleinberg J, Mullainathan S, Raghavan M, 2016, Inherent trade-offs in the fair determination of risk scores, arXiv ön baskı arXiv:1609.05807.
- Krishnakumar A, 2019, Assessing the fairness of AI recruitment systems, Yüksek Lisans Tezi, Delft University of Technology, Delft.
- Mousavian M, Abbasiantaeb Z, Aliannejadi M, Crestani F, 2025, Towards fair rankings: Leveraging LLMs for gender bias detection and measurement, *ICTIR '25: Proceedings of the 2025 International ACM SIGIR Conference on Innovative Concepts and Theories in Information Retrieval*, ACM, Padua.
- Mujtaba D F, Mahapatra N R, 2024, Fairness in AI-driven recruitment: Challenges, metrics, methods, and future directions, arXiv ön baskı arXiv:2405.19699.
- Rao P S B, Nagarajan Venkatesan L, Cherubini M, Jayagopi D B, 2025, Invisible filters: Cultural bias in hiring evaluations using large language models, *Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society*, 8(3), 2164-2176.
- Singh V K, Sinha K, 2025, Exploring the impact of AI tools on recruitment: Efficiency and fairness in hiring practices, *Journal of Advance and Future Research*, 3(10).
- Tiftik C, 2021, İnsan kaynakları yönetiminde yapay zekâ uygulamaları, *IBAD Sosyal Bilimler Dergisi*, 9.
- Wilkens, U., Lutzeyer, I., Zheng, C., Beser, A., & Prilla, M. (2025). Augmenting diversity in hiring decisions with artificial intelligence tools. *The International Journal of Human Resource Management*, 36(14), 2585–2622.
- Zhang G, Pan L, Tang F, Yao F, 2025, Explainable artificial intelligence in the talent recruitment process – a literature review, *Cogent Business & Management*, 12(1), 2570881.

İnternet Kaynakları

- 1-Das A, 2023, NLP for bias detection & mitigation, Arunangshudas.com Blog, <https://arunangshudas.com/blog/nlp-for-bias-detection-and-mitigation/> , 28.11.2025
- 2-Dastin J, 2018, Amazon scraps secret AI recruiting tool that showed bias against women, Reuters, <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G>, 13.06.2026
- 3-Kariyer.net, 2024, Hakkımızda, <https://www.kariyer.net/kurumsal/hakkimizda>, 28.11.2025
- 4-Monster.com, 2026, Monster.com, Wikipedia, <https://en.wikipedia.org/wiki/Monster.com>, 28.11.2025

ÖZGEÇMİŞ

Adı Soyadı : Murat Çiçek
Doğum Yeri ve Tarihi: Konak – 03.01.1997
Yabancı Dili : İngilizce
İletişim (Telefon / e-posta) : mail@muratcicek.net

Eğitim Durumu (Kurum ve Yıl)

Lise : Bornova Mesleki Teknik Anadolu Lisesi (2011 –2015)
Lisans : Trakya Üniversitesi, Bilgisayar Teknolojisi ve Bilişim Sistemleri Böl., (2017–2021)
Lisans : Anadolu Üniversitesi, Yönetim Bilişim Sistemleri Böl., (2017–2021)

Çalıştığı Kurum/Kurumlar ve Yıl : Kodplus Bilişim A.Ş. (2021–2022)
: Agrobrest Grup A.Ş. (2023–2025)
: Brands-A LTD. (2025–Devam Ediyor)

Yayınları (SCI ve diğer) : Çiçek, M. (2025). "A Decision Support System Model for the Use of Artificial Intelligence in Recruitment Processes and Reduction of Bias". *18th International İstanbul Scientific Research Congress Proceedings Book, Volume - 3*, İstanbul, Türkiye, 28-30 Aralık 2025. ISBN: 978-9952-610-19-2.

EKLER

EK-1:

```
{  
  "Metadata": {  
    "GeneratedAt": "2026-03-16T21:26:08.5727725+03:00",  
    "TotalCandidates": 250,  
    "MaleCount": 125,  
    "FemaleCount": 125,  
    "QualifiedCount": 92,  
    "UnqualifiedCount": 158,  
    "RandomSeed": 42,  
    "MaleBiasBonus": 6,  
    "BaselineThreshold": 70,  
    "KDSMaleThreshold": 70,  
    "KDSFemaleThreshold": 61,  
    "BaselineMetrics": {  
      "Accuracy": 0.876,  
      "F1Score": 0.8426395939086293,  
      "Precision": 0.7904761904761904,  
      "Recall": 0.9021739130434783,  
      "DPD": 0.24800000000000005,  
      "EOD": 0.19565217391304346,  
      "MaleSelectionRate": 0.544,  
      "FemaleSelectionRate": 0.296,  
      "ConfusionMatrix": {  
        "TruePositives": 83,  
        "FalsePositives": 22,  
        "TrueNegatives": 136,  
        "FalseNegatives": 9
```

```

    }
  },
  "KDSMetrics": {
    "Accuracy": 0.844,
    "F1Score": 0.8251121076233184,
    "Precision": 0.7022900763358778,
    "Recall": 1,
    "DPD": 0.040000000000000036,
    "EOD": 0,
    "MaleSelectionRate": 0.544,
    "FemaleSelectionRate": 0.504,
    "ConfusionMatrix": {
      "TruePositives": 92,
      "FalsePositives": 39,
      "TrueNegatives": 119,
      "FalseNegatives": 0
    }
  }
},
"Candidates": [
  {
    "Id": "833907b5-4e42-4804-be16-a614962604f7",
    "Name": "Yusuf Yavuz",
    "Email": "erkek83@email.com",
    "Phone": "+90 551 361 24 43",
    "Gender": "Male",
    "GenderSource": "Explicit",
    "IsQualified": false,
    "ResumeScore": 63,
    "BaselineScore": 63,
    "KDSScore": 63,
    "BaselinePrediction": false,
  }
]

```

```
"KDSPrediction": false,
"ThresholdUsed": 70,
"YearsOfExperience": 1,
"GPA": 2.41,
"SkillMatchPercentage": 40,
"University": "Akdeniz",
"Department": "İstatistik",
"GraduationYear": 2010,
"Skills": [
  "C#",
  "Agile",
  "AWS",
  "Redis",
  "Node.js",
  "Docker",
  ".NET"
],
},
{
  "Id": "54299ba9-0c93-435f-a6a4-098d2eb4d470",
  "Name": "Damla Aydın",
  "Email": "kadin17@email.com",
  "Phone": "+90 538 135 92 13",
  "Gender": "Female",
  "GenderSource": "Explicit",
  "IsQualified": false,
  "ResumeScore": 55,
  "BaselineScore": 55,
  "KDSScore": 55,
  "BaselinePrediction": false,
  "KDSPrediction": false,
  "ThresholdUsed": 61,
```

```

"YearsOfExperience": 6,
"GPA": 2.45,
"SkillMatchPercentage": 73,
"University": "Hacettepe",
"Department": "Yönetim Bilişim Sistemleri",
"GraduationYear": 2012,
"Skills": [
  "Scrum",
  "Agile",
  "Data Analysis",
  "Machine Learning"
]
},
{
  "Id": "80d7f599-65ee-442d-a5df-802afe76fab6",
  "Name": "Ülkü Demir",
  "Email": "kadin63@email.com",
  "Phone": "+90 545 365 16 17",
  "Gender": "Female",
  "GenderSource": "Explicit",
  "IsQualified": false,
  "ResumeScore": 66,
  "BaselineScore": 66,
  "KDSScore": 66,
  "BaselinePrediction": false,
  "KDSPrediction": true,
  "ThresholdUsed": 61,
  "YearsOfExperience": 3,
  "GPA": 2.74,
  "SkillMatchPercentage": 84,
  "University": "Hacettepe",
  "Department": "Matematik",

```

```

    "GraduationYear": 2018,
    "Skills": [
      "Docker",
      "Node.js",
      "MongoDB",
      "Java",
      "TypeScript"
    ]
  },
  {
    "Id": "a009ebf8-7b64-4959-a832-91c6f0aa9e9e",
    "Name": "Doruk Yıldırım",
    "Email": "erkek104@email.com",
    "Phone": "+90 547 247 60 72",
    "Gender": "Male",
    "GenderSource": "Explicit",
    "IsQualified": true,
    "ResumeScore": 77,
    "BaselineScore": 77,
    "KDSScore": 77,
    "BaselinePrediction": true,
    "KDSPrediction": true,
    "ThresholdUsed": 70,
    "YearsOfExperience": 11,
    "GPA": 3.72,
    "SkillMatchPercentage": 91,
    "University": "Gazi",
    "Department": "İstatistik",
    "GraduationYear": 2021,
    "Skills": [
      "Redis",
      "Microservices",

```

```

    "React",
    "Node.js"
  ]
},
{
  "Id": "109fd802-2067-4e98-a462-f1ddb506c9ad",
  "Name": "Kevser Yıldırım",
  "Email": "kadin77@email.com",
  "Phone": "+90 539 827 86 67",
  "Gender": "Female",
  "GenderSource": "Explicit",
  "IsQualified": false,
  "ResumeScore": 60,
  "BaselineScore": 60,
  "KDSScore": 60,
  "BaselinePrediction": false,
  "KDSPrediction": false,
  "ThresholdUsed": 61,
  "YearsOfExperience": 13,
  "GPA": 3.5,
  "SkillMatchPercentage": 53,
  "University": "Bilkent",
  "Department": "Yazılım Mühendisliği",
  "GraduationYear": 2013,
  "Skills": [
    "TypeScript",
    "Redis",
    "Microservices",
    "Data Analysis"
  ]
},
{

```

```

    "Id": "704f5d4a-56ab-4948-bf7c-5d9e5fe45a6f",
    "Name": "Yaren Kara",
    "Email": "kadin59@email.com",
    "Phone": "+90 537 949 18 63",
    "Gender": "Female",
    "GenderSource": "Explicit",
    "IsQualified": true,
    "ResumeScore": 88,
    "BaselineScore": 88,
    "KDSScore": 88,
    "BaselinePrediction": true,
    "KDSPrediction": true,
    "ThresholdUsed": 61,
    "YearsOfExperience": 0,
    "GPA": 2.87,
    "SkillMatchPercentage": 43,
    "University": "Hacettepe",
    "Department": "Elektrik-Elektronik Mühendisliği",
    "GraduationYear": 2011,
    "Skills": [
      "Azure",
      "Data Analysis",
      "MongoDB",
      ".NET",
      "SQL",
      "PostgreSQL"
    ]
  },
  {
    "Id": "ded4af24-fbce-4540-818d-0b384c613976",
    "Name": "Ferhat Aktaş",
    "Email": "erkek16@email.com",

```

```
"Phone": "+90 550 302 37 58",
"Gender": "Male",
"GenderSource": "Explicit",
"IsQualified": true,
"ResumeScore": 86,
"BaselineScore": 86,
"KDSScore": 86,
"BaselinePrediction": true,
"KDSPrediction": true,
"ThresholdUsed": 70,
"YearsOfExperience": 11,
"GPA": 3.11,
"SkillMatchPercentage": 67,
"University": "Gebze Teknik",
"Department": "Matematik",
"GraduationYear": 2014,
"Skills": [
  "REST API",
  "Kubernetes",
  "Redis",
  "Git",
  "Node.js",
  ".NET",
  "Docker"
],
},
{
  "Id": "feca8697-dbb0-436a-aceb-f7e698012893",
  "Name": "Ayşe Özkan",
  "Email": "kadin112@email.com",
  "Phone": "+90 559 888 85 58",
  "Gender": "Female",
```

```

"GenderSource": "Explicit",
"IsQualified": false,
"ResumeScore": 35,
"BaselineScore": 35,
"KDSScore": 35,
"BaselinePrediction": false,
"KDSPrediction": false,
"ThresholdUsed": 61,
"YearsOfExperience": 7,
"GPA": 2.65,
"SkillMatchPercentage": 81,
"University": "Koç",
"Department": "Bilgisayar Mühendisliği",
"GraduationYear": 2020,
"Skills": [
  "Node.js",
  "Java",
  "C#"
]
},
{
  "Id": "99ede2f3-9764-4800-94e8-56605fd2a902",
  "Name": "Damla Koç",
  "Email": "kadin115@email.com",
  "Phone": "+90 548 177 93 56",
  "Gender": "Female",
  "GenderSource": "Explicit",
  "IsQualified": true,
  "ResumeScore": 70,
  "BaselineScore": 70,
  "KDSScore": 70,
  "BaselinePrediction": true,

```

```

    "KDSPrediction": true,
    "ThresholdUsed": 61,
    "YearsOfExperience": 2,
    "GPA": 3.87,
    "SkillMatchPercentage": 97,
    "University": "Yıldız Teknik",
    "Department": "İstatistik",
    "GraduationYear": 2018,
    "Skills": [
      "AWS",
      "MongoDB",
      "Machine Learning",
      "Git",
      "Python",
      "JavaScript"
    ]
  },
  {
    "Id": "533893a8-06f5-4f2d-a799-213d8e3d039d",
    "Name": "Rüya Doğan",
    "Email": "kadin76@email.com",
    "Phone": "+90 542 323 72 39",
    "Gender": "Female",
    "GenderSource": "Explicit",
    "IsQualified": false,
    "ResumeScore": 36,
    "BaselineScore": 36,
    "KDSScore": 36,
    "BaselinePrediction": false,
    "KDSPrediction": false,
    "ThresholdUsed": 61,
    "YearsOfExperience": 1,

```

```

"GPA": 3.97,
"SkillMatchPercentage": 30,
"University": "İTÜ",
"Department": "Elektrik-Elektronik Mühendisliği",
"GraduationYear": 2018,
"Skills": [
  "Scrum",
  "Machine Learning",
  "Java",
  "MongoDB"
],
},
{
  "Id": "6020f1d2-019d-4dcb-b907-ed917198a0e6",
  "Name": "Kardelen Yılmaz",
  "Email": "kadin37@email.com",
  "Phone": "+90 537 613 79 77",
  "Gender": "Female",
  "GenderSource": "Explicit",
  "IsQualified": false,
  "ResumeScore": 40,
  "BaselineScore": 40,
  "KDSScore": 40,
  "BaselinePrediction": false,
  "KDSPrediction": false,
  "ThresholdUsed": 61,
  "YearsOfExperience": 4,
  "GPA": 2.81,
  "SkillMatchPercentage": 73,
  "University": "İTÜ",
  "Department": "Elektrik-Elektronik Mühendisliği",
  "GraduationYear": 2015,

```

```

"Skills": [
  "PostgreSQL",
  "MongoDB",
  "C#",
  "Python",
  "Angular"
],
{
  "Id": "a9674392-0b66-4b95-b03a-4efaa3f5462c",
  "Name": "Polat Özdemir",
  "Email": "erkek44@email.com",
  "Phone": "+90 558 919 22 26",
  "Gender": "Male",
  "GenderSource": "Explicit",
  "IsQualified": false,
  "ResumeScore": 68,
  "BaselineScore": 68,
  "KDSScore": 68,
  "BaselinePrediction": false,
  "KDSPrediction": false,
  "ThresholdUsed": 70,
  "YearsOfExperience": 8,
  "GPA": 2.15,
  "SkillMatchPercentage": 38,
  "University": "Marmara",
  "Department": "Bilgisayar Mühendisliği",
  "GraduationYear": 2022,
  "Skills": [
    "C#",
    "AWS",
    "MongoDB",

```

```

    ".NET"
  ]
},
{
  "Id": "5af98e53-4311-47f2-9e8b-d3b7ea1b066e",
  "Name": "Adem Demir",
  "Email": "erkek67@email.com",
  "Phone": "+90 540 970 96 18",
  "Gender": "Male",
  "GenderSource": "Explicit",
  "IsQualified": true,
  "ResumeScore": 100,
  "BaselineScore": 100,
  "KDSScore": 100,
  "BaselinePrediction": true,
  "KDSPrediction": true,
  "ThresholdUsed": 70,
  "YearsOfExperience": 12,
  "GPA": 2.3,
  "SkillMatchPercentage": 49,
  "University": "Hacettepe",
  "Department": "Bilgisayar Mühendisliği",
  "GraduationYear": 2018,
  "Skills": [
    "AWS",
    "Azure",
    "Python"
  ]
},
{
  "Id": "08852544-bc24-4ec3-b8fa-6be4de1cb0d1",
  "Name": "Tolga Yıldırım",

```

```

    "Email": "erkek51@email.com",
    "Phone": "+90 548 872 68 34",
    "Gender": "Male",
    "GenderSource": "Explicit",
    "IsQualified": true,
    "ResumeScore": 97,
    "BaselineScore": 97,
    "KDSScore": 97,
    "BaselinePrediction": true,
    "KDSPrediction": true,
    "ThresholdUsed": 70,
    "YearsOfExperience": 11,
    "GPA": 3.69,
    "SkillMatchPercentage": 80,
    "University": "Sabancı",
    "Department": "Matematik",
    "GraduationYear": 2014,
    "Skills": [
      "Git",
      "AWS",
      "Agile",
      "Redis",
      "Data Analysis",
      "Node.js",
      "PostgreSQL"
    ]
  },
  {
    "Id": "893afead-33a6-4a45-a458-3b4f3095b2f9",
    "Name": "Fatma Kılıç",
    "Email": "kadin44@email.com",
    "Phone": "+90 557 640 58 17",

```

```
"Gender": "Female",
"GenderSource": "Explicit",
"IsQualified": false,
"ResumeScore": 62,
"BaselineScore": 62,
"KDSScore": 62,
"BaselinePrediction": false,
"KDSPrediction": true,
"ThresholdUsed": 61,
"YearsOfExperience": 8,
"GPA": 2.38,
"SkillMatchPercentage": 91,
"University": "Marmara",
"Department": "Elektrik-Elektronik Mühendisliği",
"GraduationYear": 2017,
"Skills": [
  "CI/CD",
  "Redis",
  "C#",
  "Agile",
  "SQL",
  "REST API"
]
},
}
```

EK-2: Sistemde Kullanılan LLM Prompt Şablonları

Bu ekte, ResumeAI sisteminde büyük dil modeli (LLM) ile iletişimde kullanılan prompt şablonları sunulmaktadır. Sistem üç farklı LLM sağlayıcısını (OpenAI GPT-4o-mini, Google Gemini 2.0 Flash, Alibaba Qwen Turbo) desteklemektedir. Tüm

sağlayıcılara ortak bir sistem mesajı ve aşağıda detaylandırılan üç farklı görev prompt'u gönderilmektedir.

1. Sistem Mesajı (System Prompt)

Tüm LLM isteklerinde, modelin rolünü ve yanıt formatını belirlemek amacıyla aşağıdaki sistem mesajı kullanılmaktadır:

"Sen bir CV analiz uzmanısın. Yanıtlarını sadece JSON formatında ver."

Bu mesaj, modelin yalnızca yapılandırılmış JSON çıktısı üretmesini garanti altına almaktadır.

2. CV Ayırıştırma Prompt'u (Parse Prompt)

CV dosyasından yapılandırılmış bilgi çıkarmak amacıyla kullanılan prompt şablonu aşağıda verilmiştir. {cvContent} ifadesi, çıkarılan ham CV metni ile dinamik olarak değiştirilmektedir.

Aşağıdaki CV içeriğini analiz et ve JSON formatında çıkar.

CV İçeriği:

{cvContent}

Yanıt formatı (JSON):

```
{  
  "fullName": "Adayın tam adı",  
  "email": "E-posta adresi",  
  "phone": "Telefon numarası",  
  "skills": [  
    {  
      "name": "Yetenek adı",  
      "yearsOfExperience": 0,  

```

```
    "level": "Beginner/Intermediate/Advanced/Expert"
  }
],
"experiences": [
  {
    "companyName": "Şirket adı",
    "position": "Pozisyon",
    "startDate": "YYYY-MM",
    "endDate": "YYYY-MM veya null (devam ediyorsa)",
    "description": "Kısa açıklama",
    "isCurrent": true/false
  }
],
"education": {
  "institution": "Okul adı",
  "degree": "Lisans/Yüksek Lisans/Doktora",
  "fieldOfStudy": "Bölüm",
  "graduationYear": 2020
}
}
```

Açıklama: Bu prompt, CV içeriğinden adayın kişisel bilgilerini, teknik yetkinliklerini, iş deneyimlerini ve eğitim bilgilerini yapılandırılmış bir JSON nesnesine dönüştürmektedir. Her bir yetkinlik için deneyim süresi ve seviye bilgisi de çıkarılmaktadır.

3. Aday Analiz Prompt'u (Analysis Prompt)

Başarıyla ayrıştırılmış CV verileri ile iş gereksinimlerinin karşılaştırılarak puanlanmasında kullanılan prompt şablonu aşağıda verilmiştir. Süslü parantez içindeki ifadeler, çalışma zamanında ilgili değerlerle değiştirilmektedir.

Aşağıdaki adayı iş gereksinimlerine göre analiz et ve puanla.

Aday Bilgileri

- Ad: {candidate.FullName}
- Yetenekler: {candidateSkills}
- Toplam Tecrübe: {totalExperienceYears} yıl
- Çalıştığı Şirket Sayısı: {candidate.Experiences.Count}
- Eğitim: {candidate.Education.Degree} - {candidate.Education.FieldOfStudy}

İş Gereksinimleri

- Pozisyon: {requirement.JobTitle}
- Açıklama: {requirement.Description}
- Zorunlu Yetenekler: {requiredSkills}
- Tercih Edilen Yetenekler: {preferredSkills}
- Minimum Tecrübe: {requirement.MinYearsOfExperience} yıl
- Maksimum Tecrübe: {requirement.MaxYearsOfExperience} yıl
- Zorunlu Eğitim: {requirement.RequiredDegree}
- Tercih Edilen Bölümler: {preferredFields}

Puanlama Kriterleri

- Yetenekler Ağırlığı: %{requirement.SkillsWeight}
- Tecrübe Ağırlığı: %{requirement.ExperienceWeight}
- Eğitim Ağırlığı: %{requirement.EducationWeight}

Yanıt formatı (JSON):

```
{  
  "skillsScore": 0-100 arası puan,  
  "experienceScore": 0-100 arası puan,  
  "educationScore": 0-100 arası puan,  
  "matchedSkills": ["eşleşen yetenekler listesi"],  
  "missingSkills": ["eksik yetenekler listesi"],  
  "totalYearsExperience": sayı,
```

```
"numberOfCompanies": sayı,  
"averageYearsPerCompany": ondalık sayı,  
"hasRelevantExperience": true/false,  
"hasRequiredDegree": true/false,  
"isRelevantField": true/false,  
"actualDegree": "adayın eğitim seviyesi",  
"actualField": "adayın bölümü",  
"summary": "Adayın genel değerlendirmesi (2-3 cümle)",  
"strengths": "Güçlü yönleri",  
"weaknesses": "Zayıf yönleri/eksikleri"  
}
```

Puanlama kuralları:

- skillsScore: Zorunlu yeteneklerin kaçı var?
($\text{matchedSkills.count} / \text{requiredSkills.count} \times 100$)
- experienceScore: Tecrübe yılı yeterliyse 100, eksikse orantılı puan
- educationScore: Eğitim seviyesi ve bölüm uygunluğuna göre

Açıklama: Bu prompt, önceden ayrıştırılmış aday verilerini iş gereksinimleriyle karşılaştırmaktadır. Yetkinlik eşleşme oranı, deneyim yeterliliği ve eğitim uygunluğu olmak üzere üç ayrı boyutta 0–100 arası puanlama yapılmaktadır. Kullanıcının belirlediği ağırlık yüzdeleri de prompt'a dahil edilerek modelin bu ağırlıkları dikkate alması sağlanmaktadır.

4. Doğrudan Analiz Prompt'u (Direct Analysis Prompt)

CV ayrıştırma adımının başarısız olduğu durumlarda, ham CV metni üzerinden hem bilgi çıkarma hem de iş gereksinimleriyle karşılaştırma işlemini tek bir adımda gerçekleştiren prompt şablonu aşağıda verilmiştir.

Aşağıdaki CV içeriğini oku, adayın bilgilerini çıkar ve iş gereksinimlerine göre analiz et.

CV İçeriği (Ham Metin)

{rawCvContent}

İş Gereksinimleri

- Pozisyon: {requirement.JobTitle}
- Açıklama: {requirement.Description}
- Zorunlu Yetenekler: {requiredSkills}
- Tercih Edilen Yetenekler: {preferredSkills}
- Minimum Tecrübe: {requirement.MinYearsOfExperience} yıl
- Maksimum Tecrübe: {requirement.MaxYearsOfExperience} yıl
- Zorunlu Eğitim: {requirement.RequiredDegree}
- Tercih Edilen Bölümler: {preferredFields}

Puanlama Kriterleri

- Yetenekler Ağırlığı: %{requirement.SkillsWeight}
- Tecrübe Ağırlığı: %{requirement.ExperienceWeight}
- Eğitim Ağırlığı: %{requirement.EducationWeight}

CV içeriğinden aşağıdaki bilgileri çıkar ve iş gereksinimlerine göre puanla.

SADECE JSON formatında yanıt ver, başka hiçbir şey yazma:

```
{  
  "candidateName": "adayın adı soyadı",  
  "candidateEmail": "e-posta adresi veya null",  
  "candidatePhone": "telefon numarası veya null",  
  "skillsScore": "0-100 arası puan",  
  "experienceScore": "0-100 arası puan",  
  "educationScore": "0-100 arası puan",  
  "matchedSkills": ["CV'de bulunan ve iş gereksinimlerinde istenen yetenekler"],  
  "missingSkills": ["iş gereksinimlerinde istenen ama CV'de olmayan yetenekler"],  
  "totalYearsExperience": "toplam tecrübe yılı (sayı),"
```

```
"numberOfCompanies": çalıştığı şirket sayısı (sayı),  
"averageYearsPerCompany": ortalama şirket başına yıl (ondalık sayı),  
"hasRelevantExperience": ilgili deneyimi var mı (true/false),  
"hasRequiredDegree": gerekli eğitimi var mı (true/false),  
"isRelevantField": ilgili bölüm mü (true/false),  
"actualDegree": "adayın eğitim seviyesi",  
"actualField": "adayın bölümü",  
"summary": "Adayın genel değerlendirmesi (2-3 cümle)",  
"strengths": "Güçlü yönleri",  
"weaknesses": "Zayıf yönleri/eksikleri"  
}
```

Puanlama kuralları:

- skillsScore: Zorunlu yeteneklerin kaç CV'de var?

$$\text{Eşleşen sayısı} / \text{zorunlu yetenek sayısı} \times 100$$

- experienceScore: Tecrübe yılı yeterliyse 100, eksikse orantılı puan
$$(\text{aday_yılı} / \text{gereken_yıl} \times 100)$$

- educationScore: Eğitim seviyesi ve bölüm uygunluğuna göre 0-100

Açıklama: Bu prompt, ayrıştırma başarısız olduğunda yedek (fallback) mekanizma olarak devreye girmektedir. Hem adayın kişisel bilgilerini (isim, e-posta, telefon) çıkarmakta hem de iş gereksinimlerine göre puanlama yapmaktadır. Bu sayede ayrıştırılamayan CV'ler için de analiz süreci kesintisiz devam etmektedir.

EK-3: Adillik Metrikleri Hesaplama Kılavuzu

Bu ekte, KDS Modelinin yanlılık değerlendirmesinde kullanılan temel adillik metriklerinin hesaplama adımları ve yorumlama rehberi sunulmaktadır.

Demografik Eşitlik Farkı (DPD) hesaplama süreci şu adımlardan oluşmaktadır: Birinci adımda, her demografik grup için (Erkek/Kadın) işe alım kararı alınan aday sayısı toplam aday sayısına bölünerek seçilme oranı hesaplanır. İkinci adımda, iki grubun seçilme oranları arasındaki mutlak fark ($|Oran_Erkek - Oran_Kadın|$) hesaplanır. Bu değer 0'a ne kadar yakınsa, sistemin demografik eşitliği o kadar yüksektir. Örnekte, Baseline Model: $|0.544 - 0.296| = 0.248$; KDS Modeli: $|0.544 - 0.504| = 0.040$ şeklinde hesaplanmıştır.

Eşit Fırsat Farkı (EOD) hesaplama süreci şu adımlardan oluşmaktadır: Birinci adımda, yalnızca gerçekten nitelikli adaylar ($IsQualified = true$) filtrelenir. İkinci adımda, filtrelenmiş her grup için Doğru Pozitif Oranı ($True\ Positive\ Rate = TPR = TP / (TP + FN)$) hesaplanır. Üçüncü adımda, iki grubun TPR değerleri arasındaki mutlak fark alınır. Bu değer 0 ise, sistem nitelikli adayları her iki grupta da eşit doğrulukla tanımıyor demektir. Örnekte, Baseline Model: $|TPR_Erkek - TPR_Kadın| = 0.196$; KDS Modeli: $|TPR_Erkek - TPR_Kadın| = 0.000$ şeklinde hesaplanmıştır.

EK-4: Sistem Kurulum ve Yapılandırma Kılavuzu

Bu ekte ResumeAI sisteminin yerel geliştirme ortamında kurulumu ve yapılandırılması için gerekli adımlar sunulmaktadır.

Ön gereksinimler olarak .NET 8 SDK, Node.js 18+, Docker Desktop ve bir LLM sağlayıcısına ait API anahtarı (OpenAI, Google AI Studio veya Alibaba Cloud) gerekmektedir. Backend başlatma için proje klonlama ve API anahtarı ayarlama adımları şöyledir: `git clone <repository-url>` komutu ile proje klonlanır. `cd ResumeAI-API/src/ResumeAI.API` dizinine geçilerek `dotnet user-secrets set "LLMSettings:Provider" "OpenAI"` komutuyla sağlayıcı ve `dotnet user-secrets set "LLMSettings:ApiKey" "your-api-key-here"` komutuyla API anahtarı tanımlanır. Son olarak `dotnet run` komutu ile uygulama başlatılır ve API varsayılan olarak `https://localhost:5001` adresinde çalışmaya başlar.

Frontend başlatma için `cd ResumeAI-UI` dizinine geçilerek `npm install` komutu çalıştırılır ve ardından `ng serve` komutu ile Angular geliştirme sunucusu başlatılır; uygulama `http://localhost:4200` adresinden erişilebilir hale gelir. Docker ile tüm sistem başlatmak için ise proje kök dizininde `docker-compose up --build` komutu yeterlidir; bu komut hem backend hem frontend ve gerekli bağımlılıkları otomatik olarak ayağa kaldırır.

Yanlılık analizi çalıştırmak için `/api/resume/analyze-batch` uç noktasına POST isteği gönderilmesi yeterlidir. İstek gövdesinde `candidates` dizisini ve `jobRequirements` nesnesini içeren bir JSON yapısı gönderilmeli; yanıt olarak her adayın `BaselineScore`, `KDSScore` ve `fairnessMetrics` değerleri döndürülür.