



T.C.

KOCAELİ SAĞLIK VE TEKNOLOJİ ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**YAPAY ZEKÂ TABANLI MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE İŞ KAZALARININ TAHMİN EDİLMESİ;
TÜRKİYE’DE 2016–2024 SGK VERİLERİ ÜZERİNDEN 2025–
2033 PROJEKSİYONU**

Rıza UZUNKAYA

İŞ SAĞLIĞI VE GÜVENLİĞİ ANA BİLİM DALI

DANIŞMAN

Dr. Öğr. Üyesi Gül Çiçek ZENGİN BİNTAŞ

T.C.
KOCAELİ SAĞLIK VE TEKNOLOJİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YAPAY ZEKÂ TABANLI MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE İŞ KAZALARININ TAHMİN
EDİLMESİ; TÜRKİYE’DE 2016–2024 SGK VERİLERİ
ÜZERİNDEN 2025–2033 PROJEKSİYONU**

YÜKSEK LİSANS TEZİ

Rıza UZUNKAYA

İŞ SAĞLIĞI VE GÜVENLİĞİ ANA BİLİM DALI

Dr. Öğr. Üyesi Gül Çiçek ZENGİN BİNTAŞ

KOCAELİ 2026

ONAY SAYFASI

Rıza UZUNKAYA tarafından hazırlanan “YAPAY ZEKÂ TABANLI MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE İŞ KAZALARININ TAHMİN EDİLMESİ; TÜRKİYE’DE 2016–2024 SGK VERİLERİ ÜZERİNDEN 2025–2033 PROJEKSİYONU” adlı tez çalışması aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Kocaeli Sağlık ve Teknoloji Üniversitesi Lisansüstü Eğitim Enstitüsü İş Sağlığı ve Güvenliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Üyesi	Kabul / Red	Kurumu	İmza
Prof. Dr. ALİ KİBAR		Kocaeli Üniversitesi	
Dr. Öğr. Üyesi Gül Çiçek ZENGİN BİNTAŞ		Kocaeli Sağlık ve Teknoloji Üniversitesi	
Dr. Öğr. Üyesi Ahmet ŞEN		Kocaeli Sağlık ve Teknoloji Üniversitesi	

Tez Savunma Tarihi: 30.03.2026

Kocaeli Sağlık ve Teknoloji Üniversitesi Lisansüstü Eğitim Enstitüsü İş Sağlığı ve Güvenliği Anabilim Dalı’nda Yüksek Lisans tezi olması için şartları yerine getirdiğini onaylıyorum.

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANI

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda patent ve telif haklarını ihlal edici etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tezde kullanılmış olan tüm bilgi ve yorumlara kaynak gösterdiğimi beyan ederim.

Rıza UZUNKAYA

TEŐEKKÖR

Bu tez alıřmasının her ařamasında bilgi ve deneyimleriyle bana rehberlik eden, deęerli katkı ve yönlendirmeleriyle alıřmamın řekillenmesine büyük emek veren danıřmanım Dr. Öęr. Üyesi Gül iek ZENGİN BİNTAŐ'a; yapay zekâ destekli analiz kodlarının hazırlanması ve ıktıların elde edilmesi sürecindeki katkılarından dolayı Özgür SAĖIR'a; eęitim hayatım boyunca desteklerini ve sevgilerini esirgemeyen eřim Özge UZUNKAYA'ya, annem Ayře UZUNKAYA'ya, babam Ali UZUNKAYA'ya ve kız kardeřim İrem UZUNKAYA'ya teőekkürlerimi sunarım.

Rıza UZUNKAYA

ÖZET

Yapay Zekâ Tabanlı Makine Öğrenmesi Yöntemleri ile İş Kazalarının Tahmin Edilmesi; Türkiye’de 2016–2024 SGK Verileri Üzerinden 2025–2033 Projeksiyonu

Bu çalışmanın temel amacı, 2016–2024 dönemi SGK iş kazası verilerinden hareketle 2025–2033 dönemi için geçici iş göremezlik ve ölümlü iş kazası eğilimlerini tahmin etmek, geleceğe dönük proaktif projeksiyonlar üretmek ve farklı algoritmaların performanslarını karşılaştırmaktır.

Metodoloji kapsamında veri seti, yaralanma türü kodları temelinde düzenlenmiş; erkek ve kadın çalışanlar için 1, 2, 3, 4 ile 5 gün ve üzeri geçici iş göremezlik değişkenleri ile ölen erkek ve kadın değişkenlerini içerecek şekilde çoklu hedefli olarak yapılandırılmıştır. Veri ön işleme ve gecikme (lag) öznelilikleri üretme adımlarının ardından; Random Forest, XGBoost ve LightGBM algoritmaları test edilmiş, model performansları MAE ve RMSE metrikleri ile değerlendirilmiştir.

Elde edilen bulgulara göre, karşılaştırılan modeller arasında en düşük hata değerlerini Random Forest modeli (MAE: 387.81, RMSE: 933.77) üretmiştir. Bu ana modele göre, 2025 yılında 400.604 olması beklenen yıllık toplam iş kazasının %59,7 artışla 2033 yılında 639.786 seviyesine ulaşacağı hesaplanmıştır. En yüksek hacmi "5 gün ve üzeri" raporlu vakalar (2025'te 248.007'den 2033'te 395.207'ye) oluştururken, 2025-2033 dönemi için toplam 63.432 çalışanın yaşamını yitireceği ve bu mortalite öngörüsünün 61.871 vaka ile büyük ölçüde erkek çalışanlarda yoğunlaşacağı tespit edilmiştir.

Sonuç olarak, Random Forest algoritmasının veri temelli risk analizi için güçlü bir karar destek aracı sunduğu kanıtlanmış olup, özellikle beş gün ve üzeri süreli yaralanmalar ile erkek çalışan mortalitesinin İSG politikalarında öncelikli müdahale alanı olması gerektiği saptanmıştır.

Anahtar Kelimeler: İş sağlığı ve güvenliği, LightGBM, Random Forest, XGBoost, Yapay zekâ

ABSTRACT

Forecasting Occupational Accidents Using Artificial Intelligence-Based Machine Learning Methods: A 2025–2033 Projection Based on Türkiye’s 2016–2024 SSI Data

The primary objective of this study is to predict trends in temporary incapacity and fatal occupational accidents for the 2025–2033 period, based on SGK occupational accident data from 2016–2024, to generate proactive future projections and compare the performances of various algorithms.

Within the scope of the methodology, the dataset was organized based on injury type codes and structured as a multi-target framework including temporary incapacity variables for 1, 2, 3, 4, and 5 or more days, as well as variables for deceased male and female workers. Following the data preprocessing and the generation of lag features, Random Forest, XGBoost, and LightGBM algorithms were tested, and model performances were evaluated using MAE and RMSE metrics.

According to the findings, the Random Forest model produced the lowest error values (MAE: 387.81, RMSE: 933.77) among the compared models. Based on this primary model, the annual total number of occupational accidents, expected to be 400,604 in 2025, is calculated to reach 639,786 in 2033, representing a 59.7% increase. While "5 or more days" reported cases constitute the highest volume (increasing from 248,007 in 2025 to 395,207 in 2033), it was determined that a total of 63,432 employees will lose their lives during the 2025–2033 period, with this mortality projection concentrated largely among male workers with 61,871 cases.

In conclusion, it has been proven that the Random Forest algorithm provides a robust decision support tool for data-driven risk analysis, and it was established that injuries with a duration of five days or more and male worker mortality should be priority areas for intervention in occupational health and safety policies.

Keywords: Artificial intelligence, LightGBM, Occupational health and safety, Random Forest, XGBoost

İÇİNDEKİLER

ONAY SAYFASI	i
BEYAN	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xii
TABLolar DİZİNİ	xiii
GİRİŞ	1
BÖLÜM 1	
1. LİTERATÜR TARAMASI VE KAVRAMSAL ÇERÇEVE	3
1.1. İş Sağlığı ve Güvenliği Kavramları	3
1.1.1. İş Sağlığı	3
1.1.2. İş Güvenliği	4
1.1.3. Türkiye’de İş Sağlığı ve Güvenliği Tarihçesi	4
1.2. Güvenlik Kültürü ve Kaza Nedensellik Teorileri	5
1.2.1. İSG Kültürü ve Güvenlik İklimi	5
1.2.2. Kaza Sebep Teorileri	6
1.3. Sosyal Güvenlik Kurumu Veri Yapısı ve İş Kazası Sınıflandırmaları	6
1.3.1. Geçici İş Göremezlik Süreleri	7
1.3.2. Ölümlü İş Kazaları	8
1.3.3. Yaralanma Türleri ve Kaza Kodlama Metodolojileri	9
1.4. Yapay Zekâ ve Makine Öğrenmesi	10
1.4.1. Yapay Zekâ	11

1.4.2. Makine Öğrenmesi ve Zaman Serisi Analitiği	12
1.4.3. Karar Ağacı Tabanlı Modeller	12
1.4.4. Random Forest (Rassal Orman) Algoritması	13
1.4.5. eXtreme Gradient Boosting (XGBoost) Algoritması	14
1.4.6. Light Gradient Boosting Machine (LightGBM) Algoritması	15
1.5. İş Sağlığı ve Güvenliğinde Yapay Zekâ Uygulamaları	15
BÖLÜM 2	
2. MATERYAL VE YÖNTEM.....	17
2.1. Araştırmanın Problemi	17
2.2. Araştırmanın Amacı ve Önemi	18
2.3. Araştırmanın Kapsamı ve Sınırlılıkları	19
2.4. Araştırmanın Modeli ve Tasarımı	19
2.5. Veri Seti ve Ön İşleme Adımları.....	21
2.5.1. Değişkenlerin Tanımlanması	22
2.5.2. İş Göremezlik Değişkenleri.....	22
2.5.3. Ölüm Değişkenleri.....	23
2.5.4. Veri Düzenleme ve Lag Kurgusu	24
2.5.5. Dengesiz Veri ve Gürültünün Ele Alınması	25
2.6. Tahminleme Mimarisi ve Hibrit Yaklaşım	25
2.7. Makine Öğrenmesi Algoritmalarının Araştırma Kapsamında Yapılandırılması	26
2.7.1. Random Forest Model Kurgusu ve Parametreleri	27
2.7.2. XGBoost Model Kurgusu ve Parametreleri	28
2.7.3. LightGBM Model Kurgusu ve Parametreleri	29
2.8. Model Performans Değerlendirme Metrikleri	30
BÖLÜM 3	
3. BULGULAR.....	32
3.1. Makine Öğrenmesi Modellerinin Performans Karşılaştırması	32

3.1.1. LightGBM, XGBoost ve Random Forest Modellerinin Hata Metrikleri Açısından Karşılaştırılması.....	32
3.1.2. Random Forest Modelinin Karşılaştırmalı Üstünlüğü.....	33
3.2. Yıllık Toplam Kaza Projeksiyonları.....	34
3.2.1. Modeller Arası Genel Vaka Tahmin Karşılaştırmaları.....	34
3.2.2. Random Forest Modeline Göre Yıllık Artış Eğilim	35
3.3. İş Göremezlik Sürelerine Göre Yaralanma Tahminleri.....	36
3.3.1. 1 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi	36
3.3.2. 2 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi	38
3.3.3. 3 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi	39
3.3.4. 4 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi	40
3.3.5. 5 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi	41
3.4. Ölüm Projeksiyonları ve Demografik Kırılımlar	43
3.4.1. Modeller Bazında Toplam Ölüm Sayısı Tahminleri	43
3.4.2. Erkek Çalışanlara İlişkin Ölüm Projeksiyonları.....	44
3.4.3. Kadın Çalışanlara İlişkin Ölüm Projeksiyonları	45
3.5. Yaralanma Kodlarına Göre Karşılaştırmalı Model Analizi.....	47
3.5.1. Kod 000: Türü Bilinmeyen/Belirtilmemiş	49
3.5.2. Kod 011: Yüzeysel Yaralanmalar.....	50
3.5.3. Kod 012: Açık Yaralar	51
3.5.4. Kod 019: Diğer Tür Yaralar	52
3.5.5. Kod 021: Kapalı Kırıklar	53
3.5.6. Kod 022: Açık Kırıklar	54

3.5.7. Kod 029: Diğer Tür Kemik Kırıkları	55
3.5.8. Kod 031: Çıkıklar ve Yarı Çıkıklar	56
3.5.9. Kod 032: Burkulmalar ve İncinmeler	57
3.5.10. Kod 039: Diğer Tür Çıkık/Burkulmalar.....	58
3.5.11. Kod 040: Travma Sonucu Organ Kaybı (Amputasyon)	59
3.5.12. Kod 051: Beyin Sarsıntısı ve Kafatası Yaralanmaları	60
3.5.13. Kod 052: İç Yaralanmalar	62
3.5.14. Kod 059: Diğer Tür Beyin Sarsıntısı/İç Yaralanmalar	63
3.5.15. Kod 061: Termal Yanıklar	64
3.5.16. Kod 062: Kimyasal Yanıklar (Korozyon).....	65
3.5.17. Kod 063: Donmalar	66
3.5.18. Kod 069: Diğer Tür Yanıklar	67
3.5.19. Kod 071: Akut Zehirlenmeler	68
3.5.20. Kod 072: Akut Enfeksiyonlar.....	69
3.5.21. Kod 079: Diğer Tür Zehirlenmeler	70
3.5.22. Kod 081: Nefesin Kesilmesi (Asfiksi)	71
3.5.23. Kod 082: Suda Boğulma	72
3.5.24. Kod 089: Diğer Tür Boğulmalar	73
3.5.25. Kod 091: Akut İşitme Kaybı	74
3.5.26. Kod 092: Basınç Etkileri (Barotravma)	75
3.5.27. Kod 099: Diğer Ses/Titreşim Etkileri	76
3.5.28. Kod 101: Sıcaklık ve Güneş Çarpması	77
3.5.29. Kod 102: Radyasyon Etkileri (Termal Olmayan).....	78
3.5.30. Kod 103: İndirgenmiş Isı Etkileri	79
3.5.31. Kod 109: Diğer Isı/Işık/Radyasyon Etkileri.....	80
3.5.32. Kod 111: Saldırı/Tehdit Sonrası Şoklar	81
3.5.33. Kod 112: Travma Şokları.....	82

3.5.34. Kod 119: Diğer Tür Şoklar.....	83
3.5.35. Kod 120: Birden Fazla Sayıda Yaralanmalar (Multitravma)	84
3.5.36. Kod 999: Diğer Başlıklar Altında Sınıflandırılmayanlar	85
BÖLÜM 4	
4. TARTIŞMA.....	87
4.1. Bulguların Genel Değerlendirilmesi	87
4.2. Bulguların Literatür ile Karşılaştırılması.....	88
4.3. Veri Seti Yapısının Bulgulara Etkisi	89
4.4. Modellerin Karşılaştırmalı Olarak Değerlendirilmesi.....	90
4.5. Bulguların İş Sağlığı ve Güvenliği Açısından Değerlendirilmesi	91
4.6. Araştırmanın Sınırlılıkları.....	93
BÖLÜM 5	
5. SONUÇ VE ÖNERİLER	94
5.1. Sonuç	94
5.2. Araştırmanın Alana Katkıları.....	94
5.3. Uygulamaya Yönelik Öneriler	95
5.3.1. Veri Yönetimi ve Dijital Kayıt Standartlarının İyileştirilmesi.....	95
5.3.2. Yüksek Frekanslı Yaralanmalara Yönelik Teknik ve Ergonomik Müdahaleler	96
5.3.3. Yapay Zekâ Destekli Stratejik Karar Destek Mekanizmalarının Yapılandırılması.....	96
5.3.4. Bildirim Kültürü ve Sosyal Güvenlik Farkındalığının Geliştirilmesi	97
5.3.5. Gelecek Çalışmalar İçin Öneriler	97
KAYNAKLAR	99

SİMGELER VE KISALTMALAR DİZİNİ

İSG	: İş Sağlığı ve Güvenliği
LightGBM	: Light Gradient Boosting Machine
MAE	: Mean Absolute Error
MÖ	: Makine Öğrenmesi
RF	: Random Forest
RMSE	: Root Mean Squared Error
SGK	: Sosyal Güvenlik Kurumu
XGBoost	: eXtreme Gradient Boosting
YZ	: Yapay Zekâ

ŞEKİLLER DİZİNİ

Şekil 3.1. Modellerin Hata Metrikleri Açısından Karşılaştırılması.....	33
Şekil 3.2. Modeller Arası Genel Vaka Tahmin Karşılaştırmaları	35
Şekil 3.3. 1 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı ...	37
Şekil 3.4. 2 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı ...	39
Şekil 3.5. 3 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı ...	40
Şekil 3.6. 4 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı ...	41
Şekil 3.7. 5 Gün ve Üzeri İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı.....	42
Şekil 3.8. Toplam Mortalite (Ölüm) Projeksiyonları (2025-2033)	44
Şekil 3.9. Erkek Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033)	45
Şekil 3.10. Kadın Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033)	46

TABLÖLAR DİZİNİ

Tablo 3.1. Modellerinin Hata Metrikleri Açısından Karşılaştırılması	32
Tablo 3.2. Modeller Arası Genel Vaka Tahmin Karşılaştırmaları.....	34
Tablo 3.3. 1 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı..	37
Tablo 3.4. 2 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı..	38
Tablo 3.5. 3 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı..	39
Tablo 3.6. 4 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı..	40
Tablo 3.7. 5 Gün ve Üzeri İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı.....	42
Tablo 3.8. Toplam Mortalite (Ölüm) Projeksiyonları (2025-2033).....	43
Tablo 3.9. Erkek Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033).....	44
Tablo 3.10. Kadın Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033).....	45
Tablo 3.11. SGK Yaralanma Türü Kodları ve Tanımları.....	47
Tablo 3.12. Kod 000: Türü Bilinmeyen/Belirtilmemiş İçin Karşılaştırmalı Tahminler	49
Tablo 3.13. Kod 011: Yüzeysel Yaralanmalar İçin Karşılaştırmalı Tahminler	50
Tablo 3.14. Kod 012: Açık Yaralar İçin Karşılaştırmalı Tahminler	51
Tablo 3.15. Kod 019: Diğer Tür Yaralar İçin Karşılaştırmalı Tahminler	52
Tablo 3.16. Kod 021: Kapalı Kırıklar İçin Karşılaştırmalı Tahminler.....	53
Tablo 3.17. Kod 022: Açık Kırıklar İçin Karşılaştırmalı Tahminler	54
Tablo 3.18. Kod 029: Diğer Tür Kemik Kırıkları İçin Karşılaştırmalı Tahminler	56
Tablo 3.19. Kod 031: Çıkıklar ve Yarı Çıkıklar İçin Karşılaştırmalı Tahminler	57
Tablo 3.20. Kod 032: Burkulmalar ve İncinmeler İçin Karşılaştırmalı Tahminler	58
Tablo 3.21. Kod 039: Diğer Tür Çıkık/Burkulmalar İçin Karşılaştırmalı Tahminler.....	59
Tablo 3.22. Kod 040: Travma Sonucu Organ Kaybı (Amputasyon) İçin Karşılaştırmalı Tahminler	60
Tablo 3.23. Kod 051: Beyin Sarsıntısı ve Kafatası Yaralanmaları İçin Karşılaştırmalı Tahminler	61

Tablo 3.24. Kod 052: İç Yaralanmalar İçin Karşılaştırmalı Tahminler	62
Tablo 3.25. Kod 059: Diğer Tür Beyin Sarsıntısı/İç Yaralanmalar İçin Karşılaştırmalı Tahminler	63
Tablo 3.26. Kod 061: Termal Yanıklar İçin Karşılaştırmalı Tahminler	64
Tablo 3.27. Kod 062: Kimyasal Yanıklar (Korozyon) İçin Karşılaştırmalı Tahminler	65
Tablo 3.28. Kod 063: Donmalar İçin Karşılaştırmalı Tahminler.....	66
Tablo 3.29. Kod 069: Diğer Tür Yanıklar İçin Karşılaştırmalı Tahminler	67
Tablo 3.30. Kod 071: Akut Zehirlenmeler İçin Karşılaştırmalı Tahminler.....	68
Tablo 3.31. Kod 072: Akut Enfeksiyonlar İçin Karşılaştırmalı Tahminler.....	69
Tablo 3.32. Kod 079: Diğer Tür Zehirlenmeler İçin Karşılaştırmalı Tahminler	70
Tablo 3.33. Kod 081: Nefesin Kesilmesi (Asfiksi) İçin Karşılaştırmalı Tahminler	71
Tablo 3.34. Kod 082: Suda Boğulma İçin Karşılaştırmalı Tahminler	72
Tablo 3.35. Kod 089: Diğer Tür Boğulmalar İçin Karşılaştırmalı Tahminler.....	74
Tablo 3.36. Kod 091: Akut İşitme Kaybı İçin Karşılaştırmalı Tahminler	75
Tablo 3.37. Kod 092: Basınç Etkileri (Barotravma) İçin Karşılaştırmalı Tahminler	76
Tablo 3.38. Kod 099: Diğer Ses/Titreşim Etkileri İçin Karşılaştırmalı Tahminler	77
Tablo 3.39. Kod 101: Sıcaklık ve Güneş Çarpması İçin Karşılaştırmalı Tahminler	78
Tablo 3.40. Kod 102: Radyasyon Etkileri (Termal Olmayan) İçin Karşılaştırmalı Tahminler	79
Tablo 3.41. Kod 103: İndirgenmiş Isı Etkileri İçin Karşılaştırmalı Tahminler	80
Tablo 3.42. Kod 109: Diğer Isı/Işık/Radyasyon Etkileri İçin Karşılaştırmalı Tahminler ...	81
Tablo 3.43. Kod 111: Saldırı/Tehdit Sonrası Şoklar İçin Karşılaştırmalı Tahminler	82
Tablo 3.44. Kod 112: Travma Şokları İçin Karşılaştırmalı Tahminler	83
Tablo 3.45. Kod 119: Diğer Tür Şoklar İçin Karşılaştırmalı Tahminler.....	84
Tablo 3.46. Kod 120: Birden Fazla Sayıda Yaralanmalar (Multitravma) İçin Karşılaştırmalı Tahminler	85
Tablo 3.47. Kod 999: Diğer Başlıklar Altında Sınıflandırılmayanlar İçin Karşılaştırmalı Tahminler	86

GİRİŞ

Sanayi devriminden günümüze uzanan süreçte üretim biçimlerinde yaşanan dönüşümler ve teknolojinin çalışma ortamlarına entegrasyonu, iş sağlığı ve güvenliğini çalışma hayatının temel alanlarından biri hâline getirmiştir. İş sağlığı ve güvenliği; işin yürütümü sırasında doğabilecek tehlikelerin kaynağında yok edilmesini, çalışanların bedensel ve ruhsal bütünlüklerinin korunmasını hedefleyen çok disiplinli bir bilim dalı olarak tanımlanmaktadır (Şen, 2015).

Tarihsel süreç içerisinde iş sağlığı ve güvenliği uygulamaları, yalnızca iş kazalarının ardından devreye giren reaktif müdahaleler bütünü olmaktan çıkmıştır. Bu disiplin, çalışma ortamındaki tehlikelerin öngörüldüğü, risklerin bilimsel yöntemlerle değerlendirildiği proaktif bir sistematığe evrilmiştir. Bu proaktif yaklaşımın temel amacı, çalışanın kapasitesine uygun güvenli çalışma koşullarının sağlanması ve üretim sürecinin olumsuz etkilerine karşı koruyucu bir yapının oluşturulmasıdır (Karaahmetoğlu, 2022).

İş kazalarının önlenmesi ve güvenli bir çalışma ortamının sürdürülebilir kılınması, salt teknik tedbirlerin ötesinde kurumsal bir güvenlik ikliminin inşasını gerektirmektedir. Türkiye’deki çalışma mevzuatının gelişimi değerlendirildiğinde, özellikle 6331 sayılı İş Sağlığı ve Güvenliği Kanunu’nun yürürlüğe girmesiyle sistemde köklü bir paradigma değişimi yaşandığı anlaşılmaktadır. Geleneksel olay sonrası müdahale mantığı terk edilerek, tehlikeleri henüz risk aşamasına gelmeden kaynağında tespit eden önleyici yaklaşım yasal bir zemine oturtulmuştur (Kılıkış, 2013).

İş kazalarının nedenselliğini açıklayan teoriler de bu vizyona paralel olarak gelişim göstermiştir. Olayları birbirini ardışık olarak tetikleyen hata zincirleri biçiminde açıklayan klasik kuramlar, yerini kazaları sektörel ve demografik faktörlerin etkileşimi olarak ele alan çağdaş kaza modellerine bırakmıştır (Özbucak Albar, 2024). Bu çağdaş yaklaşım, çalışma hayatındaki risklerin çok boyutlu değişkenler üzerinden analiz edilmesini zorunlu kılmaktadır (Özdemir, 2025).

İş kazası oluşum süreçleri; sektör dinamikleri, makineleşme oranları ve çalışan demografisi gibi birden fazla parametrenin etkileşimine bağlıdır. Geleneksel istatistiksel yaklaşımlar genellikle değişkenler arasındaki doğrusal ilişkilere odaklanırken, son yıllarda akademik literatürde ağırlık kazanan yapay zekâ ve makine öğrenmesi algoritmaları, doğrusal olmayan karmaşık ilişkileri modelleyebilme kapasitesiyle öne çıkmaktadır (Ayan vd., 2024).

Geçmiş kaza verileri kullanılarak yapılan güncel çalışmalarda, iş kazalarının belirli örüntüler sergileyebildiği ve bu nedenle tahminleme modelleriyle analiz edilebildiği gösterilmiştir (Karakaya Özkan ve Ulaş, 2023).

Makine öğrenmesi yöntemleri, kurumsal veri havuzlarında gizli kalan bu yapısal örüntüleri ortaya çıkararak, reaktif analizlerden ziyade proaktif kaza önleme stratejilerinin geliştirilmesine zemin hazırlamaktadır. Bu teknolojik entegrasyon sayesinde, potansiyel tehlikeler risk aşamasına gelmeden saptanabilmekte ve güvenlik politikalarına bilimsel bir karar destek mekanizması sağlanmaktadır (Karabulut vd., 2024).

Türkiye’deki iş kazalarına ilişkin literatür incelendiğinde, istatistiksel ve yapay zekâ temelli çalışmalar bulunmakla birlikte, uzun dönemli projeksiyon üretmeye odaklanan ve farklı algoritmaların tahmin performanslarını karşılaştıran araştırmaların sınırlı kaldığı görülmektedir. Bu çalışmanın amacı, Sosyal Güvenlik Kurumu tarafından yayımlanan 2016–2024 dönemi iş kazası verilerinden hareketle 2025–2033 dönemine ilişkin eğilimleri Random Forest, XGBoost ve LightGBM algoritmalarıyla tahmin etmek ve modellerin performanslarını karşılaştırmaktır (Sosyal Güvenlik Kurumu, 2024).

İlgili literatürde, ölümlü vakalar ile yaralanma durumlarının kavramsal ve istatistiksel olarak ayrıştırılmasının analitik açıdan gerekli olduğu vurgulanmaktadır (Kandemir ve Şimşek, 2019).

Bu teorik dayanak doğrultusunda geliştirilen tahmin altyapısında, iş kazası kaynaklı vefat durumları ile geçici iş göremezliğe neden olan olaylar analiz sürecinde birbirinden bağımsız olarak modellenmiştir. Bu yönüyle çalışma, Türkiye’de iş kazalarının uzun dönemli tahminine yönelik karşılaştırmalı bir makine öğrenmesi çerçevesi sunmaktadır. Elde edilen bulguların, iş sağlığı ve güvenliği alanında veri temelli ve proaktif karar süreçlerinin inşasına katkı sağlaması beklenmektedir.

1. LİTERATÜR TARAMASI VE KAVRAMSAL ÇERÇEVE

1.1. İş Sağlığı ve Güvenliği Kavramları

Sanayi devriminden günümüze uzanan süreçte, üretim biçimlerinin değişmesi ve teknolojinin çalışma hayatına entegre olması, çalışanların maruz kaldığı risklerin de form değiştirmesine yol açmıştır. İş sağlığı ve güvenliği, en temel düzeyde, işin yürütümü sırasında doğabilecek tehlikelerin kaynağında yok edilmesini, çalışanların bedensel ve ruhsal bütünlüklerinin korunmasını hedefleyen çok disiplinli bir bilim dalıdır. İSG, yalnızca teknik bir mühendislik problemi değil; tıp, hukuk, sosyoloji ve veri bilimi gibi alanların kesişim noktasında yer alan bütünlük bir yönetim sistemidir (Özbucak Albar, 2024).

Bu sistemin temel amacı, kaza veya hastalık oluşuktan sonra müdahale etmek yerine, tehlikeleri henüz risk aşamasındayken tespit ederek bertaraf etmektir. Kavramsal olarak "iş sağlığı" ve "iş güvenliği" birbirini tamamlayan ancak odak noktaları farklılık gösteren iki temelden oluşmaktadır. Modern İSG yönetimi, bu iki kavramın birbirinden bağımsız düşünülemeyeceği prensibi üzerine inşa edilmiştir.

1.1.1. İş Sağlığı

İş sağlığı kavramı, en temel ifadeyle, çalışma hayatında yer alan bireylerin bedensel, ruhsal ve sosyal iyilik hâllerinin korunmasını ve bu durumun sürdürülebilir biçimde en üst düzeye çıkarılmasını hedefleyen çok disiplinli bir alan olarak tanımlanmaktadır. Bu kavram, tarihsel süreç içerisinde yalnızca meslek hastalıklarının ve iş kazalarının ortaya çıkmasının ardından uygulanan reaktif tıbbi müdahaleler bütünü olmaktan çıkmış; çalışma ortamındaki tehlikelerin önceden öngörüldüğü, risklerin bilimsel yöntemlerle değerlendirildiği ve kaynağında bertaraf edildiği modern bir önleyici sistematığe dönüşmüştür. İş sağlığı uygulamalarının temel felsefesi, çalışanın fizyolojik ve psikolojik kapasitesine uygun, güvenli ve sağlıklı çalışma koşullarının tesis edilmesi; özetle işin insana, insanın da işe uyumunun tam anlamıyla sağlanmasıdır. Türkiye'deki yasal ve kuramsal yapının gelişiminde de bahsi geçen önleyici yaklaşım merkeze alınmıştır. Özellikle mevzuatın dönüşümüyle birlikte, işyerlerinde sağlık ve güvenlik standartlarının iyileştirilmesi salt bir hukuki zorunluluk olmanın ötesine geçerek, çalışma barışının, sürdürülebilir üretimin ve toplumsal refahın ayrılmaz bir bileşeni olarak literatürdeki yerini almıştır. Bu bağlamda iş sağlığı,

alıřanı retim srecinin yıpratıcı etkilerinden koruyan btncl bir kalkan iřlevi grmektedir (Karaahmetođlu, 2022).

1.1.2. İř Gvenliđi

İř gvenliđi kavramı, iřyerindeki gvensiz kořulların ve tehlikeli durumların ortadan kaldırılması veya en aza indirilmesi amacıyla yrtlen yapısal faaliyetler btn olarak tanımlanmaktadır. Bu disiplin, alıřanların yařamına ve vcut btnlđne ynelebilecek tehlikelerin nlenmesi iin zorunlu teknik kuralları belirlemekte; rahat ve gvenli bir alıřma ortamının tesis edilmesini temel ama olarak ele almaktadır. Bu kapsamda iř gvenliđi; alıřma ortamında hlihazırda bulunan veya dıřarıdan dhil olabilecek risklerin ngrlmesini, tespit edilip deđerlendirilmesini ve teknik tedbirler vasıtasıyla tamamen yok edilmesini ya da asgari seviyeye indirilmesini hedefleyen bir koruma mekanizmasıdır. İřyerinin fiziksel inřasından makine montajına ve retim srecinde kullanılan kimyasal veya mekanik materyallerin risk ynetimine kadar uzanan geniř bir operasyonel alan, bu kavramın teknik sınırlarını oluřturmaktadır. zetle iř gvenliđi, retim faaliyetleri esnasında alıřanın yařam hakkına zarar verebilecek potansiyel tehlikelerin nceden bertaraf edilmesi adına geliřtirilmiř sistematik ve teknik kurallar btndr (řen, 2015).

1.1.3. Trkiye’de İř Sađlıđı ve Gvenliđi Tarihesi

Trkiye’deki iř sađlıđı ve gvenliđi uygulamalarının tarihsel kkenleri incelendiđinde, kurumsal nitelikteki ilk yasal adımların Osmanlı Devleti dneminde atıldıđı grlmektedir. Bu srete iřiyi korumaya ynelik ilk mevzuat olan Dilaver Pařa Nizamnamesi 1865 yılında ilan edilmiř, hemen ardından 1869 yılında yrrlđ giren Maadin Nizamnamesi ile iř kazalarına karřı ilk somut nlemler hayata geirilmiřtir. Cumhuriyet dneminde geiřle birlikte yasal altyapı daha sistematik bir yapıya kavuřmuř ve 1937 yılında Trkiye’nin ilk iř kanunu olma zelliđini tařıyan 3008 sayılı Kanun yrrlđ girmiřtir (Horozođlu, 2017). Sosyal gvenlik sisteminin geliřimiyle beraber 1945 yılında 4772 sayılı Kanun ile mesleki risk sigortası uygulaması bařlatılmıř, sanayileřme hızına paralel olarak 1971 yılında 1475 sayılı İř Kanunu ve son olarak 2012 yılında mstakil bir dzenleme olan 6331 sayılı İř Sađlıđı ve Gvenliđi Kanunu yasalařmıřtır (Horozođlu, 2017).

Sz konusu yasal geliřimin modern dnemi, zellikle 2003 yılında yrrlđ giren 4857 sayılı İř Kanunu ve buna bađlı ynetmeliklerle birlikte risk deđerlendirmesine dayalı bir anlayıřın benimsenmesiyle ivme kazanmıřtır. Bu dnemde Avrupa Birliđi standartlarına

uyum süreci çerçevesinde "önleyici yaklaşım" felsefesi Türk çalışma mevzuatına entegre edilmeye çalışılmıştır. Ancak mevzuatın dağınık yapısı ve kapsam dışı kalan çalışanların varlığı gibi temel sorunların çözümü amacıyla hazırlanan 6331 sayılı Kanun, sistemde köklü bir paradigma değişimini beraberinde getirmiştir. Bu yeni yasal çerçeve ile kaza sonrası düzeltici faaliyetlere odaklanan geleneksel reaktif yöntemler terk edilerek; tehlikelerin henüz ortaya çıkmadan kaynağında tespit edilmesini ve bertaraf edilmesini hedefleyen proaktif yaklaşım, iş sağlığı ve güvenliği stratejisinin merkezine yerleştirilmiştir (Kacır ve Taçgın, 2017).

1.2. Güvenlik Kültürü ve Kaza Nedensellik Teorileri

İşyerlerinde iş kazalarının ve meslek hastalıklarının önlenmesi, yalnızca donanımsal tedbirlerin alınmasıyla değil, organizasyonel bir güvenlik kültürünün tesis edilmesiyle mümkün olmaktadır. İş sağlığı; çeşitli sektörlerde çalışanların fiziksel, ruhsal ve sosyal refahını en üst düzeye çıkarmaya adanmış, odağında tehlikelerin ve işle ilgili yaralanmaların önlenmesi bulunan temel bir disiplindir. Çalışanların sağlığını tehdit eden risk unsurlarının sistemli çalışmalarla öngörülebilmesi, bu disiplinin gerektirdiği koruyucu ve proaktif çerçevenin zorunlu bir parçası olarak kabul edilmektedir (Canbaz ve İşsever, 2024).

1.2.1. İSG Kültürü ve Güvenlik İklimi

İş sağlığı ve güvenliği kültürü, çalışma ortamındaki risklerin tanımlanması ve bu risklere karşı ortak bir davranış modelinin geliştirilmesi sürecini ifade etmektedir. İşletmelerde kazaların oluşum mekanizmaları incelendiğinde, işin yapılması veya yürütülmesi sırasında meydana gelen olayların arkasında, iletişim eksiklikleri ve zayıf güvenlik ikliminin yattığı görülmektedir. Bu bağlamda kaza maliyetleri ve kayıpların azaltılması için, anlık işleyişin ötesinde kökleşmiş bir kültürel yapıya ihtiyaç duyulmaktadır (İlgın ve Timuralp, 2024).

Geleneksel iş sağlığı ve güvenliği sistemleri genellikle reaktif bir anlayışla kaza sonrasında devreye girerken, modern sistemler olay öncesine ve güvenlik kültürünün inşasına odaklanmaktadır. 6331 sayılı İş Sağlığı ve Güvenliği Kanunu'nun yürürlüğe girmesiyle birlikte, çalışma hayatında olay sonrası müdahaleden ziyade riskleri kaynağında tespit eden, önleyici ve proaktif bir yaklaşım yasal bir çerçeveye oturtulmuştur (Kılıkış, 2013).

1.2.2. Kaza Sebep Teorileri

İş kazalarının meydana geliş mekanizmalarını açıklayan teoriler, olayların rastlantısal olmadığını ve incelenabilir bir nedensellik çerçevesine oturduğunu ortaya koymaktadır. Kaza ve ramak kala olaylarının kök nedenlerinin bilimsel modellerle araştırılması, işletmelerde yaşanabilecek benzer vakaların önlenmesi için uygulanacak proaktif yaklaşımların temelini oluşturmaktadır (Çalışma ve Sosyal Güvenlik Bakanlığı, 2025).

Literatürde en çok kabul gören kuramlardan biri olan kaza nedenselliğine yönelik süreçler, olayların birbirine bağlı faktörlerle tetiklendiğini savunmaktadır. Domino Teorisi'ne göre; kalıtsal ve sosyal çevre, kişisel kusurlar, güvensiz hareket ve koşullar, kaza ve yaralanma olarak sıralanan beş aşama birbirini ardışık olarak etkilemekte olup, zincirin üçüncü halkası olan güvensiz koşulların ortadan kaldırılmasıyla sistemin kaza üretmesi engellenebilmektedir (Özbucak Albar, 2024).

Çağdaş kaza modelleri ise nedenselliği yalnızca operatör düzeyindeki basit bir hata zinciri olarak değil, karmaşık yönetimsel zafiyetlerin çok boyutlu bir etkileşimi olarak ele almaktadır. Çalışma hayatındaki kazaların; sektörel, demografik veya cinsiyet temelli değişkenler gibi farklı epidemiyolojik unsurlar üzerinden bütüncül bir yaklaşımla analiz edilmesi, çağdaş teorilerin gerektirdiği proaktif veri analizi standartlarını yansıtmaktadır (Özdemir, 2025).

1.3. Sosyal Güvenlik Kurumu Veri Yapısı ve İş Kazası Sınıflandırmaları

Türkiye'de çalışma hayatında meydana gelen iş kazalarının makro düzeyde izlenebilmesi ve istatistiksel bir zeminde değerlendirilebilmesi için Sosyal Güvenlik Kurumu (SGK) tarafından yayımlanan yıllık kayıtlar temel veri altyapısını oluşturmaktadır (Özdemir, 2025). Kurumun oluşturduğu bu istatistiksel yapı, kaza bildirimlerini yalnızca sayısal bir yığın olarak ele almak yerine; olayları türüne, şiddetine ve sonuçlarına göre sistematik bir biçimde kategorize etmektedir (Sosyal Güvenlik Kurumu, 2024). Bu tasnif sistemi, devasa büyüklükteki veri havuzunun belirli bir standart içinde düzenlenmesini sağlamaktadır.

SGK veri tabanında yer alan bilgilerin sınıflandırılmasında, olayların gerçekleştiği sektörel veya coğrafi bağlamı temsil eden lokasyon kodları önemli bir işleve sahiptir. Veri setinde yer alan KOD_NO değişkeni, kazaların yapısal olarak ayrıştırılmasında ve

dağılımlarının izlenmesinde temel bir tanımlayıcı olarak kurumsal kayıtlarda yer almaktadır (Sosyal Güvenlik Kurumu, 2024).

Veri mimarisinin bir diğer detaylı kırılımı ise, kazazedenin cinsiyeti ve kaza sonrasında karşılaştığı iş gücü kaybının boyutu üzerinden şekillenmektedir. Literatürdeki güncel çalışmalar da SGK verilerinin özellikle cinsiyet ve işgünü kayıpları ekseninde sunduğu bu epidemiyolojik tasnifin önemini vurgulamaktadır (Özdemir, 2025).

Kurumun kayıt sisteminde, ölümle sonuçlanmayan iş kazaları doğrudan kazazedelerin aldıkları geçici iş göremezlik süreleri baz alınarak kodlanmaktadır. Bu doğrultuda, kaza sonrasında istirahat verilen erkek sigortalılar için E1, E2, E3, E4 ve E5; kadın sigortalılar için ise K1, K2, K3, K4 ve K5 sütunları kullanılmaktadır. Bu değişkenlerde yer alan 1, 2, 3, 4 ve 5 rakamları, çalışanın sırasıyla 1 gün, 2 gün, 3 gün, 4 gün ve 5 gün (veya daha fazla) süreyle geçici iş göremezlik raporu aldığını belirtmektedir. Resmi veri yapısında yer alan bu sürelerin tamamı, yalnızca yaralanmalı ancak kişinin hayatta kaldığı olayları ölçmekte olup; hiçbir istirahat süresi ölümlü bir kazayı temsil etmemektedir.

Kaza anında veya kaza sürecinin devamında meydana gelen vefat (mortalite) vakaları ise, SGK'nın veri sözlüğünde yaralanma sürelerinden tamamen yalıtılmış özel sütunlarda raporlanmaktadır. Vefat durumları veri setine yalnızca ölen erkek ve ölen kadın değişkenleri altında kaydedilmektedir (Sosyal Güvenlik Kurumu, 2024). Yapılandırılan bu mutlak ayırım, yaralanma şiddeti ile ölüm olgusunun istatistiksel olarak birbirine karışmasını engellemekte ve yapılacak olan ileri düzey analizlerde hedef değişkenlerin doğru belirlenmesine olanak tanımaktadır.

Bunun yanı sıra, kazaların fiziksel sonuçları ve yaralanma şekilleri, anatomik özelliklerine göre önceden belirlenmiş standart kodlarla sisteme işlenmektedir. Raporlanan vakalar, niteliğine göre örneğin Kod 11: Yüzeysel Yaralanmalar, Kod 12: Açık Yaralar veya Kod 21: Kapalı Kırıklar gibi hiyerarşik tanımlayıcılarla kayıt altına alınmaktadır. SGK'nın uyguladığı bu kodlama mantığı, karmaşık iş kazası bildirimlerini epidemiyolojik olarak incelenebilir, istatistiksel gürültüden arındırılmış şeffaf bir veri setine dönüştürmektedir.

1.3.1. Geçici İş Göremezlik Süreleri

İş kazası neticesinde çalışanın bedensel veya ruhsal bütünlüğünün geçici olarak bozulması ve tıbbi istirahat alarak işten uzak kalması durumu, literatürde ve yasal mevzuatta "geçici iş göremezlik" kavramı ile tanımlanmaktadır. Sosyal Güvenlik Kurumu (SGK) kayıtlarında yer alan iş kazası istatistikleri incelendiğinde, geçici iş göremezlik sürelerinin

kaza şiddetini ve meydana gelen iş gücü kaybını ölçmede en temel epidemiyolojik göstergelerden biri olduğu görülmektedir (Kandemir ve Şimşek, 2019). Kurum normlarına göre bu süreç, kaza gününün haricinde yetkili sağlık birimlerince verilen raporla belgelendirilen ve çalışanın fiilen işten uzak kaldığı günlerin sayılması esasına dayanmaktadır.

Makro düzeydeki bu kurumsal veri yapısı, mevcut araştırmanın temelini oluşturan veri setinde makine öğrenmesi algoritmaları için spesifik hedef değişkenlere dönüştürülmüştür. İstatistiksel modelleme sürecinde geçici iş göremezlik süreleri, literatürdeki güncel kaza analizi çalışmalarında önerildiği üzere cinsiyet kırılımlı olarak tasnif edilmiştir (Kandemir ve Şimşek, 2019).

Veri setinde erkek çalışanlar için E1, E2, E3, E4 ve E5; kadın çalışanlar için ise K1, K2, K3, K4 ve K5 şeklinde kodlanan bu hiyerarşik değişkenler, kaza sonrasında sırasıyla 1, 2, 3, 4 ve 5 gün (ve üzeri) raporlu kalınan süreleri ifade etmektedir. Bu parametrelerin kuramsal ve istatistiksel olarak yorumlanmasında, araştırmanın veri bütünlüğünü sağlayan kesin bir metodolojik kısıt bulunmaktadır: İstirahat sürelerini belirten bu kodlar, kazanın fiziksel şiddeti ne kadar yüksek olursa olsun, yalnızca yaralanmalı ancak çalışanın hayatta kaldığı vakaları kapsamaktadır. SGK veri sözlüğünün temel kuralı gereği, bu sürelerin hiçbir senaryoda ölüm (mortalite) vakası olarak değerlendirilmemesi gerekmektedir (Sosyal Güvenlik Kurumu, 2024).

İş göremezlik gün sayılarındaki niceliksel artış, doğrudan kazanın anatomik etkilerine ve travmanın boyutuna işaret etmektedir. Örneğin, hafif yaralanmalar grubunda yer alan 1-2 günlük istirahatler (E1, E2, K1, K2) genellikle basit ergonomik vakaları veya yüzeysel travmaları betimlerken; 5 gün ve üzeri (E5, K5) süreler, cerrahi müdahale veya uzun süreli rehabilitasyon gerektiren ciddi iskelet-kas sistemi yaralanmalarını göstermektedir. Geliştirilen yapay zekâ tabanlı kaza tahmin modellerinde, şiddeti kademeli olarak artan bu geçici iş göremezlik süreleri, gelecekteki olası ağır riskleri ve potansiyel ölümcül kazaları tahmin etmede kritik "öncü göstergeler" (leading indicators) olarak temel alınmıştır.

1.3.2. Ölümlü İş Kazaları

İş sağlığı ve güvenliği disiplininde ölüm, çalışma ortamındaki risklerin yönetilemediğini ve alınan koruyucu tedbirlerin yetersiz kaldığını gösteren en ağır sonuçtur. Türk sosyal güvenlik sistemi bağlamında, bir iş kazasının ölümle sonuçlanması yalnızca bir

güvenlik ihlali olarak kalmamakta; vefat eden sigortalının geride kalan yakınları (hak sahipleri) açısından uzun vadeli maddi ve manevi zorlukları beraberinde getirmektedir. Bu derin sosyal ve hukuki etkilerinden dolayı devlet, oluşturduğu sosyal güvenlik ağı içerisinde ölümlü kazaları yaralanmalardan kesin hatlarla ayırmakta ve hak sahiplerini güvence altına alacak özel hukuki düzenlemeler yapmaktadır (Karaahmetoğlu, 2021).

Hukuki ve sosyal yapıdaki bu temel ayrım, Türkiye'deki iş kazası istatistiklerinin derlendiği kurumsal veri mimarisine de doğrudan yansımaktadır. Sosyal Güvenlik Kurumu (SGK) kayıt sisteminde, kaza anında veya kaza sonrasındaki süreçte gerçekleşen vefat durumları, sadece yaralanmayı temsil eden geçici iş göremezlik sürelerinden tamamen ayrı tutulmaktadır. Araştırmanın temelini oluşturan veri setinde de ölüm vakaları, istirahat kodlarına (E1-E5, K1-K5) dâhil edilmeden yalnızca "ölen erkek" ve "ölen kadın" değişkenleri üzerinden sınıflandırılmaktadır (Sosyal Güvenlik Kurumu, 2024).

Veri mimarisinde sağlanan bu net ayrım, ölümcül sonuçlar doğuran kaza kök nedenlerinin, sayıca çok daha fazla olan hafif şiddetli yaralanma verileriyle istatistiksel olarak birbirine karışmasını engellemektedir. Ölümlü vakaların kendi içinde bağımsız değişkenler olarak raporlanması; iş kazalarındaki ölümcül dinamiklerin, epidemiyolojik risk profillerinin ve cinsiyet temelli farklılıkların çok daha şeffaf ve objektif bir analitik çerçevede incelenebilmesine olanak tanımaktadır.

1.3.3. Yaralanma Türleri ve Kaza Kodlama Metodolojileri

Çalışma hayatında meydana gelen iş kazalarının doğru bir şekilde analiz edilebilmesi, bu olayların belirli standartlara uygun olarak yapılandırılmasına bağlıdır. Türkiye'de Sosyal Güvenlik Kurumu sistemine yansıyan kaza bildirimleri; kazanın oluş şekline, yaralanan vücut bölgesine ve travmanın türüne göre hiyerarşik bir düzende kayıt altına alınmaktadır. Kazaların anatomik sonuçlarına göre bu şekilde istatistiksel olarak sınıflandırılması, işletmelerde alınacak koruyucu önlemlerin belirlenmesinde doğrudan rehberlik görevi üstlenmektedir (Kandemir ve Şimşek, 2019). Nitekim güncel literatürde, kaza türlerinin yalnızca genel istatistikler üzerinden değil; sektörel bazlı fiziksel tehlikeler, ergonomik zorluklar ve çalışma ortamına özgü risk faktörleriyle birlikte değerlendirilmesi gerektiği vurgulanmaktadır (Özdemir, 2025).

Bu kuramsal altyapı doğrultusunda, araştırmamızın temelini oluşturan SGK veri setindeki kaza türleri ve fizyolojik sonuçlar, kurumun kendi veri mimarisine sadık kalınarak toplam 36 ana kaza kodu üzerinden incelenmiştir. İstatistiksel olarak ayrıştırılan bu kodlar,

işletmelerin iş sağlığı ve güvenliği yönetim sistemlerindeki mevcut zafiyetleri yansıtan somut göstergeler olarak işlev görmektedir. Örneğin, analiz edilen veri havuzunda oldukça yüksek bir frekansa sahip olan Kod 11: Yüzeysel Yaralanmalar, genellikle çalışma alanı düzeninin (housekeeping) ve temel hijyen standartlarının yeterli düzeyde sağlanamadığına işaret eden öncü bir sinyal niteliği taşımaktadır (Sosyal Güvenlik Kurumu, 2024).

Öte yandan, veri mimarisinde yer alan ağır tablolar tehlikenin şiddetinin tamamen değiştiğini göstermektedir. Kod 40: Travma Sonucu Organ Kaybı (Amputasyon) gibi geri döndürülemez kalıcı bedensel hasarlar; makine koruyucularının devre dışı bırakılması, periyodik bakımların aksatılması veya tehlikeli enerji izolasyonu (Etiketle-Kilitle-Emniyete Al-Dene / EKED) kurallarının ihlal edilmesi gibi ölümcül sonuçlar doğurabilecek majör mekanik hataların istatistiksel karşılığıdır (Sosyal Güvenlik Kurumu, 2024). SGK verilerindeki bu katı tasnif sistemi, devasa büyüklükteki olay havuzunun yalnızca sayısal bir yığın olarak değil; travmanın türü, şiddeti ve kök nedeni bağlamında epidemiyolojik olarak incelenebilmesine olanak tanımaktadır.

1.4. Yapay Zekâ ve Makine Öğrenmesi

Günümüzde veri üretim hızının ve depolama kapasitelerinin eksponansiyel olarak artması, karmaşık problemleri çözmek için geleneksel istatistiksel yöntemlerin ötesine geçen gelişmiş analiz tekniklerinin kullanılmasını zorunlu kılmıştır. Bu bağlamda, Yapay Zekâ (YZ) ve onun en önemli alt dallarından biri olan Makine Öğrenmesi (MÖ), büyük veri setlerinden anlamlı örüntüler çıkarma ve geleceğe yönelik yüksek doğruluklu tahminler yapma konusunda bilimsel araştırmaların merkezine yerleşmiştir. Özellikle iş sağlığı ve güvenliği (İSG) gibi çok değişkenli ve dinamik yapıya sahip alanlarda, geçmiş kaza verilerinin analiz edilerek gelecekteki risklerin proaktif bir şekilde yönetilmesi amacıyla YZ ve MÖ tekniklerinin kullanımı Türkiye'de ve dünyada giderek yaygınlaşmaktadır (Şengöz ve Bozkurt, 2025).

Yapay zekâ ve uzman sistemler, çalışma hayatında yaşanabilecek iş kazalarının ve meslek hastalıklarının önlenmesinde kritik bir rol oynamaktadır; bu sistemler sayesinde tehlikelerin tespiti ve risklerin ortadan kaldırılması için çalışma sahaları daha etkin yöntemlerle izlenebilmektedir. Geleneksel risk değerlendirme metotları çoğunlukla reaktif (olay sonrası) çözümler üretirken, denetimli makine öğrenmesi algoritmaları geçmiş kaza verileri gibi büyük veri havuzlarını kullanarak proaktif (olay öncesi) tahminleme modelleri sunmaktadır (Karabulut vd., 2024).

İş kazalarının oluşumu; sektörel dinamikler, çalışan demografisi, çalışma ortamı ve zamansal faktörler gibi birçok iç içe geçmiş parametreye bağlıdır. Geleneksel veri analizi yöntemleri genellikle bağımsız değişkenler arasındaki doğrusal ilişkilere odaklanırken, makine öğrenmesi algoritmaları veriler arasındaki doğrusal olmayan ve çok boyutlu karmaşık ilişkileri modelleyebilme kapasitesine sahiptir. Türkiye'deki sektörel veriler üzerine yapılan çalışmalar, makine öğrenmesi algoritmalarının iş kazası sonuç tahmini ve risk analizinde geleneksel yöntemlere kıyasla çok daha yüksek başarı oranlarına ulaştığını göstermektedir (Küntaş ve Bezek Güre, 2024). Bu tez kapsamında uygulanacak olan algoritmalar da literatürdeki bu güncel bulguları destekler nitelikte olup, kaza verileri ışığında iş kazalarının önlenmesi için güçlü ve yerel bir karar destek mekanizması sunmayı hedeflemektedir.

1.4.1. Yapay Zekâ

Yapay zekâ (YZ), en temel ifadeyle, bilgisayar sistemlerinin öğrenme, akıl yürütme, problem çözme ve karar verme gibi insan zekâsına özgü bilişsel fonksiyonları algoritmik düzeyde taklit edebilme yeteneğidir. Geleneksel yazılımlar önceden tanımlanmış katı kurallar dizisine (kural tabanlı algoritmalara) göre çalışırken, yapay zekâ sistemleri devasa veri setlerini analiz ederek kendi başlarına örüntüler keşfedebilmekte ve deneyim yoluyla performanslarını artırabilmektedir. Bu yapısal dönüşüm, yapay zekâyı salt bir otomasyon aracı olmaktan çıkarıp, karmaşık ve belirsizlik içeren dinamik ortamlarda stratejik kararlar alabilen kilit bir sisteme dönüştürmüştür. İş sağlığı ve güvenliği (İSG) disiplini yapay zekâ uygulamaları, Endüstri 4.0 ve dijitalleşme vizyonu ile birlikte hızla standartlaşmakta; kaza öngörü modellerinin oluşturulması gibi konularda geleneksel reaktif (tepkisel) yöntemlerin yerini alarak, olay öncesi (proaktif) koruma kalkanları oluşturmaktadır (Ayan, Taşçı, ve Köksal, 2024).

Özellikle Türkiye'deki kaza kayıt sistemleri gibi geniş çaplı ve çok parametrelili verilerin analizinde, yapay zekâ algoritmaları bağımsız değişkenler arasındaki doğrusal olmayan gizli ilişkileri matematiksel olarak ortaya koyabilmektedir. Literatürdeki güncel çalışmalar, faaliyet alanlarının tehlike sınıflarının belirlenmesinde ve iş kazası frekanslarının tahminlenmesinde YZ modellerinin, uzman komisyonlarının deneyimlerine ek olarak nesnel, veriye dayalı ve yanılma payı düşük sonuçlar ürettiğini kanıtlamaktadır. Sosyal Güvenlik Kurumu (SGK) iş kazası ve meslek hastalıkları istatistikleri gibi ulusal veri tabanlarının yapay zekâ ile işlenmesi, hem sektörel bazda dinamik risk haritalarının

ıkarılmasını kolaylařtırmakta hem de kaynakların kaza riski en yksek alanlara ynlendirilmesini saęlayarak iř kazalarının nlenmesinde optimum stratejiler sunmaktadır (Akaner ve zdemir, 2022).

1.4.2. Makine ğrenmesi ve Zaman Serisi Analitięi

Zaman serisi, belirli zaman aralıklarında (gnlk, aylık veya yıllık) ardışık olarak kaydedilen gzlemler dizisidir. İř kazalarının ardında yatan dinamiklerin anlařılmasında, olayların rastgele deęil, belirli bir zamansal eęilim (trend) ve mevsimsellik iinde gerekleřip gerekleřmedięinin analizi kritik neme sahiptir. Trkiye'deki Sosyal Gvenlik Kurumu (SGK) tarafından kaydedilen lm ve srekli iř gremezlik vakaları, doęası gereęi birer zaman serisi verisi oluřturur. Gemiř yıllara ait bu kaza frekanslarının tahminlenmesinde yaygın olarak kullanılan ARIMA (Otoregresif Entegre Hareketli Ortalama) gibi geleneksel doęrusal modeller, verideki karmařıklığı tam anlamıyla yansıtmakta zorlanabilmektedir. Buna karřın, makine ğrenmesi algoritmaları kaza verilerinin iindeki doęrusal olmayan gizli zamansal rntleri ok daha yksek bir doęrulukla yakalayabilmekte ve uzun vadeli iř kazası tahminlemelerinde geleneksel istatistiksel yntemlere kıyasla stn performans sergilemektedir (Ergl, 2018).

Geleneksel zaman serisi yntemleri, verilerin istatistiksel daęılımı ve duraęanlıęı hakkında katı varsayımlar gerektirdięinden, yksek grlt ieren ve duraęan olmayan veri setlerinin uzun vadeli tahminlerinde zayıf kalmaktadır. Gnmzde, byk verilerin kaydedilmesi ve anlamlı bilgiye dnřtrlmesi kolaylařtıka, zaman serisi analizinde makine ğrenmesi tekniklerinin kullanımı hızla artmıřtır. zellikle Rassal Orman (Random Forest) ve eXtreme Gradient Boosting (XGBoost) gibi topluluk (ensemble) ğrenme yntemleri, modelin varyansını ve sapmasını azaltarak yksek bir genelleme kabiliyetine ulařmaktadır. Bu algoritmalar, zaman serisi verilerinde doęrusal olarak ayrılamayan, ok boyutlu iliřkileri dıřsal řoklara karřı direnli bir řekilde modelleyebilmektedir. Dolayısıyla, iř kazası tahminleme modelleri gibi ardışık ve deęiřken yapılı karmařık veri setlerinde, makine ğrenmesi temelli zaman serisi yaklařımları proaktif stratejilerin geliřtirilmesi iin saęlam bir zemin sunmaktadır (Doęan ve Bykkr, 2022).

1.4.3. Karar Aęacı Tabanlı Modeller

Makine ğrenmesi modelleri arasında, zellikle sınıflandırma ve regresyon problemlerinin zmnde en řeffaf ve anlařılır yntemlerden biri karar aęalarıdır. Karar

ağaçları, karmaşık veri setlerini içerdikleri bağımsız değişkenlerin (örneğin kaza saati, çalışan yaşı, mesleki deneyim veya risk sınıfı) bilgi kazancı veya istatistiksel saflık derecelerine göre ardışık olarak dallara ayırarak nihai sonuçları yaprak düğümlerde toplayan algoritmik bir yapıdır. İş sağlığı ve güvenliği alanında, verilerin sahip olduğu iç içe geçmiş örüntülerin haritalandırılması ve riskli grupların tespit edilmesi amacıyla karar ağaçları oldukça sık kullanılmaktadır. Bu algoritmalar, hangi faktörlerin iş kazalarına zemin hazırladığını hiyerarşik kurallar silsilesi şeklinde ortaya koyarak olay öncesi önlem alınmasını ve risk analizini önemli ölçüde kolaylaştırır (Köse ve Ersöz, 2020).

Bununla birlikte, analiz sürecinde oluşturulan tek bir karar ağacının, kendisine sunulan mevcut eğitim verisini çok ince detaylarına kadar ezberleme riski oldukça yüksektir. Modelin eğitim verisine aşırı uyum sağlayarak ezberlemesi durumunda, model esnekliğini yitirmekte ve gelecekte karşılaşılabilecek yeni, daha önce görülmemiş kaza verilerini doğru tahmin etme başarısı ciddi oranda düşmektedir. Bu zafiyeti ortadan kaldırmak amacıyla, çalışmamızda tek bir ağacın üretebileceği yanılma payını ve sapmayı en aza indiren; birden fazla ağacın entegre edilerek ortak ve daha güçlü bir karara vardığı gelişmiş topluluk öğrenmesi yöntemleri tercih edilmiştir. Bu metodolojik yaklaşım doğrultusunda çalışmamızın temel tahminleme modellerini, topluluk öğrenmesi mimarisıyla çalışan Random Forest (Rassal Orman), XGBoost ve LightGBM algoritmaları oluşturmaktadır.

1.4.4. Random Forest (Rassal Orman) Algoritması

Rassal Orman (Random Forest) algoritması, makine öğrenmesinde hem sınıflandırma hem de regresyon problemleri için yüksek performans sunan, karar ağaçları temelli güçlü bir topluluk öğrenmesi yöntemidir. Algoritmanın temel çalışma mekanizması, literatürde "torbalama" ve "önyükleme" olarak bilinen istatistiksel veri türetme tekniklerinin entegrasyonuna dayanmaktadır. Öğrenme sürecinde, orijinal veri setinden rastgele ve yerine koyarak çekilen örneklerle çok sayıda bağımsız alt veri seti (eğitim kümesi) oluşturulur ve her bir alt veri seti kullanılarak yüzlerce farklı karar ağacı eğitilir. Buna ek olarak, ağaçların dallanma (bölünme) aşamasında mevcut tüm bağımsız değişkenler yerine rastgele seçilmiş bir değişken alt kümesi dikkate alınır. Bu ikili rastgellik stratejisi sayesinde her bir ağacın birbirinden bağımsız büyümesi sağlanarak, tekil karar ağaçlarında sıkça karşılaşılan eğitim verisini ezberleme zafiyeti (aşırı uyum) engellenir. Modelin nihai tahmin kararı ise, ormanı oluşturan tüm ağaçların ürettiği bireysel sonuçların birleştirilmesiyle (sınıflandırma problemlerinde çoğunluk oylaması, regresyonda ise ortalama alınarak) elde edilir. İş kazası

verilerinin analizinde Rassal Orman algoritmasının kullanımı, özellikle çok boyutlu, gürültülü ve kategorik değişkenlerin yoğun olduğu veri setleriyle başa çıkabilme yeteneği sayesinde öne çıkmaktadır. Türkiye'deki sektörel iş kazaları üzerine yapılan çalışmalar, bu algoritmanın kaza nedenlerini ve sonuçlarını tahminlemede geleneksel istatistiksel yöntemlere kıyasla çok daha üstün bir doğruluk oranına (k-katlı çapraz doğrulama testlerinde yüksek yüzdelik başarılarla) ulaştığını kanıtlamaktadır. İş günü kaybı, kazanın yaşandığı saat, tehlike kaynağı, çalışanın yaşı ve mesleki deneyimi gibi karmaşık değişkenler, Rassal Orman algoritmasının sunduğu "değişken önem düzeyi" metriği sayesinde matematiksel olarak sıralanabilmektedir. Böylece model, yalnızca kazanın gerçekleşme ihtimalini tahmin etmekle kalmaz; aynı zamanda hangi parametrelerin kazaya en çok zemin hazırladığını istatistiksel olarak ağırlıklandırarak, olay öncesi müdahale edilebilecek proaktif risk hedefleri sunar (Karakaya Özkan ve Ulaş, 2023).

1.4.5. eXtreme Gradient Boosting (XGBoost) Algoritması

eXtreme Gradient Boosting (XGBoost), literatürde Aşırı Gradyan Artırma olarak ifade edilen ve karar ağaçlarına dayalı olarak çalışan oldukça güçlü bir topluluk öğrenme algoritmasıdır. Rassal Orman modelinde ağaçlar birbirinden bağımsız olarak oluşturulurken, XGBoost yönteminde karar ağaçları ardışık bir düzen içerisinde inşa edilmektedir. Bu mimarinin temel amacı, kurulan her yeni ağacın bir önceki ağacın yaptığı tahmin hatalarına (artık hatalara) odaklanması ve bu hataları en aza indirecek şekilde kendini ardışık olarak eğitmesidir. Sistem, matematiksel bir optimizasyon süreciyle zayıf tahmin edicileri ardışık iterasyonlarla güçlü ve hatasız bir karar mekanizmasına dönüştürmekte; böylece özellikle büyük boyutlu veri setlerinde yüksek hesaplama hızı ve üstün bir doğruluk düzeyi sağlamaktadır (Atalay ve Zor, 2025).

Binlerce gözlem, yoğun kategorik değişken ve çok boyutlu dinamikler içeren karmaşık yapıdaki problemlerde XGBoost algoritması, sahip olduğu içsel düzenleştirme yetenekleri sayesinde öne çıkmaktadır. Algoritmanın matematiksel çekirdeğinde yer alan bu düzenleştirme mekanizmaları, modelin mevcut eğitim verisine aşırı uyum sağlayarak ezberlemesini engelleyerek, genel tahmin başarı oranını maksimize eder. Ayrıca algoritma, devasa boyutlardaki kayıt sistemlerinde sıklıkla karşılaşılan eksik, boş veya tutarsız verileri modelleme esnasında otomatik olarak doğru düğümlere yönlendirerek işleyebilme kapasitesine sahiptir. Bu esnek ve dışsal şoklara dayanıklı altyapısı sayesinde algoritma,

sınıflandırma ve regresyon problemlerindeki istatistiksel sapmaları minimuma indirerek son derece isabetli modeller oluşturulmasına imkân tanımaktadır (Tokmak, 2023).

1.4.6. Light Gradient Boosting Machine (LightGBM) Algoritması

Light Gradient Boosting Machine (LightGBM), karar ağaçlarına dayalı olarak çalışan ve özellikle büyük boyutlu veri setleri için optimize edilmiş yüksek performanslı bir topluluk öğrenme algoritmasıdır. Geleneksel karar ağacı algoritmaları ağaç mimarisini "seviye odaklı" (derinlik öncelikli) bir yatay stratejiyle büyütürken, LightGBM "yaprak odaklı" dikey bir büyüme stratejisi benimsemektedir. Bu yaklaşımda algoritma, mevcut yapraklar arasından modelin genel hata oranını en çok düşürecek olan yaprağı seçerek dallanmayı o yönde sürdürür. Buna ek olarak algoritma, sürekli değişkenleri ayrık bölmelere (sepetlere) dönüştüren "histogram tabanlı" bir matematiksel karar mekanizması kullanır. Bu sayede model, her bir düğümde en uygun bölünme noktasını bulmak için tüm veri noktalarını tek tek taramak yerine, oluşturulan bu özet bölmeler üzerinden işlem yaparak hesaplama maliyetini dramatik biçimde düşürür ve tahmin doğruluğunu artırır (Eşidir, 2025).

Kapsamlı risk tahminlemesi gibi milyonlarca satır veri ve çok sayıda bağımsız değişken barındıran devasa boyutlu analitik problemlerde LightGBM, sunduğu düşük bellek tüketimi ve olağanüstü hesaplama hızı ile literatürde öne çıkmaktadır. Algoritmanın benimsediği yaprak odaklı büyüme stratejisi doğası gereği derin ve karmaşık ağaçlar oluşturmaya eğilimli olsa da, sistemin kendi mimarisinde yer alan kısıtlayıcı düzenleme parametreleri (maksimum yaprak sayısı ve minimum yaprak verisi gibi) sayesinde modelin eğitim verisine aşırı uyum sağlayarak ezberlemesi kesin bir biçimde engellenmektedir. Böylece algoritma, devasa boyutlardaki kayıt sistemlerinden elde edilen gürültülü ve karmaşık verileri çok daha hızlı bir biçimde işleyerek, olay öncesi öngörülerde yüksek genelleme yeteneğine sahip kararlı ve güvenilir karar destek modelleri üretilmesine olanak tanır (Şimşek, 2024).

1.5. İş Sağlığı ve Güvenliğinde Yapay Zekâ Uygulamaları

İş sağlığı ve güvenliği (İSG) alanında risklerin analizi ve iş kazalarının önlenmesi amacıyla yapılan akademik çalışmalar, son yıllarda geleneksel istatistiksel yöntemlerden yapay zekâ ve makine öğrenmesi tabanlı öngörü modellerine doğru büyük bir paradigma değişimi yaşamıştır. Literatürdeki güncel çalışmalar incelendiğinde, denetimli makine öğrenmesi algoritmalarının, kaza verilerindeki doğrusal olmayan karmaşık ilişkileri

modellemede geleneksel reaktif (olay sonrası) yöntemlere kıyasla çok daha proaktif (olay öncesi) ve yüksek doğruluklu sonuçlar ürettiği görülmektedir (Karabulut vd., 2024). Özellikle sektörel bazlı kaza verilerinin analiz edildiği araştırmalar, makine öğrenmesi sistemlerinin uzman komisyonlarının deneyimlerine ek olarak nesnel, veriye dayalı ve yanılma payı düşük karar destek mekanizmaları sunduğunu kanıtlamaktadır (Ayan vd., 2024).

Kaza tahminlemesi literatüründe en çok tercih edilen algoritmaların başında karar ağacı tabanlı modeller gelmektedir. Köse ve Ersöz (2020), demir-çelik endüstrisinde yaşanan iş kazaları üzerine yaptıkları çalışmada, karar ağaçlarının hangi faktörlerin kazalara zemin hazırladığını hiyerarşik kurallar silsilesiyle başarıyla haritalandırdığını ortaya koymuştur. Ancak tekil ağaçların veriyi ezberleme (aşırı uyum) zafiyetini aşmak amacıyla araştırmacılar hızla topluluk öğrenmesi yöntemlerine yönelmiştir. Örneğin, Karakaya Özkan ve Ulaş (2023) Türkiye metal sektöründeki iş kazalarını tahminlemek için Rassal Orman (Random Forest) algoritmasını kullanmış ve modelin sunduğu "değişken önem düzeyi" metriği sayesinde kaza saatinden mesleki deneyime kadar birçok karmaşık parametrenin kaza riskindeki ağırlığını yüksek doğrulukla hesaplamayı başarmışlardır. Benzer şekilde, büyük boyutlu ve gürültülü veri setlerinin analizinde Aşırı Gradyan Artırma (XGBoost) gibi algoritmaların, ardışık öğrenme ve artık hataları düzeltme mimarisi sayesinde genel tahmin performansını maksimize ettiği literatürde sıklıkla vurgulanmaktadır (Tokmak, 2023).

Türkiye'de iş kazalarının makro boyutta incelenmesi için en güvenilir veri kaynağı olan Sosyal Güvenlik Kurumu (SGK) istatistikleri de çeşitli yapay zekâ çalışmalarına konu olmuştur. Akaner ve Özdemir (2022), SGK iş kazası verilerini kullanarak faaliyet alanlarının tehlike sınıflarını yapay sinir ağları ile belirlemiş ve makine öğrenmesinin tehlike sınıflandırmasında uzman görüşleriyle örtüşen yüksek isabet oranları yakaladığını göstermiştir. Ergül (2018) ise Türkiye'deki iş kazalarından kaynaklanan ölüm ve sürekli iş göremezlik vakalarını zaman serisi olarak modellemiş; geleneksel ARIMA gibi doğrusal metotların aksine, makine öğrenmesi algoritmalarının verideki gizli zamansal örüntüleri yakalayıp daha başarılı tahminler ürettiğini saptamıştır.

2. MATERYAL VE YÖNTEM

2.1. Araştırmanın Problemi

İş kazalarının önlenmesine yönelik ulusal çapta alınan yasal ve yönetsel tedbirlere rağmen, Türkiye'de meydana gelen iş kazaları ile bunlara bağlı iş göremezlik durumları ciddi sosyo-ekonomik sonuçlar doğurmaya devam etmektedir (İlgin ve Timuralp, 2024). Kaza kök nedenlerinin birbirini tetikleyen ardışık faktörlerden meydana gelmesi, geleneksel olay sonrası reaktif müdahale yöntemlerinin iş kazalarının önlenmesinde ve azaltılmasında yetersiz kalmasına yol açmaktadır. Bu durum, kaza oluşum mekanizmalarının ve risk faktörlerinin daha yenilikçi, kaynağında çözüme odaklanan proaktif yaklaşımlarla analiz edilmesini zorunlu kılmaktadır (Özbucak Albar, 2024).

Günümüzde çalışma hayatından elde edilen verilerin artan hacmi ve nedensel karmaşıklığı, geleneksel istatistiksel analiz yöntemlerinin geleceğe yönelik iş kazası projeksiyonları oluşturmada yetersiz kalmasına neden olmaktadır (Ergül, 2018). Bu bağlamda, yüksek boyutlu ve dengesiz dağılım sergileyen kaza verilerinin analizinde topluluk öğrenme (ensemble learning) temelli algoritmaların, geleneksel yaklaşımlara kıyasla daha başarılı sonuçlar ürettiği vurgulanmaktadır (Karakaya Özkan ve Ulaş, 2023). Çeşitli sektör uygulamalarında denetimli makine öğrenmesi algoritmalarının entegrasyonu ile görünmeyen risk örüntülerinin tespit edilmeye çalışıldığı ve İSG alanında yapay zekâ teknolojilerinin kullanımının giderek önem kazandığı görülmektedir (Ayan, Taşçı, ve Köksal, 2024).

Ulusal ölçekteki geçmiş yıllara ait kayıtlar incelendiğinde, hem geçici iş göremezlik sürelerini hem de ölümle sonuçlanan iş kazalarını aynı anda ve çoklu algoritmalarla tahmin eden zaman serisi çalışmalarının kısıtlı olduğu dikkat çekmektedir. Buradan hareketle araştırmanın temel problemi; Türkiye'deki iş kazalarının reaktif yaklaşımlarla yeterince engellenememesi ve geleceğe yönelik (2025-2033) risk projeksiyonlarının veri temelli olarak güvenilir biçimde tahmin edilebilmesi için proaktif bir modellemeye ihtiyaç duyulmasıdır. Literatürdeki bu boşluk, çok adımlı bir tahmin mimarisinin geliştirilmesini gerektirmektedir. Random Forest, XGBoost ve LightGBM algoritmalarının karşılaştırmalı olarak entegre edildiği bütünsel analizlerin literatürde oldukça sınırlı kalması, bu çalışmanın çıkış noktasını oluşturmaktadır.

2.2. Araştırmanın Amacı ve Önemi

Bu araştırmanın temel amacı; Türkiye genelinde meydana gelen iş kazalarından kaynaklı, farklı süre kategorilerindeki (1, 2, 3, 4 ile 5 gün ve üzeri) geçici iş göremezlik durumlarını ve ölümlü sonuçlanan vakaları makine öğrenmesi algoritmaları aracılığıyla karşılaştırmalı olarak tahmin etmektir. Bu doğrultuda, 2016-2024 dönemi Sosyal Güvenlik Kurumu (SGK) kayıtları temel alınarak, 2025-2033 yılları arası için Random Forest, XGBoost ve LightGBM algoritmaları ile çok adımlı projeksiyonlar oluşturulması amaçlanmaktadır. Çalışma, yalnızca geçmiş verilerin betimsel bir özetini sunmayı değil; kaza türleri, işgünü kayıpları ve ölümlü vakalar arasındaki veri örüntülerini modelleyerek, proaktif risk değerlendirmesine destek sağlayacak analitik bir çerçeve oluşturmayı hedeflemektedir.

Çalışmanın önemi, yüksek boyutlu ve dengesiz dağılım sergileyen ulusal kaza verilerinin analizinde karar ağacı tabanlı topluluk (ensemble) öğrenme algoritmalarının karşılaştırmalı olarak değerlendirilmesinden kaynaklanmaktadır. Literatürde veri madenciliği ve karar ağacı algoritmalarının endüstriyel kaza analizlerinde kullanıldığı görülse de (Köse ve Ersöz, 2020), farklı şiddetteki iş göremezlik sürelerinin ve ölümlü sonuçlanan kazaların aynı anda, ulusal ölçekte ve birden fazla algoritma ile geleceğe dönük olarak modellendiği çalışmalar oldukça kısıtlıdır. Bu araştırma, Random Forest, XGBoost ve LightGBM modellerinin zaman serisi tahminlerindeki genelleme yeteneklerini ve hata oranlarını analiz ederek literatüre karşılaştırmalı yöntemsel bir katkı sağlamaktadır (Doğan ve Büyükkör, 2022).

Elde edilecek öngörülerin, akademik literatürdeki mevcut boşluğa katkı sunmasının yanı sıra politika yapıcılara ve endüstri profesyonellerine stratejik bir karar destek zemini oluşturma potansiyeli taşıdığı değerlendirilmektedir. Denetimli makine öğrenmesi algoritmalarının kaza önleme stratejilerine entegre edilmesi, sektördeki risklerin henüz gerçekleşmeden öngörülebilmesi için analitik bir yaklaşım sunmaktadır (Karabulut, Baran, ve Eraslan, 2024). Bu bağlamda, çalışmanın potansiyel bulguları; ulusal İSG politikalarının veri temelli güncellenmesi, denetim mekanizmalarının risk projeksiyonlarına göre önceliklendirilmesi ve kaza maliyetlerinin proaktif bir yaklaşımla azaltılmasına destek vermesi açısından önem arz etmektedir.

2.3. Araştırmanın Kapsamı ve Sınırlılıkları

İş sağlığı ve güvenliği disiplini risklerin yönetilebilmesi ve önleyici stratejilerin geliştirilmesi amacıyla nicel analizlerin yürütülmesi temel bir gereklilik olarak kabul edilmektedir (Karabal, 2021). Bu gereklilikten hareketle kurgulanan araştırmanın veri kapsamı, Türkiye genelinde 2016-2024 yılları arasında Sosyal Güvenlik Kurumu (SGK) tarafından kayıt altına alınan ve iş kazası yaralanma türü kodlarına göre sınıflandırılan ulusal istatistiklerle sınırlandırılmıştır. Çalışmanın analitik kapsamı, farklı süre kategorilerindeki geçici iş göremezlik süreleri ile ölümlerle sonuçlanan vakaların incelenmesini içermektedir. Yöntemsel kapsam ise, söz konusu tarihsel veriler üzerinden eğitilen Random Forest, XGBoost ve LightGBM algoritmaları aracılığıyla 2025-2033 dönemine yönelik çok adımlı projeksiyonların üretilmesiyle belirlenmiştir.

Araştırmanın temel veri sınırlılığı, analiz edilen veri setinin yalnızca yasal bildirim yükümlülüklerinin yerine getirildiği kayıtlı istihdam verilerine dayanmasıdır. İstatistiksel analizlerde risk faktörlerinin tam olarak modellenmesi için resmi kayıtlara yansımayan ramak kala olayların ve kayıt dışı durumların da bilinmesi gerektiği, aksi takdirde sonuçların eksik kalabileceği literatürde vurgulanmaktadır (Tunca ve Utlu, 2016). Bu durum doğrultusunda; kayıt dışı istihdam alanlarında meydana gelen veya çeşitli idari nedenlerle SGK sistemine bildirilmeyen hafif yaralanmalı iş kazaları resmi verilere yansımadığı için bu araştırmanın kapsamı dışında bırakılmıştır.

Araştırmanın bir diğer sınırlılığı ise zaman serisi ve makine öğrenmesi modellerinin doğasından kaynaklanmaktadır. Zaman serisi modellemelerinde gelecek tahminlerinin başarı oranı, eğitim setindeki verilerin kalitesine ve çevresel faktörlerin sabit kalması varsayımına bağlıdır (Azizoğlu, 2025). Ayrıca, dengesiz dağılım sergileyen ve gürültülü (noise) öznitelikler barındıran veri setlerinin, karmaşık algoritmaların genelleme yeteneklerini belirli ölçüde kısıtlayabildiği bilinmektedir (Gökalp, 2022). Bu bağlamda, iş kazası veri setinin doğasında bulunan dengesizliklerin algoritmalar üzerindeki kısıtlayıcı etkisi ile ilerleyen yıllarda (2025-2033) meydana gelebilecek makroekonomik dalgalanmaların, yasal mevzuat değişikliklerinin veya dışsal şokların kaza frekanslarındaki olası saptırıcı etkileri, çalışmanın yöntemsel sınırlılıkları olarak kabul edilmiştir.

2.4. Araştırmanın Modeli ve Tasarımı

Bu araştırma, geçmiş yıllara ait iş kazası verilerinden hareketle geleceğe dönük risk projeksiyonları üretebilmek amacıyla nicel araştırma deseninde kurgulanmıştır. Çalışma,

birden fazla hedef deęiřkeni ayrı ayrı ele alan ve çok adımlı tahmin üreten bir zaman serisi modelleme tasarımına dayanmaktadır. Geleneksel istatistiksel yaklaşımların aksine; iş kazalarının sonuçlarını yansıtan göstergeleri, karmařık veri örüntülerini ve doğrusal olmayan ilişkileri analiz edebilmek için denetimli makine öğrenmesi (machine learning) algoritmalarından yararlanılmıştır. Literatürde, yüksek boyutlu kaza verilerinin analizinde makine öğrenmesi teknolojilerinin tahmin performansına önemli katkılar sunabildięi ifade edilmektedir (Yavuz vd., 2021).

Araştırma tasarımı, veri setinin dönüřtürölmesi ve modellerin eęitilmesi olmak üzere ardışık aşamalardan meydana gelmektedir. Öncelikle, 2016-2024 dönemine ait yıllık Sosyal Güvenlik Kurumu (SGK) verileri; iş kazası yaralanma türü kodları ve hedef deęiřkenler (farklı süre kategorilerindeki geçici iş göremezlik süreleri ile cinsiyete göre sınıflandırılmış ölümlü vakalar) baz alınarak bütünleşik bir panel veri setine dönüřtürölmüřtür. Zaman serilerinde algoritmaların tarihsel örüntüleri öğrenmesini saęlamak için geçmiş yılların verilerini modele tanıtan gecikme (lag) öznitelikleri üretilmiştir. Kaza tahmin modellerinde tarihsel serilerin gecikmeli olarak sisteme dâhil edilmesi, modelin geleceęi öngörme yeteneęini iyileştirebilmektedir (Yaęımlı ve İzci, 2017). Bu doğrultuda, yapılan ön testler ve algoritmaların aşırı öğrenme (overfitting) eğilimleri dikkate alınarak tasarımsal bir sınırlandırmaya gidilmiştir. Bu doğrultuda, veri setine Random Forest modeli için yalnızca 1 yıllık gecikme (Lag-1), XGBoost ve LightGBM modelleri için ise 1, 2 ve 3 yıllık gecikme deęiřkenleri (Lag-1, Lag-2, Lag-3) dâhil edilmiştir.

Analiz aşamasında, karar ağacı tabanlı topluluk (ensemble) öğrenme algoritmalarından olan Random Forest (Bagging mantıęı), XGBoost ve LightGBM (Boosting mantıęı) modelleri karşılařtırmalı olarak kurgulanmıştır. Karar ağacı temelli topluluk yapılarının, veri setindeki karmařıklıęı yöneterek aşırı uyum riskini sınırlandırdıęı ve tahmin varyansını azaltabildięi bilinmektedir (Yılmaz, 2014). Geliřtirilen bu çoklu makine öğrenmesi mimarisinde modellerin performansı; Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Hata (MAE) metrikleri kullanılarak deęerlendirilmiştir (Koc vd., 2022). Bu metrikler üzerinden yapılan karşılařtırmalı deęerlendirme sonucunda, en düşük hata skorlarını üreten model belirlenmiş ve çalışma kapsamında bu model aracılıęıyla 2025-2033 dönemine ait ulusal kaza projeksiyonlarının oluřturulması hedeflenmiştir.

2.5. Veri Seti ve Ön İşleme Adımları

Bu araştırmanın temel veri setini, Sosyal Güvenlik Kurumu (SGK) tarafından kayıt altına alınan 2016-2024 dönemine ait yıllık iş kazası istatistikleri oluşturmaktadır. Veri kümesi, kazaların oluşum biçimlerini standardize eden "Yaralanma Türü Kodları" (KOD_NO) temelinde (örneğin; Kod 011: Yüzeysel Yaralanmalar, Kod 021: Kapalı Kırıklar) yapılandırılmıştır. Modelde kullanılacak hedef değişkenler, cinsiyet ve kaza şiddeti kırılımlarına göre özel olarak tasnif edilmiştir. Bu bağlamda, erkek (E1, E2, E3, E4, E5) ve kadın (K1, K2, K3, K4, K5) çalışanlar için sırasıyla 1, 2, 3, 4 ile 5 gün ve üzeri rapor alınan vakalar, geçici iş göremezlik durumları olarak tanımlanmıştır. Ölümle sonuçlanan iş kazaları ise bu sürelerden bağımsız biçimde, veri setindeki "ölen erkek" ve "ölen kadın" sütunlarında yer alan mutlak değerler üzerinden modele sunulmuştur.

Makine öğrenmesi modellerinin ham verilerle çalıştırılması durumunda öğrenme performanslarının düşebileceği; bu nedenle veri setlerinin analize girmeden önce eksik (null) değerlerden arındırılması ve yapısal bir ön işleme (preprocessing) sürecinden geçirilmesi gerektiği literatürde ifade edilmektedir (Karakaya Özkan ve Ulaş, 2023). Bu teorik gereklilikten hareketle; çalışmada öncelikle her yıla ait bağımsız SGK veri dosyaları kronolojik olarak birleştirilmiş ve bütünlüklü bir panel veri matrisine dönüştürülmüştür. Bu aşamada, veri kaybından kaynaklanan gerçek eksik veriler ile olay yaşanmaması nedeniyle ortaya çıkan "yapısal sıfırlar" (structural zeros) birbirinden özenle ayrılmıştır. İlgili yılda belirli bir yaralanma türü kodunda hiç kaza veya ölüm rapor edilmemişse, bu durum bir veri eksikliği değil istatistiksel bir gerçeklik (yapısal sıfır) kabul edilerek, zaman serisi bütünlüğünü korumak amacıyla söz konusu hücrelere sıfır (0) değeri atanmıştır. Ayrıca, algoritmaların veri örüntülerini hatasız işleyebilmesi için tüm sütunlar sayısal (integer/float) formata dönüştürülerek standardize edilmiştir.

Zaman serisi projeksiyonlarında algoritmaların sadece mevcut anı değil, geçmişin eğilimlerini de öğrenebilmesi için geçmiş dönem gözlemlerinin yeni öznitelikler (feature) olarak sisteme tanıtılması, tahmin yeteneğini destekleyen bir veri mühendisliği adımı olarak değerlendirilmektedir (Doğan ve Büyükkör, 2022). Bu yöntem benimsenerek; veri setindeki her bir yaralanma kodu ve hedef değişken için geçmiş yılları temsil eden yeni gecikme değişkenleri (Lag serileri) üretilmiş ve veri havuzuna dâhil edilmiştir. Hangi makine öğrenmesi algoritmasının hangi gecikme düzeyini (Lag-1, Lag-2 vb.) kullanacağı hususu ise modellerin kendi mimari özelliklerine bırakılmış olup, bu atamalar algoritma yapılandırma aşamasında gerçekleştirilmiştir. Uygulanan veri temizleme ve öznitelik mühendisliği

süreçlerinin sonucunda; "Yıl" ve "KOD_NO" tanımlayıcı değişkenleri ile birlikte, iş göremezlik (E1-E5, K1-K5) ve mortalite (ölen erkek, ölen kadın) sütunlarını barındıran toplam 14 ana değişkenli, eğitime hazır nihai bir veri seti elde edilmiştir.

2.5.1. Değişkenlerin Tanımlanması

Makine öğrenmesi araştırmalarında algoritmaların statik kurallar yerine veriye dayalı isabetli tahminler üretebilmesi; sisteme sunulan örnek girdi öznelikleri (features) ile model çıktısı olarak tahmin edilecek hedef değişkenin (target) yapısal olarak net bir biçimde belirlenip ayrıştırılmasına dayanmaktadır (Zilyas ve Yılmaz, 2023). Bu metodolojik gereklilik doğrultusunda çalışmanın veri seti, Sosyal Güvenlik Kurumu (SGK) tarafından kayıt altına alınan 2016-2024 dönemine ait ulusal iş kazası istatistikleri üzerinden tanımlanmıştır.

Veri matrisinin temel sınıflandırma omurgasını, kaza oluşum biçimlerini kategorize eden "Yaralanma Türü Kodları" (KOD_NO) oluşturmaktadır (Örneğin; Kod 011: Yüzeysel Yaralanmalar, Kod 021: Kapalı Kırıklar). Modellerin eğitimi için kurgulanan veri seti; zaman boyutunu gösteren "Yıl", kaza türünü tanımlayan "KOD_NO" ve tahmin edilecek hedef değişkenler olmak üzere toplam 14 ana değişkenden meydana gelmektedir. Algoritmaların kaza risk örüntülerini etkili biçimde modelleyebilmesi amacıyla, söz konusu hedef değişkenler yapısal olarak iki bağımsız gruba ayrılmıştır. Birinci hedef grubu olan geçici iş göremezlik vakaları; erkek (E1, E2, E3, E4, E5) ve kadın (K1, K2, K3, K4, K5) çalışanlar için raporlanan 1, 2, 3, 4 ile 5 gün ve üzeri istirahat sürelerini kapsayan 10 alt değişkenden oluşmaktadır. İkinci hedef grubu olan mortalite (ölüm) vakaları ise iş göremezlik sürelerinden bağımsız olarak; yalnızca "ölen erkek" ve "ölen kadın" verilerini barındıran 2 değişkenden oluşmaktadır. Bu yapısal sınıflandırma, algoritmaların yaralanma ve ölüm vakalarına ait farklı veri örüntülerini birbirinden yalıtarak daha tutarlı projeksiyonlar üretmesini desteklemek amacıyla kurgulanmıştır.

2.5.2. İş Göremezlik Değişkenleri

İş sağlığı ve güvenliği çalışmalarında geçici iş göremezlik süresi, kaza şiddetinin ölçülebilir bir göstergesi olarak değerlendirilmekte ve bu sürelerin cinsiyet gibi faktörlerle birlikte analiz edilmesi, risk örüntülerinin modellenmesinde temel bir yaklaşım olarak kabul edilmektedir (Kandemir ve Şimşek, 2019). Bu analitik çerçevede, çalışmada ölümle sonuçlanmayan yaralanmalı iş kazaları, Sosyal Güvenlik Kurumu (SGK) kayıt sistematığına

uygun olarak cinsiyet ve istirahat günü bazlı iş göremezlik değişkenleri üzerinden tanımlanmıştır.

Veri matrisindeki geçici iş göremezlik değişkenleri, cinsiyet faktörü dikkate alınarak E (Erkek) ve K (Kadın) ön ekleriyle kodlanmıştır. İlgili ön eklerin yanında yer alan sayısal değerler, kaza sonrasında alınan istirahat gün sayısını belirtmektedir. Bu yapısal tasnife göre; E1 ve K1 değişkenleri 1 günlük, E2 ve K2 değişkenleri 2 günlük, E3 ve K3 değişkenleri 3 günlük, E4 ve K4 değişkenleri 4 günlük, E5 ve K5 değişkenleri ise 5 gün ve daha uzun süreli iş göremezlik durumlarını ifade etmektedir. Toplam 10 alt değişkenden oluşan bu grup, geçici işgücü kaybının yaşandığı ve ölümle sonuçlanmayan vakaları kapsamaktadır. Makine öğrenmesi algoritmalarının hedef değişkenleri sınıflandırma sürecinde yapısal bir karmaşa yaşanmaması adına, E1-E5 ve K1-K5 değişkenleri analiz modelinde yaralanma şiddeti göstergesi olarak konumlandırılmış ve mortalite (ölüm) vakalarından yöntemsel olarak ayrıştırılmıştır.

2.5.3. Ölüm Değişkenleri

İş kazası istatistiklerinin analitik olarak modellenmesinde ölümle sonuçlanan (mortalite) vakalar, yaralanmalı olaylardan yapısal olarak farklı bir şiddet boyutunu temsil etmekte ve kaza risk analizlerinde bağımsız bir hedef çıktı olarak ele alınmaktadır (Horozoğlu, 2017). Bu metodolojik yaklaşıma uygun olarak çalışmada, kaza sonrası ölümle sonuçlanan vakalar, geçici iş göremezlik sürelerini temsil eden değişkenlerden (E1-E5, K1-K5) ayrılarak bağımsız bir hedef değişken grubu şeklinde yapılandırılmıştır.

Veri matrisinde mortalite durumu, Sosyal Güvenlik Kurumu (SGK) kayıtlarındaki cinsiyet kırılımlarına sadık kalınarak "ölen erkek" ve "ölen kadın" olmak üzere iki ayrı sayısal değişken üzerinden modele aktarılmıştır. İş göremezlik değişkenlerindeki gün bazlı sınıflandırmanın aksine, bu iki mortalite değişkeni ilgili yılda ve ilgili yaralanma türü kodunda (KOD_NO) meydana gelen mutlak ölüm sayılarını (frekanslarını) ifade etmektedir. Makine öğrenmesi algoritmalarının eğitim sürecinde, ölümle sonuçlanan vakaların istatistiksel olarak daha düşük olan frekans yapısını ve kendine özgü örüntülerini doğru bir şekilde modelleyebilmesi için söz konusu veriler diğer hedef değişkenlerden bağımsız olarak tanımlanmıştır. Bu ayrıştırma stratejisi, algoritmaların ölümcül olan ve olmayan kazalar arasındaki yapısal farkları tanımasını ve projeksiyon üretirken değişkenler arası etkileşimden doğabilecek modelleme hatalarını önlemeyi amaçlamaktadır.

2.5.4. Veri Düzenleme ve Lag Kurgusu

Zaman serisi modellemelerinde bağımlı değişkenlerin geçmiş dönem değerlerinin modele bağımsız değişken (girdi) olarak dâhil edilmesi, algoritmaların tarihsel örüntüleri öğrenme kapasitesini artıran temel bir yaklaşımdır (Doğan ve Büyükkör, 2022). Bu doğrultuda, çalışmadaki her bir hedef değişken için kaza oluşum biçimlerini temsil eden "KOD_NO" bazında gecikme (lag) öznitelikleri üretilmiştir.

Veri ön işleme aşamasında eksik gözlemlere (missing data) yönelik iki farklı strateji uygulanmıştır. İlk olarak, geçmiş verilerin kaydırılmasıyla yeni sütunlar oluşturulurken zaman serisinin başlangıç periyotlarında doğal olarak boş (null) satırlar meydana gelmektedir. Lag üretiminden kaynaklanan bu yapısal eksiklikleri içeren gözlemler eğitim veri setinden çıkarılmıştır. Diğer yandan, veri matrisi içinde kalan diğer eksik değerler ise uç değerlerin (outliers) etkisini en aza indirmek amacıyla ilgili sütunun medyan (ortanca) değeri ile doldurulmuştur.

Algoritmaların yapısal özelliklerine ve aşırı öğrenme (overfitting) risklerine bağlı olarak farklı lag hafızaları tanımlanmıştır. Bu kapsamda, Random Forest modelinin eğitiminde yalnızca 1 yıllık gecikmeyi temsil eden Lag-1 parametresi kullanılmış ve bu yapı Denklem(1)'de gösterilmiştir.

$$X_t^{(lag1)} = Y_{t-1} \quad (1)$$

XGBoost ve LightGBM modellerinde ise zaman serisindeki daha derin örüntüleri yakalayabilmek amacıyla Lag-1, Lag-2 ve Lag-3 düzeylerindeki gecikme değişkenleri kullanılmıştır.

Veri setinin eğitim ve test alt kümelerine ayrılmasında KOD_NO bazlı gözlem sayıları referans alınmıştır. Örneklem hacminin ayrık bir test kümesi oluşturmaya yeterli düzeyde olduğu durumlarda veri seti %85 eğitim ve %15 test olacak şekilde ikiye bölünmüştür. Gözlem sayısının kısıtlı kaldığı spesifik kodlarda ise veri kaybını önlemek adına mevcut verinin tamamı eğitim seti olarak kullanılmıştır.

Çoklu hedef değişkenli regresyon modellerinin eğitilebilmesi amacıyla bağımsız (X) ve hedef (Y) değişken matrisleri ayrı ayrı yapılandırılmıştır. Bağımsız değişken matrisi, algoritmaların kullandığı lag derinliğine bağlı olarak değişiklik göstermiş; hedef değişken matrisi ise tahmin edilmesi amaçlanan iş göremezlik ve mortalite değişkenlerinden oluşturulmuştur. Bu yapının genel matris gösterimi Denklem (2) ve (3)'te verilmiştir. Burada p , modelde kullanılan gecikme düzeyini temsil etmekte olup bağımsız değişken matrisi buna bağlı olarak bir, iki veya üç dönemlik gecikmeli değerler üzerinden tanımlanabilmektedir.

$$X = [E1_{lagp}, \dots, K5_{lagp}, olen_erkek_{lagp}, olen_kadin_{lagp}], \quad p \in \{1,2,3\} \quad (2)$$

$$Y = [E1, E2, \dots, K5, olen_erkek, olen_kadin] \quad (3)$$

2.5.5. Dengesiz Veri ve Gürültünün Ele Alınması

İş kazası veri setleri yapıları gereği dengesiz (imbalanced) bir sınıf dağılımı sergilemektedir; geçici iş göremezlikle sonuçlanan yaralanmalı vaka sayılarının, ölümle sonuçlanan vakalara kıyasla oransal olarak çok daha yüksek olması veri yapısının doğal bir sonucudur. Makine öğrenmesi literatüründe bu tür azınlık sınıflarını dengelemek amacıyla sıklıkla sentetik veri üretme tekniklerine (örneğin SMOTE) başvurulsa da, zaman serisi yapılarında yapay veri üretilmesi veri setinin doğal frekans dağılımını ve tarihsel örüntüsünü bozma riski taşımaktadır (Köse ve Ersöz, 2020). Bu metodolojik kısıt dikkate alınarak çalışmada sentetik veri üretimine başvurulmamış; dengesizlik ve gürültü (noise) problemleri doğrudan kullanılan algoritmaların yapısal özellikleri üzerinden yönetilmiştir.

Bu strateji doğrultusunda, çalışmanın analitik altyapısı karar ağacı tabanlı topluluk (ensemble) öğrenme algoritmaları olan Random Forest, XGBoost ve LightGBM üzerine inşa edilmiştir. Karar ağacı tabanlı topluluk öğrenme algoritmaları, veri içindeki karmaşık örüntüleri birden fazla ağaç yapısı üzerinden modelleyebildikleri için gürültüye ve aykırı değerlere karşı daha dayanıklı bir öğrenme çerçevesi sunmaktadır. Ayrıca, algoritmaların eğitim sürecinde azınlık sınıfını oluşturan mortalite vakalarını göz ardı ederek ağırlıklı sınıfa aşırı uyum (overfitting) sağlamasını engellemek amacıyla modellerin kendi mimarilerinde yer alan sınıf ağırlıklandırma parametreleri optimize edilmiştir. Bu yapısal yaklaşım sayesinde iş kazası istatistiklerinin orijinal veri bütünlüğü korunmuş ve azınlık sınıfını daha duyarlı biçimde ele alan bir modelleme kurgusu oluşturulmuştur.

2.6. Tahminleme Mimarisi ve Hibrit Yaklaşım

Zaman serisi analizlerinde tek bir zaman adımının ötesine geçerek uzun vadeli projeksiyonlar (multi-step forecasting) üretebilmek, kullanılan makine öğrenmesi algoritmalarının tahmin mimarisine dayanmaktadır. Literatürde çoklu adım tahminlemeleri için temel olarak iki farklı strateji öne çıkmaktadır: ardışık (recursive) tahminleme ve

doğrudan (direct) tahminleme (Doğan ve Büyükkör, 2022). Bu çalışmada, iş kazalarına yönelik 2025-2033 dönemi projeksiyonlarının istatistiksel sapmalardan arındırılarak modellenmesi amacıyla, her iki stratejiyi algoritmalar bazında bir araya getiren hibrit bir tahminleme mimarisi kurgulanmıştır.

Ardışık (recursive) tahminleme yaklaşımında modeller, bir sonraki zaman adımını tahmin etmek için kendi ürettikleri geçmiş tahminleri yeni bir bağımsız değişken (girdi) olarak sisteme geri beslemektedir. Bu yöntem, zaman serisinin ardışık bağımlılıklarını koruma konusunda analitik bir bütünlük sağlasa da, uzun vadeli projeksiyonlarda erken aşamadaki tahmin hatalarının ileriye taşınarak birikmesi (error accumulation) riskini taşımaktadır. Doğrudan (direct) tahminleme yaklaşımı ise gelecekteki her bir zaman ufku için birbirinden bağımsız tahmin modellerinin oluşturulması esasına dayanmaktadır. Bu strateji hata birikimini engellemede işlevsel bir yapı sunarken, zaman adımları arasındaki ilişkisel örüntülerin zayıflamasına neden olabilmektedir.

Belirtilen metodolojik kısıtlar göz önünde bulundurularak, çalışmanın tahmin aşamasında algoritmaların yapısal özelliklerine dayalı hibrit bir yaklaşım benimsenmiştir. Bu mimari kapsamında, Random Forest algoritması ardışık (recursive) multi-step stratejisi ile yapılandırılmıştır. Bu tercih ile zaman serisindeki ardışık bağımlılıkların modele aktarılması amaçlanmıştır. Buna karşılık, XGBoost ve LightGBM algoritmaları ise hata yayılımını (error propagation) sınırlandırmak amacıyla doğrudan (direct) multi-step stratejisiyle kurgulanmıştır. Algoritma bazında özelleştirilen bu hibrit mimari sayesinde; uzun vadeli (2025-2033) iş göremezlik ve mortalite projeksiyonlarında ardışık hata birikimi riski kontrol altına alınmış ve serinin trend eğilimleri yapısal bir bütünlük içinde modellenmiştir.

2.7. Makine Öğrenmesi Algoritmalarının Araştırma Kapsamında Yapılandırılması

Makine öğrenmesi modellerinin ham algoritmik yapılarının, çalışılan veri setinin spesifik problem uzayına uyarlanabilmesi ve test verisi üzerinde yüksek genelleme kapasitesine ulaşabilmesi için hiperparametre optimizasyonu ve yapısal konfigürasyon süreçlerinden geçirilmesi gerekmektedir (Karabulut vd., 2024). Bu metodolojik gereklilik doğrultusunda; çalışmanın tahmin mimarisinde tercih edilen Random Forest, XGBoost ve LightGBM algoritmaları standart varsayılan (default) ayarlarıyla kullanılmamış, iş kazası

frekanslarının tarihsel örüntülerini daha dengeli ve tutarlı biçimde modelleyebilecekleri veriye özgü parametre setleriyle kurgulanmıştır.

Algoritmaların araştırma kapsamında yapılandırılmasında üç temel analitik strateji izlenmiştir: Birincisi, algoritmaların eğitim verisini ezberleyerek aşırı öğrenmeye (overfitting) düşmesini engellemek amacıyla ağaç derinlikleri ve dallanma kriterleri sınırlandırılmıştır. İkincisi, veri matrisinde azınlık sınıfını oluşturan mortalite (ölüm) vakalarının model tarafından göz ardı edilmesini önlemek için algoritmaların kendi iç mimarilerinde yer alan ve azınlık sınıfına duyarlılık sağlayan sınıf ağırlıklandırma parametreleri kullanılmıştır. Üçüncüsü ise, çalışmanın hibrit tahmin mimarisinde kurgulanan ardışık (recursive) ve doğrudan (direct) yaklaşımlara uygun olarak her bir algoritmanın geçmiş zaman hafızası (Lag) modele özgü biçimde belirlenmiştir. Algoritmaların kendi matematiksel tabanlarına özgü olarak gerçekleştirilen bu konfigürasyon adımları ve parametre kurguları, takip eden alt başlıklarda detaylandırılmıştır.

2.7.1. Random Forest Model Kurgusu ve Parametreleri

Random Forest (RF) algoritması, eğitim veri setinden yerine koyma (bootstrap) yöntemiyle rastgele alt kümeler çekerek çok sayıda karar ağacı oluşturan ve bu ağaçların ürettiği tahminlerin ortalamasını alarak model varyansını düşüren bir torbalama (bagging) yöntemidir (Karakaya Özkan ve Ulaş, 2023). Çalışma kapsamında RF modeli, zaman serisindeki ardışık bağımlılıkları modelleyebilmek amacıyla yapısal olarak 1 yıllık gecikmeyi temsil eden "Lag-1" özniteliği ile sınırlandırılmış ve ardışık (recursive) tahminleme mimarisine entegre edilmiştir. Bu kurgu, algoritmanın iş kazası frekanslarına ait kısa vadeli trendleri geçmiş yılın verisi üzerinden öğrenmesine ve zaman serisinin ardışık yapısını koruyarak projeksiyon üretmesine olanak tanımaktadır.

Veri matrisinde yer alan geçici iş göremezlik ve mortalite gibi çoklu hedef değişkenlerin aynı modelleme çerçevesinde tahmin edilebilmesi için model, MultiOutputRegressor sarmalayıcısı (wrapper) çerçevesinde eğitilmiştir. Algoritmanın veri setindeki karmaşık ilişkileri öğrenme kapasitesini optimize etmek, gürültüyü yönetmek ve aşırı öğrenmeyi (overfitting) kontrol altına almak amacıyla aşağıdaki hiperparametre konfigürasyonları gerçekleştirilmiştir:

- $n_estimators = 150$: Topluluk içindeki toplam bağımsız ağaç sayısını ifade eden bu parametre, model kararlılığı ile hesaplama maliyeti arasında optimum denge kuracak şekilde 150 olarak belirlenmiştir.

- $\text{max_depth} = 15$: Karar ağaçlarının maksimum büyüme sınırı 15 seviyesi ile kısıtlandırılarak, algoritmanın eğitim verisindeki aykırı değerleri (outliers) ezberlemesi sınırlandırılmış ve modelin genelleme kapasitesinin desteklenmesi amaçlanmıştır.
- $\text{min_samples_split} = 5$ ve $\text{min_samples_leaf} = 3$: Bir düğümün (node) bölünmesi için gereken minimum örnek sayısı 5, nihai bir yaprak düğümünde (leaf) bulunması gereken minimum örnek sayısı ise 3 olarak ayarlanmıştır. Bu yapısal frenleme mekanizması, ağaçların çok küçük ve gürültülü veri parçacıklarına aşırı duyarlı hale gelmesinin önüne geçmiştir.
- $\text{n_jobs} = -1$: Çoklu hedef değişkenli ve 150 karar ağacından oluşan modelin hesaplama maliyetini azaltmak amacıyla, eğitim sürecinin bilgisayarın tüm işlemci çekirdeklerinde paralel olarak yürütülmesi sağlanmıştır.
- Dengesiz Veri Yapısına Duyarlılık: Veri setindeki ölüm vakalarının istatistiksel olarak düşük frekans yapısının model tarafından ihmal edilmemesi amacıyla, regresyon kurgusunda dengesiz veri yapısına duyarlı parametre tercihleri gözetilmiş ve modelin ölümlü kazalara yönelik analitik duyarlılığının korunması hedeflenmiştir.

2.7.2. XGBoost Model Kurgusu ve Parametreleri

XGBoost (eXtreme Gradient Boosting), zayıf tahmin ediciler olarak işlev gören karar ağaçlarının ardışık (sequential) biçimde bir araya getirilmesine dayanan bir gradyan artırma (gradient boosting) algoritmasıdır. Temelini topluluk öğrenme (ensemble) mantığından alan bu yaklaşımda, modele eklenen her yeni karar ağacı, bir önceki aşamada ortaya çıkan tahmin hatalarını (residual errors) minimize etmeye odaklanmaktadır. Algoritmanın sahip olduğu bu ardışık hata azaltma mekanizması, veri seti içindeki karmaşık ve doğrusal olmayan örüntüleri modelleme konusunda oldukça güçlü bir çerçeve sunmaktadır.

Çalışma kapsamında XGBoost algoritması, veri matrisinde yer alan çoklu hedef değişkenlerin (geçici iş göremezlik süreleri ve mortalite verileri) aynı çerçevede tahmin edilebilmesi için Multioutput Regressor sarmalayıcısı (wrapper) ile yapılandırılmıştır. Modelin geçmiş zaman hafızasını oluşturmak ve tarihsel örüntüleri algoritmaya tanıtabilmek amacıyla "Lag-1", "Lag-2" ve "Lag-3" düzeylerindeki gecikme değişkenleri modele girdi (feature) olarak sunulmuştur. Tezin hibrit tahmin mimarisine uygun olarak, XGBoost modelinde hata birikimini önlemek adına doğrudan (direct) multi-step tahminleme stratejisi kurgulanmıştır. Bu yapı kapsamında algoritma, gelecekteki zaman ufuklarını ardışık geri

besleme (recursive) döngüsüyle değil; yalnızca geçmiş yılların verisine ve gecikme değişkenlerine dayanan bağımsız bir tahminleme mantığıyla ele almaktadır.

Modelin eğitim sürecinde algoritmik kararlılığı sağlamak ve veri setinin barındırdığı yapısal dinamikleri yönetmek amacıyla modele özgü parametre tercihleri gözetilmiştir. Algoritmanın gradyan artırma doğası gereği eğilimli olabileceği aşırı öğrenme (overfitting) riskini sınırlandırmak ve veri içindeki gürültüleri filtrelemek üzere veri yapısına uygun konfigürasyonlar uygulanmıştır. Buna ek olarak, iş kazası istatistiklerindeki ölüm vakalarının düşük frekanslı (azınlık sınıfı) yapısının model tarafından ihmal edilmesini önlemek adına, algoritmanın bu vakalara karşı duyarlılığını artıracak yapısal ayarlar tercih edilmiştir. Bu yapılandırma adımları sayesinde XGBoost algoritması, çalışmanın çoklu hedefli tahmin kurgusuna ve veri mimarisine güvenli bir biçimde entegre edilmiştir.

2.7.3. LightGBM Model Kurgusu ve Parametreleri

LightGBM (Light Gradient Boosting Machine), karar ağacı tabanlı bir gradyan artırma (gradient boosting) algoritması olup, özellikle büyük ve karmaşık veri yapılarında bulunduğu öğrenme verimliliği ile öne çıkan bir makine öğrenmesi yaklaşımıdır. Diğer boosting algoritmalarına benzer şekilde, modele eklenen her yeni karar ağacının bir önceki aşamanın tahmin hatalarını (residual errors) ardışık biçimde azaltması prensibine dayanmaktadır. Algoritmanın veri içindeki karmaşık ve doğrusal olmayan örüntüleri yakalama kapasitesi ile hesaplama süreçlerindeki yapısal verimliliği, bu modelin zaman serisi analizlerinde güçlü bir tahminleyici olarak konumlandırılmasını sağlamaktadır.

Çalışma kapsamında LightGBM algoritması, veri matrisinde yer alan geçici iş göremezlik ve mortalite gibi çoklu hedef değişkenlerin aynı çerçevede modellenenebilmesi amacıyla Multioutput Regressor sarmalayıcısı (wrapper) ile yapılandırılmıştır. Modelin tarihsel örüntüleri öğrenebilmesi ve geçmiş zaman hafızasının oluşturulması için "Lag-1", "Lag-2" ve "Lag-3" düzeylerindeki gecikme değişkenleri algoritmaya girdi (feature) olarak sunulmuştur. Tezin hibrit tahmin mimarisine uygun olarak, LightGBM modelinde de doğrudan (direct) multi-step tahminleme yaklaşımı kurgulanmıştır. Bu strateji doğrultusunda algoritma, gelecekteki zaman ufuklarını ardışık geri besleme (recursive) döngüsüyle değil; doğrudan doğruya geçmiş yılların verisine ve gecikme değişkenlerine dayanan bağımsız bir tahminleme mantığıyla ele almaktadır.

Modelin eğitim sürecinde, veri setinin barındırdığı yapısal dinamikleri yönetmek ve algoritmik kararlılığı desteklemek amacıyla modele özgü parametre tercihleri gözetilmiştir.

Algoritmanın doğası gereği eğilimli olabileceği aşırı öğrenme (overfitting) riskini sınırlandırmak ve veri içindeki gürültüleri (noise) filtrelemek üzere veri yapısına uygun konfigürasyonlar uygulanmıştır. Buna ek olarak, iş kazası istatistiklerindeki ölüm vakalarının düşük frekanslı yapısının (azınlık sınıfı) modelin öğrenme sürecinde ihmal edilmesini önlemek adına, algoritmanın düşük frekanslı vakalara duyarlılığını artıracak yapısal tercihler benimsenmiştir. Uygulanan bu parametrik stratejiler, LightGBM algoritmasının çalışmanın analitik gereksinimlerine ve çoklu hedef kurgusuna metodolojik olarak tutarlı bir biçimde entegre edilmesini sağlamıştır.

2.8. Model Performans Değerlendirme Metrikleri

Makine öğrenmesi alanında sürekli sayısal değerlerin tahmin edilmesini gerektiren problemler yapısal olarak regresyon problemi kapsamında değerlendirilmektedir. Bu çalışma kapsamında, 2025–2033 dönemine yönelik iş kazası sayıları ve frekanslarının çoklu hedefli bir mimariyle projeksiyonu amaçlandığından, analiz süreci regresyon problemi olarak ele alınmıştır. Bu metodolojik çerçeve doğrultusunda, geliştirilen modellerin performansı sınıflandırma metrikleriyle değil, regresyon hata metrikleriyle değerlendirilmiştir. Çalışmada uygulanan Random Forest, XGBoost ve LightGBM algoritmalarının tahmin doğruluklarının karşılaştırmalı olarak analiz edilebilmesi amacıyla, regresyon problemlerinde yaygın biçimde kullanılan Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE) metrikleri tercih edilmiştir.

Ortalama Mutlak Hata (MAE), model tarafından tahmin edilen değerler ile gözlemlenen gerçek değerler arasındaki mutlak farkların aritmetik ortalamasını ifade etmektedir. Bu metrik, hata yönünü dikkate almadan tüm sapmalara eşit ağırlık vermekte ve modelin genel sapma düzeyini doğrusal bir ölçekte sunmaktadır. Başka bir ifadeyle MAE, tahminlerin gerçek verilerden ortalama olarak ne kadar uzaklaştığını açık ve yorumlanabilir bir biçimde göstermektedir. MAE metriğinin matematiksel gösteriminde; n toplam gözlem sayısını, y_i gerçek değeri ve $\hat{y}_i$ model tarafından üretilen tahmin değerini ifade etmektedir. Bu doğrultuda, MAE'nin standart formülü Denklem (4)'te sunulmuştur.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

Kök Ortalama Kare Hata (RMSE) ise, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin aritmetik ortalamasının karekökü alınarak hesaplanan bir

hata ölçütüdür. RMSE'yi MAE'den ayıran temel özellik, farkların karesinin alınması nedeniyle büyük hatalara karşı daha duyarlı olmasıdır. Bu nedenle RMSE, özellikle büyük tahmin sapmalarının model performansı üzerindeki etkisini daha belirgin biçimde ortaya koymaktadır. İş kazası istatistikleri gibi tek bir büyük tahmin hatasının analitik sonuçları etkileyebileceği veri yapılarında, RMSE önemli bir değerlendirme ölçütü sunmaktadır. RMSE formülünde; n toplam gözlem sayısını, y_i gerçek değeri ve $\hat{y}_i$ tahmin edilen değeri göstermektedir. Buna göre RMSE'nin standart formülü Denklem (5)'te verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Regresyon tabanlı makine öğrenmesi modellerinde hesaplanan MAE ve RMSE değerlerinin küçülmesi, model tahminleri ile gerçek değerler arasındaki farkın azaldığını ve tahmin performansının iyileştiğini göstermektedir. Bu doğrultuda söz konusu iki metrik, çalışmada geliştirilen modellerin doğruluk ve hata düzeylerini istatistiksel olarak karşılaştırmak ve tahmin mimarisinin başarısını nesnel bir çerçevede değerlendirmek amacıyla temel performans ölçütleri olarak kullanılmıştır.

3. BULGULAR

3.1. Makine Öğrenmesi Modellerinin Performans Karşılaştırması

Bu bölümde, 2016-2024 yıllarını kapsayan Sosyal Güvenlik Kurumu (SGK) verileri temel alınarak 2025-2033 dönemi için gerçekleştirilen projeksiyon üretiminde kullanılan modellerin performans sonuçları sunulmaktadır. Araştırma kapsamında oluşturulan tahmin mimarisinde Random Forest, XGBoost ve LightGBM makine öğrenmesi algoritmaları kullanılmıştır. Performans karşılaştırmaları, çoklu hedefli regresyon çerçevesinde test verisi üzerinde hesaplanan Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Hata (MAE) metrikleri üzerinden gerçekleştirilmiştir. Elde edilen bulgular aşağıdaki alt başlıklarda karşılaştırmalı olarak sunulmuştur.

3.1.1. LightGBM, XGBoost ve Random Forest Modellerinin Hata Metrikleri Açısından Karşılaştırılması

Makine öğrenmesi algoritmalarının test verisi üzerindeki performansları MAE ve RMSE metrikleri doğrultusunda incelenmiştir. Daha düşük MAE ve RMSE değerleri, model tahminlerinin gerçek gözlemlere daha yakın olduğunu göstermektedir.


Tablo 3.1. Modellerin Hata Metrikleri Açısından Karşılaştırılması

Algoritma	Ortalama Mutlak Hata (MAE)	Kök Ortalama Kare Hata (RMSE)
Random Forest	387.813	933.778
XGBoost	616.049	1311.791
LightGBM	818.597	1640.725

Tablo 3.1'de görüldüğü üzere, LightGBM modeli RMSE metriğinde 1640.72 ve MAE metriğinde 818.59 değerlerini üreterek değerlendirilen algoritmalar arasında en yüksek hata değerlerini üretmiştir. XGBoost algoritması ise RMSE metriğinde 1311.79 ve MAE metriğinde 616.05 değerlerini vermiştir.

Buna karşılık, Random Forest modeli test edilen algoritmalar arasında en düşük hata değerlerine ulaşmıştır. Modelin test verisi üzerindeki RMSE değeri 933.78, MAE değeri ise

387.813 olarak hesaplanmıştır. Elde edilen bulgular, Random Forest modelinin MAE metriğinde en yakın rakibi olan XGBoost'a kıyasla %37, LightGBM'e kıyasla ise %52 oranında daha düşük hata ile çalıştığını göstermektedir. Büyük hataların ağırlıklandırıldığı RMSE metriğinde de Random Forest, diğer iki modele göre daha düşük hata değerleri üreterek genel performans bakımından daha başarılı sonuç vermiştir.



Şekil 3.1. Modellerin Hata Metrikleri Açısından Karşılaştırılması

3.1.2. Random Forest Modelinin Karşılaştırmalı Üstünlüğü

Topluluk öğrenmesi (ensemble learning) yöntemleri arasında yer alan Random Forest algoritmasının, birden fazla bağımsız karar ağacının tahmin ortalamasını alarak model varyansını düşürdüğü bilinmektedir (Karakaya Özkan ve Ulaş, 2023). Algoritmanın bu içsel mekanizmasının, uç değerlerden etkilenme düzeyini azaltabildiği ve modellerdeki aşırı öğrenme (overfitting) riskini sınırlayabildiği literatürde ifade edilmektedir (Karabulut, Baran, ve Eraslan, 2024).

Literatürdeki bu kuramsal bilgilerle uyumlu olarak, çalışma kapsamında elde edilen sayısal bulgular değerlendirildiğinde, Random Forest algoritmasının mevcut veri setini modelleme sürecinde en düşük hata değerlerini sağladığı tespit edilmiştir. XGBoost ve LightGBM algoritmaları kabul edilebilir performans sonuçları üretmiş olsa da, test verisi sonuçları bağlamında Random Forest modelinin daha düşük hata oranları ve daha dengeli bir performans sergilediği görülmüştür. Bu sonuç, yöntem bölümünde Lag-1 temelli ardışık

(recursive) tahminleme mimarisiyle yapılandırılan Random Forest modelinin veri yapısına daha uyumlu bir performans sergilediğini düşündürmektedir.

Bu tercih, kuramsal varsayımlardan ziyade doğrudan test verisi üzerinde elde edilen hata metriklerine dayalı olarak yapılmıştır. İlgili bulgular doğrultusunda, 2025-2033 dönemini kapsayan yıllık toplam iş kazası vakası, iş göremezlik süresi ve mortalite projeksiyonlarında Random Forest algoritması ana senaryo (temel tahmin) modeli olarak belirlenmiştir. İzleyen alt bölümlerdeki tüm projeksiyon analizleri ve değerlendirmeler, bu modelin ürettiği çıktılar üzerinden yapılandırılmıştır.

3.2. Yıllık Toplam Kaza Projeksiyonları

Bu bölümde, 2016-2024 yıllarını kapsayan veri seti temel alınarak 2025-2033 dönemi için gerçekleştirilen yıllık toplam iş kazası vaka projeksiyonları sunulmaktadır. Burada ifade edilen "toplam vaka" kavramı, analiz kapsamındaki tüm yaralanma kodlarına (KOD_NO) ait yıllık tahminlerin genel toplamını temsil etmektedir. İlgili projeksiyon sonuçları; LightGBM, XGBoost ve Random Forest algoritmaları ekseninde karşılaştırmalı olarak incelenmiş ve ardından ana senaryo modeli olarak belirlenen Random Forest algoritmasına ait vaka artış eğilimi ayrıntılı olarak ele alınmıştır.

3.2.1. Modeller Arası Genel Vaka Tahmin Karşılaştırmaları


Makine öğrenmesi algoritmalarının 2025-2033 dönemi için ürettiği yıllık toplam iş kazası tahminleri değerlendirildiğinde, modellerin geçmiş dönem örüntülerini geleceğe yansıtma biçimlerinde belirgin farklılıklar gözlemlenmiştir. İlgili projeksiyon sonuçları Tablo 3.2'de sunulmuştur.

Tablo 3.2. Modeller Arası Genel Vaka Tahmin Karşılaştırmaları

Yıl	LightGBM	Random Forest	XGBoost
2025	444761	400604	316591
2026	777460	431014	356532
2027	893404	466431	372982
2028	982217	494610	380097
2029	940102	519559	350725
2030	967160	547845	368539

2031	1084623	567624	377982
2032	1170491	598582	382231
2033	1206528	639786	352385

Tablo 3.2 incelendiğinde, LightGBM algoritmasının projeksiyon dönemine 2025 yılı için 444.761 vaka tahmini ile başladığı görülmektedir. Bu modelin, 2033 yılında 1.206.528 vakaya ulaşarak değerlendirilen algoritmalar arasında en yüksek projeksiyon artışını gösterdiği belirlenmiştir. Bu durum, ilgili modelin zaman serisi içindeki artış trendini diğer modellere kıyasla daha yüksek bir artış eğilimiyle yansıttığını göstermektedir. Buna karşılık, XGBoost algoritmasının tahminleri daha yatay bir seyir izlemiştir; 2025 yılı için öngörülen 316.591 vaka sayısının, dönemsel dalgalanmalarla birlikte 2033 yılında 352.385 seviyesinde gerçekleşeceği öngörülmüştür. Önceki bölümde test verisi üzerindeki en düşük hata değerlerini ürettiği tespit edilen Random Forest modeli ise diğer modellere kıyasla daha ılımlı ve düzenli bir projeksiyon deseni sunmuştur. Random Forest algoritması, 2025 yılında 400.604 vaka ile başlattığı tahmin serisini artırarak 2033 yılında 639.786 seviyesine taşımıştır.



Şekil 3.2. Modeller Arası Genel Vaka Tahmin Karşılaştırmaları

3.2.2. Random Forest Modeline Göre Yıllık Artış Eğilim

Performans metrikleri doğrultusunda ana senaryo modeli olarak konumlandırılan Random Forest algoritmasının toplam vaka tahminleri incelendiğinde, 2025-2033 yılları

arasında düzenli bir yükseliş eğilimi izlenmiştir. Algoritmanın ürettiği sayısal sonuçlara göre, 2025 yılında 400.604 olması beklenen toplam iş kazası vaka sayısının, projeksiyon döneminin ortası kabul edilebilecek 2029 yılında 519.559 seviyesine, projeksiyon döneminin sonu olan 2033 yılında ise 639.786 seviyesine ulaşacağı öngörülmüştür. Bu bulgular, 2025 yılı başlangıç değeri ile kıyaslandığında 2033 yılına kadar toplam vaka sayılarında mutlak olarak 239.182 adetlik, oransal olarak ise yaklaşık %59,7 düzeyinde bir artış gerçekleşeceğine işaret etmektedir. Yöntem bölümünde kurgulanan Lag-1 temelli yapılandırmanın, geçmiş dönem örüntülerinin ileri yıllara taşınmasında etkili olduğu ve modelin bu bağımlılıkları istikrarlı bir artış eğilimi içinde yansıttığı düşünülmektedir. Elde edilen bu artış eğilimi, iş sağlığı ve güvenliği politikaları açısından dikkate alınması gereken bir görünüme işaret etmektedir.

3.3. İş Göremezlik Sürelerine Göre Yaralanma Tahminleri

Bu bölümde, 2025–2033 dönemi için öngörülen toplam iş kazası vakalarının, kaza sonucu oluşan geçici iş göremezlik sürelerine göre dağılımları incelenmektedir. Literatürde geçici iş göremezlik süresi; çalışanın uğradığı iş kazası sonucunda istirahat raporu alarak işten uzak kaldığı gün sayısını ifade eden ve kazanın şiddetini yansıtan temel bir gösterge olarak kabul edilmektedir (Kandemir ve Şimşek, 2019).

Bu bölüm kapsamında ele alınan 1, 2, 3, 4 ve 5 gün ve üzeri iş göremezlikle sonuçlanan vakalar, yaralanmalı ancak hayatta kalan iş kazalarını temsil etmekte olup ölümlü iş kazalarını kapsamamaktadır. Analizler, LightGBM, XGBoost ve ana senaryo modeli olarak belirlenen Random Forest algoritmalarının ürettiği sayısal projeksiyonlar üzerinden karşılaştırmalı olarak sunulmuştur.

3.3.1. 1 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi


Makine öğrenmesi algoritmalarının 1 günlük iş göremezlikle sonuçlanan yaralanmalar için ürettiği 2025–2033 dönemi projeksiyonları incelendiğinde, modellerin tahmin eğilimleri arasında belirgin farklılıklar gözlenmiştir.

Elde edilen sayısal bulgulara göre, LightGBM algoritması projeksiyon dönemine 2025 yılı için 29.818 vaka tahmini ile başlamış ve bu sayıyı 2033 yılında 87.026 seviyesine ulaştırmıştır. XGBoost algoritması ise 2025 yılı için 26.699 olarak öngördüğü vaka sayısını daha sınırlı bir artışla 2033 yılında 31.214 seviyesine taşımıştır. Test verisi üzerinde en düşük

hata değerlerini üreten Random Forest modeli ise 2025 yılında 27.253 vaka olarak hesapladığı 1 günlük iş göremezlik sayısını, ardışık tahminleme yapısına dayalı olarak düzenli bir artış eğilimiyle 2033 yılında 44.244 seviyesine yükseltmiştir.

Tablo 3.3. 1 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

Yıl	Random Forest	XGBoost	LightGBM
2025	27253	26699	29818
2026	29861	27680	48949
2027	32640	30336	58534
2028	34962	28694	65278
2029	37106	30718	67121
2030	39175	29474	69035
2031	40617	31556	78896
2032	42292	29427	83548
2033	44244	31214	87026



Şekil 3.3. 1 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı


3.3.2. 2 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi

İki günlük istirahat raporu ile sonuçlanan yaralanma vakalarına ilişkin model tahminleri, 1 günlük iş göremezlik vakalarına kıyasla daha yüksek bir hacim ortaya koymaktadır.

İlgili bulgular değerlendirildiğinde, LightGBM modelinin 2025 yılında 46.711 olan 2 günlük vaka tahminini 2033 yılında 133.104 seviyesine yükselttiği görülmüştür. XGBoost modeli, 2025 yılında öngördüğü 39.106 vaka sayısını 2033 yılında 48.729 seviyesine çıkarmıştır. Ana senaryo modeli olan Random Forest ise 2025 yılı için 45.128 olarak hesapladığı 2 günlük iş göremezlik vakası sayısını 2033 yılı sonunda 72.613 seviyesine taşımıştır.

Tablo 3.4. 2 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

Yıl	Random Forest	XGBoost	LightGBM
2025	45128	39106	46711
2026	49251	44522	78907
2027	53557	47416	93229
2028	56999	48640	102295
2029	60131	47396	103245
2030	63417	49263	104342
2031	65712	50335	120900
2032	68737	50196	127832
2033	72613	48729	133104



Şekil 3.4. 2 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

3.3.3. 3 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi


Üç günlük iş göremezlikle sonuçlanan yaralanmalara ilişkin projeksiyonlar incelendiğinde, bu kategorinin kısa süreli iş göremezlikler içinde yüksek hacimli gruplardan biri olduğu görülmektedir.

Sayısal analiz sonuçlarına göre, LightGBM algoritması 3 günlük iş göremezlik vakalarını 2025 yılında 62.413 vaka ile başlatmış ve 2033 yılında 185.111 seviyesine taşımıştır. XGBoost modeli 2025 yılı için 57.113 vaka tahmin etmiş ve bu sayıyı 2033 yılında 60.915 olarak hesaplamıştır. Random Forest algoritması ise 2025 yılında 63.554 olan 3 günlük vaka beklentisini 2033 yılına gelindiğinde 101.321 seviyesine ulaştırmıştır.

Tablo 3.5. 3 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

Yıl	Random Forest	XGBoost	LightGBM
2025	63554	57113	62413
2026	69340	63090	109508
2027	75730	64176	127704
2028	80624	68154	142733

2029	84708	61274	141033
2030	88976	63658	147076
2031	91997	63617	168426
2032	96038	67913	177653
2033	101321	60915	185111



Şekil 3.5. 3 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

3.3.4. 4 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi


Dört gün süreli geçici iş göremezlik ile sonuçlanan kazalar, kısa süreli istirahat raporları içinde görece daha düşük hacimli bir kategoriye oluşturmaktadır.

Modellerin çıktıları incelendiğinde, LightGBM algoritması 2025 yılında 16.146 olan vaka tahminini 2033 yılında 47.679 seviyesine yükseltmiştir. XGBoost algoritması 2025 yılındaki 13.731 vakayı 2033 yılında 14.907 olarak öngörmüştür. Dengeli tahmin performansı ile öne çıkan Random Forest modeli ise 2025 yılı için 16.662 olarak hesapladığı 4 günlük iş göremezlik sayısını 2033 projeksiyonunda 26.401 seviyesine taşımıştır.

Tablo 3.6. 4 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

Yıl	Random Forest	XGBoost	LightGBM
-----	---------------	---------	----------

2025	16662	13731	16146
2026	18084	15902	28979
2027	19728	16246	32585
2028	20974	17863	37271
2029	21978	15200	36507
2030	23070	16245	38436
2031	23833	15705	43664
2032	24934	17395	45933
2033	26401	14907	47679



Şekil 3.6. 4 4 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

3.3.5. 5 Gün İş Göremezlikle Sonuçlanan Yaralanmaların Dağılımı ve Karşılaştırmalı Analizi


Analiz veri setinde 5 gün ve üzeri iş göremezlikle sonuçlanan kazalar, hayatta kalınan ancak ciddi yaralanma niteliği taşıyan ve toplam iş göremezlik hacmi içinde en yüksek payı oluşturan kategoriyi temsil etmektedir.

Elde edilen bulgular değerlendirildiğinde, tüm modellerin en yüksek sayısal tahminlerini bu kategoride ürettiği görülmektedir. LightGBM modeli, 2025 yılında 289.673 olan vaka sayısını 2033 yılında 753.608 seviyesine çıkararak değerlendirilen tüm iş

göremezlik süreleri içinde en yüksek projeksiyon artışını göstermiştir. XGBoost modeli 2025 yılı için 179.942 olan tahminini 2033 yılında 196.620 seviyesine ulaştırmıştır. Ana senaryo modeli olan Random Forest ise 5 gün ve üzeri iş göremezlikle sonuçlanan ciddi yaralanmaların hacmini 2025 yılı için 248.007 olarak hesaplamış ve 2033 yılı için bu sayıyı 395.207 seviyesine taşımıştır.

Tablo 3.7. 5 Gün ve Üzeri İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

Yıl	Random Forest	XGBoost	LightGBM
2025	248007	179942	289673
2026	264478	205338	511117
2027	284776	214808	581352
2028	301051	216746	634640
2029	315636	196137	592196
2030	333207	209899	608271
2031	345465	216769	672737
2032	366581	217300	735525
2033	395207	196620	753608



Şekil 3.7. 5 Gün ve Üzeri İş Göremezlikle Sonuçlanan Yaralanmaların Karşılaştırmalı Dağılımı

3.4. Ölüm Projeksiyonları ve Demografik Kırılımlar

Bu bölümde, Sosyal Güvenlik Kurumu veri setinde yer alan "olen_erkek" ve "olen_kadin" değişkenleri temel alınarak 2025-2033 dönemi için gerçekleştirilen ölümlü iş kazası (mortalite) projeksiyonları ve bu projeksiyonların demografik kırılımları incelenmektedir. Makine öğrenmesi analizlerinde mortalite verilerinin, yaralanmalı iş göremezlik sürelerinden ayrı bir hedef değişken grubu olarak modellenmesi, iş sağlığı ve güvenliği kapsamında öncelikli risk alanlarının değerlendirilmesi açısından önemli bir analitik çerçeve sunmaktadır.

3.4.1. Modeller Bazında Toplam Ölüm Sayısı Tahminleri

Makine öğrenmesi algoritmalarının 2025-2033 dönemi için ürettiği yıllık toplam ölüm sayısı tahminleri incelenmiştir. Ölüm verilerinin toplam veri seti içindeki düşük frekans yapısından kaynaklı olarak modellerin farklı tahmin davranışları sergilediği gözlemlenmiştir. Burada ifade edilen toplam ölüm sayısı, ilgili yılda "olen_erkek" ve "olen_kadin" değişkenlerine ait tahminlerin toplamını temsil etmektedir. İlgili projeksiyon sonuçları Tablo 3.8'de sunulmuştur.

Tablo 3.8. Toplam Mortalite (Ölüm) Projeksiyonları (2025-2033)


Yıl	LightGBM	Random Forest	XGBoost
2025	5938	5065	5656
2026	5392	5796	6649
2027	9028	6118	7258
2028	11345	6684	6289
2029	13205	7351	6871
2030	13129	7751	6904
2031	13788	8017	7150
2032	14456	8260	6325
2033	14962	8390	7011

Tablo 3.8 değerlendirildiğinde, LightGBM algoritmasının 2025 yılında 5.938 olan ölümlü vaka tahminini 2033 yılında 14.962 seviyesine çıkararak değerlendirilen modeller arasında en yüksek projeksiyon artışını gösterdiği tespit edilmiştir. XGBoost algoritması ise

2025 yılı için 5.656 olarak öngördüğü ölüm sayısını 2033 yılında 7.011 seviyesinde hesaplamıştır.

Hata metrikleri bakımından en düşük hata değerlerini veren ve ana senaryo modeli olarak seçilen Random Forest algoritmasının tahminlerine göre; 2025 yılında 5.065 çalışanın iş kazası sonucu yaşamını yitireceği öngörülmüştür. Modelin geçmiş dönem örüntülerini yansıtan hesaplamalarına göre bu sayının, istikrarlı bir artış eğilimiyle 2029 yılında 7.351'e, projeksiyon döneminin sonu olan 2033 yılında ise 8.390'a ulaşması beklenmektedir.

Dokuz yıllık projeksiyon periyodu (2025-2033) bütünüyle değerlendirildiğinde, Random Forest modeline göre toplam 63.432 çalışanın iş kazası nedeniyle yaşamını yitireceği hesaplanmıştır. Bu bulgu, iş sağlığı ve güvenliği politikaları açısından dikkatle değerlendirilmesi gereken önemli bir risk göstergesine işaret etmektedir.



Şekil 3.8. Toplam Mortalite (Ölüm) Projeksiyonları (2025-2033)

3.4.2. Erkek Çalışanlara İlişkin Ölüm Projeksiyonları


Erkek çalışanlara yönelik mortalite projeksiyonları Tablo 3.9'da sunulmuştur.

Tablo 3.9. Erkek Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033)

Yıl	LightGBM	Random Forest	XGBoost
2025	5807	4944	5530
2026	5261	5653	6503

2027	8800	5966	7093
2028	11051	6517	6142
2029	12855	7169	6752
2030	12790	7558	6767
2031	13431	7817	6994
2032	14075	8059	6176
2033	14567	8188	6891

Ana senaryo modeli olan Random Forest çıktılarına göre; 2025 yılında yaşamını yitirmesi öngörülen toplam 5.065 çalışanın 4.944'ünü erkek çalışanlar oluşturmaktadır. Bu sayının yıllar itibarıyla kademeli bir artış eğilimi göstererek 2033 yılında yıllık 8.188 erkek çalışan ölümüne ulaşacağı hesaplanmıştır. 2025-2033 dönemi boyunca gerçekleşmesi beklenen 63.432 toplam ölüm vakasının 61.871'inin erkek çalışanlardan oluşması beklenmektedir. Bu bulgular, mortalite projeksiyonlarının büyük ölçüde erkek çalışanlar üzerinde kadın çalışanlara kıyasla belirgin biçimde daha yüksek seyrettiğini göstermektedir.



Şekil 3.9. Erkek Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033)


3.4.3. Kadın Çalışanlara İlişkin Ölüm Projeksiyonları

Kadın çalışanlara yönelik mortalite projeksiyonları Tablo 3.10'da sunulmuştur.

Tablo 3.10. Kadın Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033)

Yıl	LightGBM	Random Forest	XGBoost
2025	131	121	126
2026	131	143	146
2027	228	152	165
2028	294	167	147
2029	350	182	119
2030	339	193	137
2031	357	200	156
2032	381	201	149
2033	395	202	120

Random Forest algoritmasının tahminlerine göre, kadın çalışanlara yönelik mortalite öngörüsü 2025 yılı için 121 olarak hesaplanmıştır. Bu gruptaki vaka sayılarının, genel artış eğilimine kıyasla çok daha yatay bir seyir izleyerek 2033 yılında 202 seviyesine ulaşması beklenmektedir. Dokuz yıllık projeksiyon döneminin toplamında öngörülen kadın çalışan ölüm sayısının 1.561 olacağı hesaplanmıştır. Bu bulgu, kadın çalışanlara ilişkin mortalite düzeyinin erkek çalışanlara kıyasla belirgin biçimde daha düşük seyrettiğini göstermektedir.



Şekil 3.10. Kadın Çalışanlara İlişkin Mortalite Projeksiyonları (2025-2033)

3.5. Yaralanma Kodlarına Göre Karşılaştırmalı Model Analizi

Bu bölümde, 2016-2024 dönemine ait veri seti esas alınarak 2025-2033 dönemi için üretilen iş kazası projeksiyonları, Sosyal Güvenlik Kurumu (SGK) standartlarına uygun yaralanma kodları (KOD_NO) temelinde incelenmektedir. Geliştirilen çoklu hedefli regresyon mimarisi kapsamında LightGBM, XGBoost ve ana senaryo modeli olarak belirlenen Random Forest algoritmalarının yaralanma kodları bazında ürettikleri vaka ve mortalite tahminleri karşılaştırmalı olarak değerlendirilmiştir. Analiz süreci, belirli yaralanma kodlarında ortaya çıkan projeksiyon farklılıklarının ve modeller arası tahmin örüntülerinin sayısal olarak ortaya konulmasını amaçlamaktadır. Bu kapsamda, karşılaştırmalı model analizlerine geçmeden önce, araştırmada kullanılan SGK veri setindeki yaranın türü kodları ve bu kodlara karşılık gelen tanımlar aşağıdaki tabloda sunulmuştur. İzleyen alt başlıklarda ise her bir yaralanma koduna ilişkin projeksiyon çıktıları ayrıntılı biçimde ele alınmıştır.

Tablo 3.11. SGK Yaralanma Türü Kodları ve Tanımları

Kod No	Yaranın Türü
000	Türü Bilinmeyen/Belirtilmemiş
011	Yüzeysel Yaralanmalar
012	Açık Yaralar
019	Diğer Tür Yaralar
021	Kapalı Kırıklar
022	Açık Kırıklar
029	Diğer Tür Kemik Kırıkları
031	Çıkıklar ve Yarı Çıkıklar
032	Burkulmalar ve İncinmeler
039	Diğer Tür Çıkık/Burkulmalar

040	Travma Sonucu Organ Kaybı (Amputasyon)
051	Beyin Sarsıntısı ve Kafatası Yaralanmaları
052	İç Yaralanmalar
059	Diğer Tür Beyin Sarsıntısı/İç Yaralanmalar
061	Termal Yanıklar
062	Kimyasal Yanıklar (Korozyon)
063	Donmalar
069	Diğer Tür Yanıklar
071	Akut Zehirlenmeler
072	Akut Enfeksiyonlar
079	Diğer Tür Zehirlenmeler
081	Nefesin Kesilmesi (Asfiksi)
082	Suda Boğulma
089	Diğer Tür Boğulmalar
091	Akut İşitme Kaybı
092	Basınç Etkileri (Barotravma)
099	Diğer Ses/Titreşim Etkileri
101	Sıcaklık ve Güneş Çarpması
102	Radyasyon Etkileri (Termal Olmayan)
103	İndirgenmiş Isı Etkileri
109	Diğer Isı/L ışık/Radyasyon Etkileri

111	Saldırı/Tehdit Sonrası Şoklar
112	Travma Şokları
119	Diğer Tür Şoklar
120	Birden Fazla Sayıda Yaralanmalar (Multitravma)
999	Diğer Başlıklar Altında Sınıflandırılmayanlar

3.5.1. Kod 000: Türü Bilinmeyen/Belirtilmemiş

Random Forest modeli 2025 yılı için 25.918 vaka ve 283 ölüm tahmin ederken, aynı yıl için XGBoost modeli 15.355 vaka ve 273 ölüm, LightGBM modeli ise 34.122 vaka ve 397 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca daha dengeli bir seyir izleyerek 2033 yılı itibarıyla 29.230 vaka ve 299 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük vaka tahminleri üretmesine karşın, ölüm tahminlerinde daha dalgalı bir görünüm sergilemekte ve 2033 yılı için 17.468 vaka ile 345 ölüm öngörmektedir. LightGBM modeli ise diğer algoritmalara kıyasla daha yüksek tahminler üretmekte ve 2026 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 000 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha düşük hacimli ve LightGBM modelinin ise daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 260.006 vaka ve 2.650 ölüm, XGBoost modeli için toplam 155.870 vaka ve 2.989 ölüm, LightGBM modeli için ise toplam 395.682 vaka ve 4.757 ölüm öngörülmektedir.

Tablo 3.12. Kod 000: Türü Bilinmeyen/Belirtilmemiş İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	25918	283	15355	273	34122	397
2026	29898	293	17258	274	45195	545

2027	28510	283	18449	372	45195	545
2028	29530	296	17468	345	45195	545
2029	29230	299	17468	345	45195	545
2030	29230	299	17468	345	45195	545
2031	29230	299	17468	345	45195	545
2032	29230	299	17468	345	45195	545
2033	29230	299	17468	345	45195	545

3.5.2. Kod 011: Yüzeysel Yaralanmalar

Random Forest modeli 2025 yılı için 84.407 vaka ve 130 ölüm tahmin ederken, aynı yıl için XGBoost modeli 87.654 vaka ve 144 ölüm, LightGBM modeli ise 61.463 vaka ve 410 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca aynı düzeyi koruyarak 2033 yılı itibarıyla 84.407 vaka ve 130 ölüm seviyesinde kalmaktadır. XGBoost modeli dönemsel dalgalanmalar göstermekle birlikte 2033 yılı için 92.688 vaka ve 185 ölüm öngörmektedir. LightGBM modeli ise diğer algoritmalarla kıyasla daha düşük vaka, buna karşılık daha yüksek ölüm tahminleri üretmekte ve izleyen yıllarda 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 011 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha yüksek düzeyli ve LightGBM modelinin ise vaka sayısı bakımından daha düşük hacimli, ölüm sayısı bakımından ise daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 759.663 vaka ve 1.170 ölüm, XGBoost modeli için toplam 807.325 vaka ve 1.624 ölüm, LightGBM modeli için ise toplam 423.023 vaka ve 4.770 ölüm öngörülmektedir.

Tablo 3.13. Kod 011: Yüzeysel Yaralanmalar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	84407	130	87654	144	61463	410

2026	84407	130	87229	185	45195	545
2027	84407	130	92688	185	45195	545
2028	84407	130	87230	185	45195	545
2029	84407	130	92688	185	45195	545
2030	84407	130	87230	185	45195	545
2031	84407	130	92688	185	45195	545
2032	84407	130	87230	185	45195	545
2033	84407	130	92688	185	45195	545

3.5.3. Kod 012: Açık Yaralar

Random Forest modeli 2025 yılı için 27.943 vaka ve 276 ölüm tahmin ederken, aynı yıl için XGBoost modeli 30.229 vaka ve 335 ölüm, LightGBM modeli ise 45.195 vaka ve 545 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca daha dengeli bir seyir izleyerek 2033 yılı itibarıyla 29.230 vaka ve 299 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli vaka tahminleri üretmekle birlikte ölüm tahminlerinde daha yüksek bir düzeye ulaşmakta ve 2033 yılı için 27.623 vaka ile 357 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca aynı düzeyi koruyarak 2033 yılı itibarıyla 45.195 vaka ve 545 ölüm seviyesinde kalmaktadır. Kod 012 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin vaka sayısı bakımından daha düşük hacimli ancak ölüm sayısı bakımından daha yüksek düzeyli ve LightGBM modelinin ise daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 262.393 vaka ve 2.657 ölüm, XGBoost modeli için toplam 251.094 vaka ve 3.191 ölüm, LightGBM modeli için ise toplam 406.755 vaka ve 4.905 ölüm öngörülmektedir.

Tablo 3.14. Kod 012: Açık Yaralar İçin Karşılaştırmalı Tahminler

Yıl	RF	RF	XGBoost	XGBoost	LightGBM	LightGBM
	Vaka	Ölüm	Vaka	Ölüm	Vaka	Ölüm

2025	27943	276	30229	335	45195	545
2026	29622	292	27504	357	45195	545
2027	29448	295	27623	357	45195	545
2028	29230	299	27623	357	45195	545
2029	29230	299	27623	357	45195	545
2030	29230	299	27623	357	45195	545
2031	29230	299	27623	357	45195	545
2032	29230	299	27623	357	45195	545
2033	29230	299	27623	357	45195	545

3.5.4. Kod 019: Diğer Tür Yaralar

Random Forest modeli 2025 yılı için 6.954 vaka ve 157 ölüm tahmin ederken, aynı yıl için XGBoost modeli 2.375 vaka ve 174 ölüm, LightGBM modeli ise 18.222 vaka ve 71 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 29.476 vaka ve 293 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka tahminlerinde daha düşük hacimli bir seyir izlemekle birlikte, ölüm tahminlerinde 2026 yılından itibaren 208 düzeyine yaklaşmakta ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise özellikle 2026 yılından sonra belirgin biçimde daha yüksek tahminler üretmekte ve 2028 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 019 özelinde Random Forest modelinin artış eğilimini daha dengeli biçimde yansıttığı, XGBoost modelinin daha düşük hacimli tahminler sunduğu ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler ürettiği görülmektedir. Random Forest modeli için toplam 140.128 vaka ve 2.151 ölüm, XGBoost modeli için toplam 32.325 vaka ve 1.838 ölüm, LightGBM modeli için ise toplam 415.775 vaka ve 3.893 ölüm öngörülmektedir.

Tablo 3.15. Kod 019: Diğer Tür Yaralar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	6954	157	2375	174	18222	71
2026	9161	204	3828	208	65906	153
2027	11275	236	3723	208	60477	399
2028	12095	242	3734	208	45195	545
2029	12501	243	3733	208	45195	545
2030	13038	245	3733	208	45195	545
2031	17254	247	3733	208	45195	545
2032	28374	284	3733	208	45195	545
2033	29476	293	3733	208	45195	545

3.5.5. Kod 021: Kapalı Kırıklar

Random Forest modeli 2025 yılı için 26.687 vaka ve 247 ölüm tahmin ederken, aynı yıl için XGBoost modeli 24.187 vaka ve 200 ölüm, LightGBM modeli ise 61.463 vaka ve 410 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca daha dengeli bir seyir izleyerek 2033 yılı itibarıyla 29.230 vaka ve 299 ölüm düzeyine ulaşmaktadır. XGBoost modeli 2026 yılında 30.378 vaka ve 231 ölüm düzeyine yükselmekte, izleyen yıllarda ise 27.623 vaka ve 357 ölüm düzeyinde seyretmektedir. LightGBM modeli ise 2025 yılındaki yüksek başlangıç düzeyinin ardından 2026 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde devam etmektedir. Kod 021 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha yüksek düzeyli ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 259.785 vaka ve 2.620 ölüm, XGBoost modeli için toplam 247.757 vaka ve 2.921 ölüm, LightGBM modeli için ise toplam 423.023 vaka ve 4.770 ölüm öngörülmektedir.

Tablo 3.16. Kod 021: Kapalı Kırıklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	26687	247	24187	200	61463	410
2026	28242	286	30378	231	45195	545
2027	29476	293	27454	348	45195	545
2028	29230	299	27623	357	45195	545
2029	29230	299	27623	357	45195	545
2030	29230	299	27623	357	45195	545
2031	29230	299	27623	357	45195	545
2032	29230	299	27623	357	45195	545
2033	29230	299	27623	357	45195	545

3.5.6. Kod 022: Açık Kırıklar

Random Forest modeli 2025 yılı için 1.019 vaka ve 160 ölüm tahmin ederken, aynı yıl için XGBoost modeli 702 vaka ve 164 ölüm, LightGBM modeli ise 4.420 vaka ve 53 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca kademeli bir artış göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir vaka örüntüsü sergilemekte ve 2033 yılı için 509 vaka ile 60 ölüm öngörmektedir. LightGBM modeli ise özellikle dönem ortasından itibaren belirgin biçimde daha yüksek tahminler üretmekte, 2031 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 022 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha düşük hacimli ve LightGBM modelinin ise dönem sonuna doğru belirgin biçimde daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 11.095 vaka ve 1.828 ölüm, XGBoost modeli için toplam 5.124 vaka ve 778 ölüm, LightGBM modeli için ise toplam 230.679 vaka ve 3.036 ölüm öngörülmektedir.

Tablo 3.17. Kod 022: Açık Kırıklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1019	160	702	164	4420	53
2026	1147	188	718	133	10971	74
2027	1204	197	576	82	16919	133
2028	1285	213	523	79	17414	271
2029	1288	214	527	60	16367	469
2030	1288	214	549	60	29003	401
2031	1288	214	505	79	45195	545
2032	1288	214	515	61	45195	545
2033	1288	214	509	60	45195	545

3.5.7. Kod 029: Diğer Tür Kemik Kırıkları

Random Forest modeli 2025 yılı için 4.743 vaka ve 105 ölüm tahmin ederken, aynı yıl için XGBoost modeli 3.735 vaka ve 157 ölüm, LightGBM modeli ise 10.295 vaka ve 74 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 13.038 vaka ve 245 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka sayısı bakımından daha sınırlı bir seyir izlemekle birlikte ölüm tahminlerinde 2026 yılından itibaren 208 düzeyinde dengelenmekte ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise özellikle vaka tahminlerinde diğer algoritmalara kıyasla daha yüksek değerler üretmekte ve 2028 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 029 özelinde Random Forest modelinin artış eğilimini daha dengeli biçimde yansıttığı, XGBoost modelinin daha düşük hacimli tahminler sunduğu ve LightGBM modelinin ise daha yüksek düzeyli tahminler ürettiği görülmektedir. Random Forest modeli için toplam 79.492 vaka ve 1.684 ölüm, XGBoost modeli için toplam 33.580 vaka ve 1.821 ölüm, LightGBM modeli için ise toplam 348.636 vaka ve 3.542 ölüm öngörülmektedir.

Tablo 3.18. Kod 029: Diğer Tür Kemik Kırıkları İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	4743	105	3735	157	10295	74
2026	5468	131	3713	208	34406	0
2027	5909	142	3734	208	32765	198
2028	6710	154	3733	208	45195	545
2029	8380	189	3733	208	45195	545
2030	11175	234	3733	208	45195	545
2031	11660	240	3733	208	45195	545
2032	12409	244	3733	208	45195	545
2033	13038	245	3733	208	45195	545

3.5.8. Kod 031: Çıkıklar ve Yarı Çıkıklar

Random Forest modeli 2025 yılı için 5.323 vaka ve 120 ölüm tahmin ederken, aynı yıl için XGBoost modeli 2.761 vaka ve 150 ölüm, LightGBM modeli ise 19.508 vaka ve 86 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 13.038 vaka ve 245 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka tahminlerinde daha düşük hacimli bir seyir izlemekle birlikte, ölüm tahminlerinde 2026 yılından itibaren 208 düzeyine yaklaşmakta ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise özellikle 2026 yılından sonra belirgin biçimde daha yüksek tahminler üretmekte ve 2028 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 031 özelinde Random Forest modelinin artış eğilimini daha dengeli biçimde yansıttığı, XGBoost modelinin daha düşük hacimli tahminler sunduğu ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler ürettiği görülmektedir. Random Forest modeli için toplam 85.444 vaka ve 1.785 ölüm, XGBoost

modeli için toplam 32.643 vaka ve 1.815 ölüm, LightGBM modeli için ise toplam 417.061 vaka ve 3.908 ölüm öngörülmektedir.

Tablo 3.19. Kod 031: Çıkıklar ve Yarı Çıkıklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	5323	120	2761	150	19508	86
2026	5750	139	3760	209	65906	153
2027	6494	151	3723	208	60477	399
2028	7959	179	3734	208	45195	545
2029	10840	229	3733	208	45195	545
2030	11444	237	3733	208	45195	545
2031	12095	242	3733	208	45195	545
2032	12501	243	3733	208	45195	545
2033	13038	245	3733	208	45195	545

3.5.9. Kod 032: Burkulmalar ve İncinmeler

Random Forest modeli 2025 yılı için 69.431 vaka ve 214 ölüm tahmin ederken, aynı yıl için XGBoost modeli 44.022 vaka ve 420 ölüm, LightGBM modeli ise 45.195 vaka ve 545 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış göstererek 2028 yılından itibaren 84.407 vaka düzeyine ulaşmakta, ölüm tahminleri ise aynı yıl itibarıyla 130 düzeyine gerileyerek dönem sonuna kadar bu seviyede seyretmektedir. XGBoost modeli dönem boyunca dalgalı bir görünüm sergilemekte ve 2033 yılı için 44.053 vaka ile 587 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca aynı düzeyi koruyarak 2033 yılı itibarıyla 45.195 vaka ve 545 ölüm düzeyinde kalmaktadır. Kod 032 özelinde Random Forest modelinin daha dengeli bir tahmin örüntüsü sunduğu, XGBoost modelinin özellikle ölüm tahminleri bakımından daha yüksek ve dalgalı bir yapı sergilediği,

LightGBM modelinin ise yüksek düzeyde sabit kalan tahminler ürettiği görülmektedir. Random Forest modeli için toplam 729.698 vaka ve 1.331 ölüm, XGBoost modeli için toplam 477.265 vaka ve 4.490 ölüm, LightGBM modeli için ise toplam 406.755 vaka ve 4.905 ölüm öngörülmektedir.

Tablo 3.20. Kod 032: Burkulmalar ve İncinmeler İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	69431	214	44022	420	45195	545
2026	73146	193	54013	536	45195	545
2027	80679	144	56884	658	45195	545
2028	84407	130	61685	243	45195	545
2029	84407	130	44053	587	45195	545
2030	84407	130	53986	558	45195	545
2031	84407	130	56884	658	45195	545
2032	84407	130	61685	243	45195	545
2033	84407	130	44053	587	45195	545

3.5.10. Kod 039: Diğer Tür Çıkık/Burkulmalar

Random Forest modeli 2025 yılı için 11.421 vaka ve 237 ölüm tahmin ederken, aynı yıl için XGBoost modeli 11.340 vaka ve 240 ölüm, LightGBM modeli ise 10.192 vaka ve 222 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 29.230 vaka ve 299 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka ve ölüm tahminlerinde dönemsel artışlar göstermekle birlikte 2033 yılı için 17.468 vaka ile 345 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca daha sınırlı

bir deęişim sergileyerek 2033 yılı itibarıyla 10.307 vaka ve 221 ölüm düzeyinde seyretmektedir. Kod 039 özelinde Random Forest modelinin daha belirgin artış eğilimi gösteren ve daha dengeli bir tahmin yapısı sunduęu, XGBoost modelinin benzer doğrultuda ancak daha yüksek ölüm tahminleri ürettięi, LightGBM modelinin ise daha düşük hacimli ve görece yatay bir seyir izleyen tahminler ortaya koyduęu görölmektedir. Random Forest modeli için toplam 182.619 vaka ve 2.389 ölüm, XGBoost modeli için toplam 150.928 vaka ve 2.959 ölüm, LightGBM modeli için ise toplam 92.648 vaka ve 1.990 ölüm öngörülmektedir.

Tablo 3.21. Kod 039: Dięer Tür Çıkık/Burkulmalar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	11421	237	11340	240	10192	222
2026	12095	242	15332	301	10307	221
2027	12501	243	17239	294	10307	221
2028	13038	245	19116	372	10307	221
2029	17254	247	17409	345	10307	221
2030	28374	284	18088	372	10307	221
2031	29476	293	17468	345	10307	221
2032	29230	299	17468	345	10307	221
2033	29230	299	17468	345	10307	221

3.5.11. Kod 040: Travma Sonucu Organ Kaybı (Amputasyon)

Random Forest modeli 2025 yılı için 1.231 vaka ve 177 ölüm tahmin ederken, aynı yıl için XGBoost modeli 686 vaka ve 96 ölüm, LightGBM modeli ise 8.333 vaka ve 136 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca sınırlı bir artış göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost

modeli daha düşük hacimli vaka ve ölüm tahminleri üretmekte olup 2033 yılı için 505 vaka ile 79 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca daha yüksek ve dalgalı tahminler sunmakta; özellikle 2028 yılında 69.505 vaka ve 126 ölüm düzeyine ulaşmasının ardından 2030 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 040 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha düşük hacimli ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 11.494 vaka ve 1.872 ölüm, XGBoost modeli için toplam 5.020 vaka ve 671 ölüm, LightGBM modeli için ise toplam 374.391 vaka ve 2.992 ölüm öngörülmektedir.

Tablo 3.22. Kod 040: Travma Sonucu Organ Kaybı (Amputasyon) İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1231	177	686	96	8333	136
2026	1250	198	571	79	13123	86
2027	1285	213	535	79	41187	54
2028	1288	214	567	60	69505	126
2029	1288	214	557	79	61463	410
2030	1288	214	523	79	45195	545
2031	1288	214	527	60	45195	545
2032	1288	214	549	60	45195	545
2033	1288	214	505	79	45195	545

3.5.12. Kod 051: Beyin Sarsıntısı ve Kafatası Yaralanmaları

Random Forest modeli 2025 yılı için 673 vaka ve 54 ölüm tahmin ederken, aynı yıl için XGBoost modeli 593 vaka ve 60 ölüm, LightGBM modeli ise 2.439 vaka ve 70 ölüm

öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha sınırlı bir vaka hacmiyle seyretmekte ve 2033 yılı için 616 vaka ile 49 ölüm öngörmektedir. LightGBM modeli ise özellikle 2029 yılından itibaren belirgin biçimde daha yüksek tahminler üretmekte ve 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 051 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli tahminler ürettiği ve LightGBM modelinin ise özellikle dönem ortasından itibaren daha yüksek düzeyli tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 9.306 vaka ve 1.301 ölüm, XGBoost modeli için toplam 5.563 vaka ve 447 ölüm, LightGBM modeli için ise toplam 296.583 vaka ve 3.563 ölüm öngörülmektedir.

Tablo 3.23. Kod 051: Beyin Sarsıntısı ve Kafatası Yaralanmaları İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	673	54	593	60	2439	70
2026	835	67	616	18	11317	106
2027	878	84	624	58	27517	187
2028	946	115	656	48	29335	475
2029	1088	171	615	67	45195	545
2030	1125	188	611	49	45195	545
2031	1188	195	616	49	45195	545
2032	1285	213	616	49	45195	545
2033	1288	214	616	49	45195	545

3.5.13. Kod 052: İç Yaralanmalar

Random Forest modeli 2025 yılı için 620 vaka ve 48 ölüm tahmin ederken, aynı yıl için XGBoost modeli 625 vaka ve 18 ölüm, LightGBM modeli ise 203 vaka ve 34 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha sınırlı bir seyir izlemekte ve 2033 yılı için 509 vaka ile 60 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca oldukça dalgalı bir görünüm sergilemekte ve 2033 yılı itibarıyla 60.477 vaka ile 399 ölüm düzeyine ulaşmaktadır. Kod 052 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli tahminler ürettiği ve LightGBM modelinin ise özellikle dönem sonuna doğru belirgin biçimde daha yüksek düzeyli tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 9.381 vaka ve 1.344 ölüm, XGBoost modeli için toplam 4.953 vaka ve 603 ölüm, LightGBM modeli için ise toplam 157.880 vaka ve 875 ölüm öngörülmektedir.

Tablo 3.24. Kod 052: İç Yaralanmalar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	620	48	625	18	203	34
2026	834	73	651	106	10285	0
2027	882	89	548	80	0	79
2028	1008	135	524	79	4843	6
2029	1108	179	527	60	766	64
2030	1135	190	549	60	8499	47
2031	1218	202	505	79	22010	78
2032	1288	214	515	61	50797	168
2033	1288	214	509	60	60477	399

3.5.14. Kod 059: Diğer Tür Beyin Sarsıntısı/İç Yaralanmalar

Random Forest modeli 2025 yılı için 605 vaka ve 60 ölüm tahmin ederken, aynı yıl için XGBoost modeli 433 vaka ve 57 ölüm, LightGBM modeli ise 6.105 vaka ve 26 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir seyir izlemekte ve 2033 yılı için 509 vaka ile 60 ölüm öngörmektedir. LightGBM modeli ise özellikle dönem ortasından itibaren belirgin biçimde daha yüksek tahminler üretmekte ve 2033 yılı itibarıyla 45.195 vaka ile 545 ölüm düzeyine ulaşmaktadır. Kod 059 özelinde Random Forest modelinin daha dengeli bir artış örüntüsü sunduğu, XGBoost modelinin daha düşük hacimli tahminler ürettiği ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 9.179 vaka ve 1.307 ölüm, XGBoost modeli için toplam 4.507 vaka ve 578 ölüm, LightGBM modeli için ise toplam 328.066 vaka ve 2.927 ölüm öngörülmektedir.

Tablo 3.25. Kod 059: Diğer Tür Beyin Sarsıntısı/İç Yaralanmalar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	605	60	433	57	6105	26
2026	797	67	482	30	3156	111
2027	857	84	503	62	18837	51
2028	946	115	498	107	58711	160
2029	1088	171	521	61	60477	399
2030	1125	188	541	61	45195	545
2031	1188	195	505	79	45195	545
2032	1285	213	515	61	45195	545

2033	1288	214	509	60	45195	545
------	------	-----	-----	----	-------	-----

3.5.15. Kod 061: Termal Yanıklar

Random Forest modeli 2025 yılı için 6.412 vaka ve 149 ölüm tahmin ederken, aynı yıl için XGBoost modeli 2.673 vaka ve 171 ölüm, LightGBM modeli ise 18.222 vaka ve 71 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 28.374 vaka ve 284 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli vaka tahminleri üretmekle birlikte ölüm tahminlerinde 2033 yılı için 3.733 vaka ile 208 ölüm düzeyine ulaşmaktadır. LightGBM modeli ise özellikle 2026 yılından itibaren daha yüksek vaka tahminleri üretmekte ve 2028 yılından sonra 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 061 özelinde Random Forest modelinin artış eğilimini daha dengeli biçimde yansıttığı, XGBoost modelinin daha düşük hacimli tahminler sunduğu ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler ürettiği görülmektedir. Random Forest modeli için toplam 119.917 vaka ve 2.055 ölüm, XGBoost modeli için toplam 32.528 vaka ve 1.835 ölüm, LightGBM modeli için ise toplam 415.775 vaka ve 3.893 ölüm öngörülmektedir.

Tablo 3.26. Kod 061: Termal Yanıklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	6412	149	2673	171	18222	71
2026	7959	179	3733	208	65906	153
2027	10840	229	3723	208	60477	399
2028	11444	237	3734	208	45195	545
2029	12095	242	3733	208	45195	545
2030	12501	243	3733	208	45195	545
2031	13038	245	3733	208	45195	545

2032	17254	247	3733	208	45195	545
2033	28374	284	3733	208	45195	545

3.5.16. Kod 062: Kimyasal Yanıklar (Korozyon)

Random Forest modeli 2025 yılı için 1.031 vaka ve 158 ölüm tahmin ederken, aynı yıl için XGBoost modeli 802 vaka ve 129 ölüm, LightGBM modeli ise 3.682 vaka ve 26 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir görünüm sergilemekte ve 2033 yılı için 499 vaka ile 61 ölüm öngörmektedir. LightGBM modeli ise özellikle 2027 yılından sonra daha yüksek düzeyli tahminler üretmekte ve 2028 yılından itibaren 45.195 vaka ile 545 ölüm seviyesinde seyretmektedir. Kod 062 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha düşük hacimli ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 11.064 vaka ve 1.821 ölüm, XGBoost modeli için toplam 5.023 vaka ve 671 ölüm, LightGBM modeli için ise toplam 331.395 vaka ve 3.672 ölüm öngörülmektedir.

Tablo 3.27. Kod 062: Kimyasal Yanıklar (Korozyon) İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1031	158	802	129	3682	26
2026	1120	185	599	82	13665	112
2027	1188	195	518	79	42878	264
2028	1285	213	527	60	45195	545
2029	1288	214	549	60	45195	545
2030	1288	214	505	79	45195	545

2031	1288	214	515	61	45195	545
2032	1288	214	509	60	45195	545
2033	1288	214	499	61	45195	545

3.5.17. Kod 063: Donmalar

Random Forest modeli 2025 yılı için 5.267 vaka ve 104 ölüm tahmin ederken, aynı yıl için XGBoost modeli 3.389 vaka ve 174 ölüm, LightGBM modeli ise 0 vaka ve 132 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 13.038 vaka ve 245 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka tahminlerinde daha sınırlı bir düzeyde seyretmekle birlikte 2033 yılı için 3.733 vaka ve 208 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca dalgalı bir görünüm sergilemekte ve 2033 yılı itibarıyla 23.566 vaka ile 73 ölüm düzeyine ulaşmaktadır. Kod 063 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli ancak ölüm sayısı bakımından daha yüksek düzeyli tahminler ürettiği ve LightGBM modelinin ise daha değişken bir tahmin yapısı ortaya koyduğu görülmektedir. Random Forest modeli için toplam 85.400 vaka ve 1.770 ölüm, XGBoost modeli için toplam 33.457 vaka ve 1.838 ölüm, LightGBM modeli için ise toplam 66.967 vaka ve 690 ölüm öngörülmektedir.

Tablo 3.28. Kod 063: Donmalar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	5267	104	3389	174	0	132
2026	5762	140	3911	208	3629	18
2027	6494	151	3759	208	2933	111
2028	7959	179	3733	208	6878	106
2029	10840	229	3733	208	4290	103

2030	11444	237	3733	208	7117	72
2031	12095	242	3733	208	8300	17
2032	12501	243	3733	208	10254	58
2033	13038	245	3733	208	23566	73

3.5.18. Kod 069: Diğer Tür Yanıklar

Random Forest modeli 2025 yılı için 5.386 vaka ve 116 ölüm tahmin ederken, aynı yıl için XGBoost modeli 2.784 vaka ve 150 ölüm, LightGBM modeli ise 18.389 vaka ve 86 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 17.254 vaka ve 247 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir vaka örüntüsü sergilemekle birlikte ölüm tahminlerinde 2026 yılından itibaren 208 düzeyine yaklaşmakta ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise özellikle 2026 ve 2027 yıllarında daha yüksek tahminler üretmekte, 2028 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 069 özelinde Random Forest modelinin artış eğilimini daha dengeli biçimde yansıttığı, XGBoost modelinin daha düşük hacimli tahminler sunduğu ve LightGBM modelinin ise daha yüksek düzeyli tahminler ürettiği görülmektedir. Random Forest modeli için toplam 91.450 vaka ve 1.803 ölüm, XGBoost modeli için toplam 32.758 vaka ve 1.815 ölüm, LightGBM modeli için ise toplam 409.843 vaka ve 3.908 ölüm öngörülmektedir.

Tablo 3.29. Kod 069: Diğer Tür Yanıklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	5386	116	2784	150	18389	86
2026	5819	140	3840	209	59807	153
2027	6568	152	3735	208	60477	399

2028	8214	186	3734	208	45195	545
2029	11102	233	3733	208	45195	545
2030	11660	240	3733	208	45195	545
2031	12409	244	3733	208	45195	545
2032	13038	245	3733	208	45195	545
2033	17254	247	3733	208	45195	545

3.5.19. Kod 071: Akut Zehirlenmeler

Random Forest modeli 2025 yılı için 756 vaka ve 45 ölüm tahmin ederken, aynı yıl için XGBoost modeli 594 vaka ve 22 ölüm, LightGBM modeli ise 9.218 vaka ve 27 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli tahminler üretmekte ve 2033 yılı için 616 vaka ile 49 ölüm öngörmektedir. LightGBM modeli ise özellikle 2027 yılından itibaren belirgin biçimde daha yüksek tahminler üretmekte ve 2028 yılından sonra 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 071 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli tahminler ürettiği ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 9.558 vaka ve 1.336 ölüm, XGBoost modeli için toplam 5.499 vaka ve 424 ölüm, LightGBM modeli için ise toplam 368.304 vaka ve 3.799 ölüm öngörülmektedir.

Tablo 3.30. Kod 071: Akut Zehirlenmeler İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	756	45	594	22	9218	27
2026	868	70	603	60	26644	92

2027	889	87	615	48	61272	410
2028	1008	135	607	49	45195	545
2029	1108	179	616	49	45195	545
2030	1135	190	616	49	45195	545
2031	1218	202	616	49	45195	545
2032	1288	214	616	49	45195	545
2033	1288	214	616	49	45195	545

3.5.20. Kod 072: Akut Enfeksiyonlar

Random Forest modeli 2025 yılı için 1.505 vaka ve 156 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.852 vaka ve 121 ölüm, LightGBM modeli ise 0 vaka ve 164 ölüm öngörmektedir. Random Forest modelinde tahminler 2026 yılı sonrasında daha sınırlı bir değişim göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyinde seyretmektedir. XGBoost modeli vaka ve ölüm tahminlerinde daha yüksek bir düzey sergilemekte ve 2028 yılından itibaren 3.733 vaka ile 208 ölüm düzeyinde dengelenmektedir. LightGBM modeli ise dönem boyunca dalgalı bir örüntü ortaya koymakta ve 2033 yılı itibarıyla 3.574 vaka ile 201 ölüm düzeyine ulaşmaktadır. Kod 072 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha yüksek düzeyli ve LightGBM modelinin ise daha değişken bir tahmin yapısı sunduğu görülmektedir. Random Forest modeli için toplam 11.838 vaka ve 1.848 ölüm, XGBoost modeli için toplam 31.146 vaka ve 1.732 ölüm, LightGBM modeli için ise toplam 30.485 vaka ve 1.591 ölüm öngörülmektedir.

Tablo 3.31. Kod 072: Akut Enfeksiyonlar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1505	156	1852	121	0	164
2026	1320	195	3183	155	3196	1

2027	1285	213	3712	208	1844	182
2028	1288	214	3734	208	5317	207
2029	1288	214	3733	208	2837	237
2030	1288	214	3733	208	5010	199
2031	1288	214	3733	208	3694	201
2032	1288	214	3733	208	5013	199
2033	1288	214	3733	208	3574	201

3.5.21. Kod 079: Diğer Tür Zehirlenmeler

Random Forest modeli 2025 yılı için 1.987 vaka ve 135 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.566 vaka ve 103 ölüm, LightGBM modeli ise 6.332 vaka ve 105 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 12.095 vaka ve 242 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir seyir izlemekle birlikte 2033 yılı için 3.734 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise özellikle 2027 ve 2028 yıllarında daha yüksek tahminler üretmekte, 2029 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 079 özelinde Random Forest modelinin artış eğilimini daha dengeli biçimde yansıttığı, XGBoost modelinin daha düşük hacimli tahminler sunduğu ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler ürettiği görülmektedir. Random Forest modeli için toplam 62.978 vaka ve 1.537 ölüm, XGBoost modeli için toplam 24.060 vaka ve 1.108 ölüm, LightGBM modeli için ise toplam 372.434 vaka ve 3.448 ölüm öngörülmektedir.

Tablo 3.32. Kod 079: Diğer Tür Zehirlenmeler İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1987	135	1566	103	6332	105

2026	3274	137	1862	92	19077	83
2027	5138	120	1824	87	59587	125
2028	5605	136	1849	87	61463	410
2029	6333	148	2160	87	45195	545
2030	7248	164	3747	87	45195	545
2031	9854	218	3612	149	45195	545
2032	11444	237	3706	208	45195	545
2033	12095	242	3734	208	45195	545

3.5.22. Kod 081: Nefesin Kesilmesi (Asfiksi)

Random Forest modeli 2025 yılı için 4.786 vaka ve 96 ölüm tahmin ederken, aynı yıl için XGBoost modeli 4.291 vaka ve 169 ölüm, LightGBM modeli ise 0 vaka ve 137 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 13.038 vaka ve 245 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka sayısı bakımından daha sınırlı bir görünüm sergilemekle birlikte ölüm tahminlerinde yüksek bir düzeyi korumakta ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca dalgalı bir örüntü ortaya koymakta ve 2033 yılı itibarıyla 3.574 vaka ile 201 ölüm düzeyine ulaşmaktadır. Kod 081 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli ancak ölüm sayısı bakımından daha yüksek düzeyli tahminler ürettiği ve LightGBM modelinin ise daha değişken bir tahmin yapısı sergilediği görülmektedir. Random Forest modeli için toplam 78.994 vaka ve 1.659 ölüm, XGBoost modeli için toplam 33.470 vaka ve 1.834 ölüm, LightGBM modeli için ise toplam 30.485 vaka ve 1.564 ölüm öngörülmektedir.

Tablo 3.33. Kod 081: Nefesin Kesilmesi (Asfiksi) İçin Karşılaştırmalı Tahminler

Yıl	RF	RF	XGBoost	XGBoost	LightGBM	LightGBM
	Vaka	Ölüm	Vaka	Ölüm	Vaka	Ölüm

2025	4786	96	4291	169	0	137
2026	5398	123	2867	209	3196	1
2027	5819	140	3889	208	1844	182
2028	6568	152	3758	208	5317	207
2029	8214	186	3733	208	2837	237
2030	11102	233	3733	208	5010	199
2031	11660	240	3733	208	3694	201
2032	12409	244	3733	208	5013	199
2033	13038	245	3733	208	3574	201

3.5.23. Kod 082: Suda Boğulma

Random Forest modeli 2025 yılı için 5.669 vaka ve 117 ölüm tahmin ederken, aynı yıl için XGBoost modeli 3.314 vaka ve 175 ölüm, LightGBM modeli ise 0 vaka ve 81 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 17.254 vaka ve 247 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir görünüm sergilemekle birlikte ölüm tahminlerinde yüksek bir düzeyi korumakta ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca dalgalı bir seyir izlemekte, özellikle 2031 yılından itibaren belirgin biçimde yükselerek 2033 yılı itibarıyla 45.195 vaka ve 545 ölüm düzeyine ulaşmaktadır. Kod 082 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli ancak ölüm sayısı bakımından daha yüksek düzeyli tahminler ürettiği ve LightGBM modelinin ise dönem sonuna doğru belirgin biçimde yükselen tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 97.270 vaka ve 1.889 ölüm, XGBoost modeli için toplam 33.204 vaka ve 1.839 ölüm, LightGBM modeli için ise toplam 172.599 vaka ve 2.002 ölüm öngörülmektedir.

Tablo 3.34. Kod 082: Suda Boğulma İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	5669	117	3314	175	0	81
2026	6470	150	3768	208	5148	6
2027	7959	179	3723	208	0	45
2028	10840	229	3734	208	11234	2
2029	11444	237	3733	208	10853	181
2030	12095	242	3733	208	14671	200
2031	12501	243	3733	208	40303	397
2032	13038	245	3733	208	45195	545
2033	17254	247	3733	208	45195	545

3.5.24. Kod 089: Diğer Tür Boğulmalar

Random Forest modeli 2025 yılı için 5.669 vaka ve 117 ölüm tahmin ederken, aynı yıl için XGBoost modeli 3.272 vaka ve 175 ölüm, LightGBM modeli ise 0 vaka ve 80 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 17.254 vaka ve 247 ölüm düzeyine ulaşmaktadır. XGBoost modeli daha düşük hacimli bir seyir izlemekle birlikte ölüm tahminlerinde yüksek düzeyi korumakta ve 2033 yılı için 3.733 vaka ile 208 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca dalgalı bir görünüm sergilemekte, özellikle 2031 yılından itibaren belirgin biçimde yükselerek 2033 yılı itibarıyla 45.195 vaka ve 545 ölüm düzeyine ulaşmaktadır. Kod 089 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha düşük hacimli ancak ölüm sayısı bakımından daha yüksek düzeyli tahminler ürettiği ve LightGBM modelinin ise dönem sonuna doğru belirgin biçimde yükselen tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 97.270 vaka ve 1.889 ölüm, XGBoost modeli için toplam 33.146 vaka ve 1.839 ölüm, LightGBM modeli için ise toplam 172.599 vaka ve 2.001 ölüm öngörülmektedir.

Tablo 3.35. Kod 089: Diğer Tür Boğulmalar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	5669	117	3272	175	0	80
2026	6470	150	3752	208	5148	6
2027	7959	179	3723	208	0	45
2028	10840	229	3734	208	11234	2
2029	11444	237	3733	208	10853	181
2030	12095	242	3733	208	14671	200
2031	12501	243	3733	208	40303	397
2032	13038	245	3733	208	45195	545
2033	17254	247	3733	208	45195	545

3.5.25. Kod 091: Akut İşitme Kaybı

Random Forest modeli 2025 yılı için 1.233 vaka ve 149 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.327 vaka ve 122 ölüm, LightGBM modeli ise 2 vaka ve 169 ölüm öngörmektedir. Random Forest modelinde tahminler 2028 yılından itibaren yatay bir seyir izleyerek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyinde devam etmektedir. XGBoost modeli dönem boyunca daha sınırlı bir değişim göstermekte ve 2033 yılı için 1.022 vaka ile 67 ölüm öngörmektedir. LightGBM modeli ise vaka ve ölüm tahminlerinde dalgalı bir örüntü sergilemekte, 2033 yılı itibarıyla 3.694 vaka ve 201 ölüm düzeyine ulaşmaktadır. Kod 091 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha sınırlı değişim gösteren ve düşük düzeyli tahminler sunduğu, LightGBM modelinin ise daha değişken bir tahmin yapısı ortaya koyduğu görülmektedir. Random Forest modeli için toplam 11.473 vaka ve 1.835 ölüm, XGBoost modeli için toplam 9.803 vaka ve 801 ölüm, LightGBM modeli için ise toplam 27.201 vaka ve 1.629 ölüm öngörülmektedir.

Tablo 3.36. Kod 091: Akut İşitme Kaybı İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1233	149	1327	122	2	169
2026	1233	193	1158	156	2804	6
2027	1279	209	1130	120	1528	188
2028	1288	214	1078	68	5931	199
2029	1288	214	1045	67	1679	240
2030	1288	214	999	67	3099	214
2031	1288	214	1022	67	3454	213
2032	1288	214	1022	67	5010	199
2033	1288	214	1022	67	3694	201

3.5.26. Kod 092: Basıncı Etkileri (Barotravma)

Random Forest modeli 2025 yılı için 1.351 vaka ve 163 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.314 vaka ve 121 ölüm, LightGBM modeli ise 0 vaka ve 165 ölüm öngörmektedir. Random Forest modelinde tahminler 2028 yılından itibaren yatay bir seyir izleyerek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyinde devam etmektedir. XGBoost modeli dönem boyunca daha sınırlı bir değişim göstermekte ve 2033 yılı için 1.022 vaka ile 67 ölüm öngörmektedir. LightGBM modeli ise dalgalı bir yapı sergilemekte, dönem boyunca orta ölçekli artış ve azalışlar göstererek 2033 yılı itibarıyla 3.574 vaka ve 201 ölüm düzeyine ulaşmaktadır. Kod 092 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha sınırlı değişim gösteren ve düşük düzeyli tahminler sunduğu, LightGBM modelinin ise daha değişken bir tahmin örüntüsü ortaya koyduğu görülmektedir. Random Forest modeli için toplam 11.603 vaka ve 1.855 ölüm, XGBoost modeli için toplam 9.778 vaka ve 800 ölüm, LightGBM modeli için ise toplam 30.485 vaka ve 1.592 ölüm öngörülmektedir.

Tablo 3.37. Kod 092: Basınç Etkileri (Barotravma) İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1351	163	1314	121	0	165
2026	1239	195	1149	156	3196	1
2027	1285	213	1127	120	1844	182
2028	1288	214	1078	68	5317	207
2029	1288	214	1045	67	2837	237
2030	1288	214	999	67	5010	199
2031	1288	214	1022	67	3694	201
2032	1288	214	1022	67	5013	199
2033	1288	214	1022	67	3574	201

3.5.27. Kod 099: Diğer Ses/Titreşim Etkileri

Random Forest modeli 2025 yılı için 1.666 vaka ve 152 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.656 vaka ve 93 ölüm, LightGBM modeli ise 10.182 vaka ve 130 ölüm öngörmektedir. Random Forest modelinde tahminler 2028 yılından itibaren yatay bir seyir izleyerek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyinde devam etmektedir. XGBoost modeli dönem boyunca kademeli bir düşüş göstererek 2033 yılı için 616 vaka ile 49 ölüm öngörmektedir. LightGBM modeli ise özellikle 2026 yılından sonra belirgin biçimde daha yüksek tahminler üretmekte ve 2027 yılından itibaren 45.195 vaka ile 545 ölüm düzeyinde seyretmektedir. Kod 099 özelinde Random Forest modelinin daha dengeli, XGBoost modelinin daha düşük hacimli ve LightGBM modelinin ise belirgin biçimde daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 12.194 vaka ve 1.828 ölüm, XGBoost modeli için toplam 7.181 vaka ve 583 ölüm, LightGBM modeli için ise toplam 364.559 vaka ve 4.131 ölüm öngörülmektedir.

Tablo 3.38. Kod 099: Diğer Ses/Titreşim Etkileri İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1666	152	1656	93	10182	130
2026	1495	189	972	92	38012	186
2027	1305	203	769	68	45195	545
2028	1288	214	703	67	45195	545
2029	1288	214	622	67	45195	545
2030	1288	214	611	49	45195	545
2031	1288	214	616	49	45195	545
2032	1288	214	616	49	45195	545
2033	1288	214	616	49	45195	545

3.5.28. Kod 101: Sıcaklık ve Güneş Çarpması

Random Forest modeli 2025 yılı için 2.143 vaka ve 128 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.963 vaka ve 121 ölüm, LightGBM modeli ise 0 vaka ve 168 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 12.095 vaka ve 242 ölüm düzeyine ulaşmaktadır. XGBoost modeli ise 2026 yılından sonra daha yüksek bir seyir izleyerek 2028 yılından itibaren 3.733 vaka ile 208 ölüm düzeyinde devam etmekte ve 2033 yılı için aynı seviyeyi korumaktadır. LightGBM modeli ise dönem boyunca dalgalı bir görünüm sergilemekte ve 2033 yılı itibarıyla 3.574 vaka ile 201 ölüm düzeyine ulaşmaktadır. Kod 101 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin orta düzeyli ve daha istikrarlı bir tahmin örüntüsü sergilediği, LightGBM modelinin ise daha değişken bir yapı ortaya koyduğu görülmektedir. Random Forest modeli için toplam 63.417 vaka ve 1.524 ölüm, XGBoost modeli için toplam 31.849 vaka ve 1.733 ölüm, LightGBM modeli için ise toplam 30.485 vaka ve 1.595 ölüm öngörülmektedir.

Tablo 3.39. Kod 101: Sıcaklık ve Güneş Çarpması İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	2143	128	1963	121	0	168
2026	3516	133	3763	156	3196	1
2027	5179	118	3724	208	1844	182
2028	5605	136	3734	208	5317	207
2029	6333	148	3733	208	2837	237
2030	7248	164	3733	208	5010	199
2031	9854	218	3733	208	3694	201
2032	11444	237	3733	208	5013	199
2033	12095	242	3733	208	3574	201

3.5.29. Kod 102: Radyasyon Etkileri (Termal Olmayan)

Random Forest modeli 2025 yılı için 6.168 vaka ve 127 ölüm tahmin ederken, aynı yıl için XGBoost modeli 5.675 vaka ve 175 ölüm, LightGBM modeli ise 0 vaka ve 85 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca kademeli biçimde artarak 2033 yılı itibarıyla 28.374 vaka ve 284 ölüm düzeyine ulaşmaktadır. XGBoost modeli de benzer biçimde artış göstermekle birlikte özellikle 2030 sonrasında daha yüksek vaka ve ölüm tahminleri üretmekte ve 2033 yılı için 17.468 vaka ile 345 ölüm öngörmektedir. LightGBM modeli ise dönem başında düşük düzeyde seyretmesine karşın özellikle 2031 yılından itibaren keskin biçimde yükselmekte ve 2033 yılı itibarıyla 45.195 vaka ile 545 ölüm düzeyine ulaşmaktadır. Kod 102 özelinde Random Forest modelinin daha dengeli bir artış örüntüsü sunduğu, XGBoost modelinin daha yüksek düzeyli tahminler ürettiği ve LightGBM modelinin ise dönem sonuna doğru belirgin biçimde sıçrayan tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 117.829 vaka

ve 2.003 ölüm, XGBoost modeli için toplam 131.186 vaka ve 2.659 ölüm, LightGBM modeli için ise toplam 172.599 vaka ve 2.006 ölüm öngörülmektedir.

Tablo 3.40. Kod 102: Radyasyon Etkileri (Termal Olmayan) İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	6168	127	5675	175	0	85
2026	7146	161	9499	247	5148	6
2027	9809	217	12818	285	0	45
2028	11444	237	15142	272	11234	2
2029	12095	242	17199	273	10853	181
2030	12501	243	18449	372	14671	200
2031	13038	245	17468	345	40303	397
2032	17254	247	17468	345	45195	545
2033	28374	284	17468	345	45195	545

3.5.30. Kod 103: İndirgenmiş Isı Etkileri

Random Forest modeli 2025 yılı için 3.677 vaka ve 102 ölüm tahmin ederken, aynı yıl için XGBoost modeli 4.391 vaka ve 121 ölüm, LightGBM modeli ise 0 vaka ve 161 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 12.501 vaka ve 243 ölüm düzeyine ulaşmaktadır. XGBoost modeli ilk yılda daha yüksek vaka tahmini üretmekle birlikte, izleyen yıllarda 3.733 vaka ile 208 ölüm düzeyinde daha yatay bir seyir izlemekte ve 2033 yılı için aynı seviyeyi korumaktadır. LightGBM modeli ise dönem boyunca dalgalı bir yapı sergilemekte ve 2033 yılı itibarıyla 3.574 vaka ile 201 ölüm düzeyine ulaşmaktadır. Kod 103 özelinde Random Forest modelinin daha dengeli bir artış örüntüsü sunduğu, XGBoost modelinin daha sınırlı değişim gösteren

bir tahmin yapısı ortaya koyduğu ve LightGBM modelinin ise daha değişken tahminler ürettiği görülmektedir. Random Forest modeli için toplam 74.027 vaka ve 1.607 ölüm, XGBoost modeli için toplam 33.362 vaka ve 1.751 ölüm, LightGBM modeli için ise toplam 30.485 vaka ve 1.588 ölüm öngörülmektedir.

Tablo 3.41. Kod 103: İndirgenmiş Isı Etkileri İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	3677	102	4391	121	0	161
2026	5280	118	2744	173	3196	1
2027	5595	135	3826	209	1844	182
2028	6333	148	3735	208	5317	207
2029	7248	164	3734	208	2837	237
2030	9854	218	3733	208	5010	199
2031	11444	237	3733	208	3694	201
2032	12095	242	3733	208	5013	199
2033	12501	243	3733	208	3574	201

3.5.31. Kod 109: Diğer Isı/Işık/Radyasyon Etkileri

Random Forest modeli 2025 yılı için 564 vaka ve 43 ölüm tahmin ederken, aynı yıl için XGBoost modeli 516 vaka ve 23 ölüm, LightGBM modeli ise 38 vaka ve 44 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca kademeli biçimde artarak 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost modeli ise daha düşük hacimli ve sınırlı değişim gösteren bir seyir izlemekte, 2033 yılı için 498 vaka ile 61 ölüm öngörmektedir. LightGBM modeli dönem boyunca oldukça dalgalı bir örüntü sergilemekte ve özellikle 2031 sonrasında belirgin biçimde yükselerek 2033 yılı itibarıyla 60.477 vaka ile 399 ölüm düzeyine ulaşmaktadır. Kod 109 özelinde Random Forest

modelinin daha dengeli, XGBoost modelinin daha düşük hacimli ve LightGBM modelinin ise özellikle dönem sonuna doğru belirgin biçimde daha yüksek düzeyli tahminler sunduğu görülmektedir. Random Forest modeli için toplam 9.159 vaka ve 1.274 ölüm, XGBoost modeli için toplam 4.687 vaka ve 528 ölüm, LightGBM modeli için ise toplam 155.703 vaka ve 870 ölüm öngörülmektedir.

Tablo 3.42. Kod 109: Diğer Isı/Işık/Radyasyon Etkileri İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	564	43	516	23	38	44
2026	799	59	641	62	8273	7
2027	873	77	513	78	0	57
2028	949	114	515	61	4843	6
2029	1088	171	509	60	766	64
2030	1125	188	499	61	8499	47
2031	1188	195	498	61	22010	78
2032	1285	213	498	61	50797	168
2033	1288	214	498	61	60477	399

3.5.32. Kod 111: Saldırı/Tehdit Sonrası Şoklar

Random Forest modeli 2025 yılı için 5.188 vaka ve 102 ölüm tahmin ederken, aynı yıl için XGBoost modeli 3.398 vaka ve 174 ölüm, LightGBM modeli ise 0 vaka ve 128 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 13.038 vaka ve 245 ölüm düzeyine ulaşmaktadır. XGBoost modeli vaka tahminlerinde daha düşük hacimli bir seyir izlemekle birlikte 2033 yılı için 3.733 vaka ve 208 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca dalgalı bir görünüm

sergilemekte ve 2033 yılı itibarıyla 23.566 vaka ile 73 ölüm düzeyine ulaşmaktadır. Kod 111 özelinde Random Forest modelinin daha dengeli bir artış örüntüsü sunduğu, XGBoost modelinin daha düşük hacimli ancak ölüm sayısı bakımından daha yüksek düzeyli tahminler ürettiği ve LightGBM modelinin ise daha değişken bir tahmin yapısı ortaya koyduğu görülmektedir. Random Forest modeli için toplam 83.314 vaka ve 1.734 ölüm, XGBoost modeli için toplam 33.469 vaka ve 1.838 ölüm, LightGBM modeli için ise toplam 66.967 vaka ve 686 ölüm öngörülmektedir.

Tablo 3.43. Kod 111: Saldırı/Tehdit Sonrası Şoklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	5188	102	3398	174	0	128
2026	5613	135	3914	208	3629	18
2027	6333	148	3759	208	2933	111
2028	7248	164	3733	208	6878	106
2029	9854	218	3733	208	4290	103
2030	11444	237	3733	208	7117	72
2031	12095	242	3733	208	8300	17
2032	12501	243	3733	208	10254	58
2033	13038	245	3733	208	23566	73

3.5.33. Kod 112: Travma Şokları

Random Forest modeli 2025 yılı için 1.803 vaka ve 151 ölüm tahmin ederken, aynı yıl için XGBoost modeli 1.894 vaka ve 121 ölüm, LightGBM modeli ise 0 vaka ve 142 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış eğilimi göstererek 2033 yılı itibarıyla 11.660 vaka ve 240 ölüm düzeyine ulaşmaktadır. XGBoost modeli 2027 yılından itibaren 3.733 vaka ve 208 ölüm düzeyinde daha yatay bir seyir izlemekte ve dönem

sonuna kadar bu düzeyi korumaktadır. LightGBM modeli ise dönem boyunca dalgalı bir görünüm sergilemekte ve 2033 yılı itibarıyla 3.574 vaka ile 201 ölüm düzeyinde seyretmektedir. Kod 112 özelinde Random Forest modelinin daha dengeli bir artış eğilimi sunduğu, XGBoost modelinin daha sınırlı değişim gösteren bir tahmin yapısı ortaya koyduğu ve LightGBM modelinin ise daha değişken bir tahmin örüntüsü sergilediği görülmektedir. Random Forest modeli için toplam 56.713 vaka ve 1.517 ölüm, XGBoost modeli için toplam 31.229 vaka ve 1.732 ölüm, LightGBM modeli için ise toplam 30.485 vaka ve 1.569 ölüm öngörülmektedir.

Tablo 3.44. Kod 112: Travma Şokları İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1803	151	1894	121	0	142
2026	2291	167	3203	155	3196	1
2027	3915	126	3733	208	1844	182
2028	5367	122	3734	208	5317	207
2029	5793	140	3733	208	2837	237
2030	6568	152	3733	208	5010	199
2031	8214	186	3733	208	3694	201
2032	11102	233	3733	208	5013	199
2033	11660	240	3733	208	3574	201

3.5.34. Kod 119: Diğer Tür Şoklar

Random Forest modeli 2025 yılı için 545 vaka ve 43 ölüm tahmin ederken, aynı yıl için XGBoost modeli 370 vaka ve 29 ölüm, LightGBM modeli ise 4.597 vaka ve 14 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca kademeli bir artış göstererek 2033 yılı itibarıyla 1.288 vaka ve 214 ölüm düzeyine ulaşmaktadır. XGBoost

modeli dönem boyunca daha düşük hacimli bir seyir izlemekte ve 2033 yılı için 509 vaka ile 60 ölüm öngörmektedir. LightGBM modeli ise belirgin dalgalanmalar sergilemekte ve 2033 yılı itibarıyla 5.013 vaka ile 199 ölüm düzeyinde seyretmektedir. Kod 119 özelinde Random Forest modelinin daha dengeli bir artış örüntüsü sunduğu, XGBoost modelinin daha düşük hacimli tahminler ürettiği ve LightGBM modelinin ise daha değişken ve görece daha yüksek düzeyli tahminler ortaya koyduğu görülmektedir. Random Forest modeli için toplam 8.822 vaka ve 1.174 ölüm, XGBoost modeli için toplam 4.596 vaka ve 549 ölüm, LightGBM modeli için ise toplam 31.508 vaka ve 1.387 ölüm öngörülmektedir.

Tablo 3.45. Kod 119: Diğer Tür Şoklar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	545	43	370	29	4597	14
2026	770	53	613	23	0	147
2027	861	71	490	89	3196	1
2028	889	87	517	88	1844	182
2029	1008	135	528	60	5317	207
2030	1108	179	548	60	2837	237
2031	1135	190	506	79	5010	199
2032	1218	202	515	61	3694	201
2033	1288	214	509	60	5013	199

3.5.35. Kod 120: Birden Fazla Sayıda Yaralanmalar (Multitravma)

Random Forest modeli 2025 yılı için 1.392 vaka ve 230 ölüm tahmin ederken, aynı yıl için XGBoost modeli 831 vaka ve 259 ölüm, LightGBM modeli ise 1.749 vaka ve 199 ölüm öngörmektedir. Random Forest modelinde tahminler 2026 yılından itibaren 1.374 vaka ve 228 ölüm düzeyinde yatay bir seyir izlemekte ve dönem sonuna kadar bu seviyeyi

korumaktadır. XGBoost modeli vaka tahminlerinde daha düşük hacimli bir görünüm sergilemekte ve 2033 yılı için 515 vaka ile 61 ölüm öngörmektedir. LightGBM modeli ise dönem boyunca dalgalı bir yapı ortaya koymakta ve 2033 yılı itibarıyla 3.694 vaka ile 201 ölüm düzeyine ulaşmaktadır. Kod 120 özelinde Random Forest modelinin daha dengeli ve istikrarlı bir tahmin yapısı sunduğu, XGBoost modelinin daha düşük hacimli tahminler ürettiği ve LightGBM modelinin ise daha değişken bir örüntü sergilediği görülmektedir. Random Forest modeli için toplam 12.384 vaka ve 2.054 ölüm, XGBoost modeli için toplam 5.414 vaka ve 989 ölüm, LightGBM modeli için ise toplam 31.671 vaka ve 1.884 ölüm öngörülmektedir.

Tablo 3.46. Kod 120: Birden Fazla Sayıda Yaralanmalar (Multitravma) İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	1392	230	831	259	1749	199
2026	1374	228	692	171	4847	219
2027	1374	228	685	138	2208	200
2028	1374	228	585	82	5931	199
2029	1374	228	525	79	1679	240
2030	1374	228	527	60	3099	214
2031	1374	228	549	60	3454	213
2032	1374	228	505	79	5010	199
2033	1374	228	515	61	3694	201

3.5.36. Kod 999: Diğer Başlıklar Altında Sınıflandırılmayanlar

Random Forest modeli 2025 yılı için 69.431 vaka ve 214 ölüm tahmin ederken, aynı yıl için XGBoost modeli 44.022 vaka ve 420 ölüm, LightGBM modeli ise 45.195 vaka ve

545 ölüm öngörmektedir. Random Forest modelinde tahminler dönem boyunca artış göstererek 2028 yılından itibaren 84.407 vaka ve 130 ölüm düzeyine ulaşmakta ve dönem sonuna kadar bu seviyeyi korumaktadır. XGBoost modeli ise dönem boyunca dalgalı bir seyir izlemekte ve 2033 yılı için 44.053 vaka ile 587 ölüm öngörmektedir. LightGBM modeli dönem boyunca aynı düzeyi koruyarak 2033 yılı itibarıyla 45.195 vaka ve 545 ölüm seviyesinde kalmaktadır. Kod 999 özelinde Random Forest modelinin daha dengeli bir tahmin örüntüsü sunduğu, XGBoost modelinin ölüm tahminleri bakımından daha yüksek ve dalgalı bir yapı sergilediği, LightGBM modelinin ise yüksek düzeyde sabit kalan tahminler ürettiği görülmektedir. Random Forest modeli için toplam 729.698 vaka ve 1.331 ölüm, XGBoost modeli için toplam 477.265 vaka ve 4.490 ölüm, LightGBM modeli için ise toplam 406.755 vaka ve 4.905 ölüm öngörülmektedir.

Tablo 3.47. Kod 999: Diğer Başlıklar Altında Sınıflandırılmayanlar İçin Karşılaştırmalı Tahminler

Yıl	RF Vaka	RF Ölüm	XGBoost Vaka	XGBoost Ölüm	LightGBM Vaka	LightGBM Ölüm
2025	69431	214	44022	420	45195	545
2026	73146	193	54013	536	45195	545
2027	80679	144	56884	658	45195	545
2028	84407	130	61685	243	45195	545
2029	84407	130	44053	587	45195	545
2030	84407	130	53986	558	45195	545
2031	84407	130	56884	658	45195	545
2032	84407	130	61685	243	45195	545
2033	84407	130	44053	587	45195	545

4. TARTIŞMA

4.1. Bulguların Genel Değerlendirilmesi

Araştırma kapsamında, 2016-2024 yıllarına ait Sosyal Güvenlik Kurumu (SGK) verileri kullanılarak Random Forest, XGBoost ve LightGBM algoritmaları ile 2025-2033 dönemi için projeksiyonlar gerçekleştirilmiştir. Çoklu hedef değişkenli makine öğrenimi modellerinden elde edilen bulgular bütüncül olarak değerlendirildiğinde, ilgili dokuz yıllık periyotta iş kazası ve ilişkili sonuç değişkenlerinde istikrarlı bir artış eğilimi yaşanacağı öngörülmektedir. Ortaya çıkan bu sayısal artış projeksiyonu, çalışma hayatındaki risk potansiyelinin büyüme eğiliminde olduğuna işaret etmekte ve mevcut reaktif iş sağlığı ve güvenliği (İSG) yaklaşımlarının, veri analitiği temelli önleyici stratejilerle desteklenmesi gerektiğini düşündürmektedir.

Gerçekleştirilen zaman serisi tahminlerinin yapısal dağılımı incelendiğinde, öngörülen toplam kaza hacminin en büyük bölümünü bir, iki, üç, dört ile beş gün ve üzeri iş göremezlikle sonuçlanan yaralanmaların oluşturduğu saptanmıştır. Ölümle sonuçlanmayan ancak doğrudan iş gücü ve verimlilik kaybı yaratan bu kaza türlerindeki artış beklentisi, çalışmanın temel tespitlerinden biri olarak öne çıkmaktadır. Öte yandan, veri seti içerisinde nicel olarak sınıf dengesizliği yaratan ölümlü kaza verileri (yalnızca ölen erkek ve ölen kadın çalışan değişkenleri), iş göremezlik sürelerinden bağımsız, farklı bir sonuç değişkeni grubu olarak değerlendirilmiştir. Modellerin, veri setindeki nadir rastlanan bu mortalite örüntülerini de yansıtabildiği görülmektedir; nitekim ölüm vakalarında da genel kaza artışına paralel olarak yukarı yönlü bir ivmeye işaret edilmektedir.

Analize dâhil edilen ağaç tabanlı algoritmaların genel tahminsel başarısı değerlendirildiğinde, modellerin kaza eğilimlerini ve veri setindeki dengesizlikleri yansıtabildiği görülmektedir. Özellikle, sayıca az olan ölüm vakalarına ait artış trendinin tahminlere yansıtılabilmesi, makine öğrenimi mimarilerinin İSG alanındaki risk öngörüsü potansiyelini desteklemektedir. Sonuç olarak çalışmanın genel bulguları; kaza öngörülerinde geleneksel yöntemlerin ötesine geçilerek, yapay zekâ algoritmalarının İSG alanında risklerin öngörülmesine yönelik analitik bir araç olarak değerlendirilebileceğini göstermektedir.

4.2. Bulguların Literatür ile Karşılaştırılması

Çalışma kapsamında oluşturulan zaman serisi projeksiyonlarında, makine öğrenimi modellerinin performansı değerlendirildiğinde Random Forest algoritmasının en düşük hata oranlarına (RMSE: 933.78, MAE: 387.813) ulaşarak veri setini karşılaştırmalı olarak en iyi temsil eden model olduğu saptanmıştır. Özellikle milyonlarca kayıttan oluşan iş göremezlik vakaları ile sayıca çok daha az olan ölüm vakaları arasındaki sınıf dengesizliğinin (class imbalance) etkilerinin, modelin çoklu karar ağacı yapısı sayesinde daha dengeli biçimde yansıtılabildiği görülmektedir.

İlgili literatür incelendiğinde; Random Forest algoritmasının, hedef değişkenler arasında aşırı dengesiz dağılımların bulunduğu veri setlerinde varyansı düşürerek aşırı ezberlemenin (overfitting) önüne geçtiği ve diğer algoritmalara kıyasla daha kararlı sonuçlar ürettiği görülmektedir (Bilenler, 2021). Benzer biçimde, Türkiye'deki endüstriyel iş kazası verileri üzerinde yapılan spesifik tahminleme araştırmalarında da Random Forest modellerinin yüksek doğruluk oranlarına ulaştığı ifade edilmektedir (Karakaya Özkan ve Ulaş, 2023). Çalışmada en iyi performans gösteren model olarak öne çıkan Random Forest'ın gürültülü İSG verilerinde yapısal karmaşıklığı yönetebilme biçiminin, literatürdeki bu makine öğrenimi bulgularıyla örtüştüğü görülmektedir.

Öte yandan, analiz sürecine dâhil edilen ağaç tabanlı artırma (boosting) algoritmalarından LightGBM, en yüksek hata oranlarını (RMSE: 1640.72, MAE: 818.59) üreterek bu çalışmanın veri seti sınırları dâhilinde görece en düşük performansı sergilemiştir. Modelin yaprak odaklı (leaf-wise) büyüme stratejisinin, eldeki veri hacmi ve kaza örüntüleri karşısında veri setindeki dalgalı örüntülere daha duyarlı bir yapı sergilediği ve daha değişken sonuçlar ürettiği değerlendirilmektedir.

Makine öğrenimi algoritmalarının karşılaştırmalı performansını inceleyen güncel çalışmalar değerlendirildiğinde; Random Forest gibi torbalama (bagging) yöntemlerinin yüksek doğruluk sunduğu veri yapılarında, LightGBM gibi modellerin kısıtlı veri senaryolarında daha düşük doğruluk oranlarında kalabildiği raporlanmaktadır (Kızıltepe ve Gülbandılar, 2024). Literatürdeki bu tespitler, LightGBM algoritmasının genellikle daha büyük ölçekli veri yapılarında daha istikrarlı çalışabildiği yönündeki metodolojik çıkarımlarımızı desteklemektedir.

Sürece dâhil edilen bir diğer model olan XGBoost ise orta seviyede bir performans sergilemiş (RMSE: 1311.79, MAE: 616.05) ve hata metriklerinde Random Forest'in gerisinde kalmıştır. XGBoost algoritmasının tahmin hatalarını ardışık olarak düzeltmeye

alışan yapısının, İSG veri setindeki aykırı değere (outliers) ve yerel dalgalanmalara daha duyarlı bir tahmin yapısı sergilediđi değereendirilmektedir. alıřma sonucunda elde edilen bu genel performans hiyerarřisi; iř sađlıđı ve gvenliđi gibi nadir olayların ve yođun yıđılmaların bir arada bulunduđu karmařık veri setlerinde, bu alıřma kapsamında torbalama temelli algoritmaların artırma temelli algoritmalara kıyasla daha dengeli tahminler sunduđunu dřndrmektedir.

4.3. Veri Seti Yapısının Bulgulara Etkisi

alıřmada kullanılan 2016-2024 SGK veri setinin yapısal zellikleri, makine đrenimi modellerinin đrenme srecini ve genel tahmin hiyerarřisini dođrudan řekillendiren en temel faktrlerden biri olarak değereendirilmektedir. Veri seti incelendiđinde; milyonlarca kayıttan oluřan bir, iki, , drt ve beř gn ve zeri iř gremezlik vakalarının (ođunluk sınıfı), grece ok daha nadir rastlanan lml kaza vakalarına (azınlık sınıfı) kıyasla ařırı bir nicel yıđılma yarattıđı saptanmıřtır. oklu hedef deđiřkenli tahmin mimarisinde, Random Forest algoritmasının bu ařırı sınıf dengesizliđine (class imbalance) rađmen karar ađalarını bađımsız olarak eđiterek azınlık sınıfına ait lm eđilimlerini de tahmin yapısına daha dengeli biimde dhil edebildiđi grlmektedir.

İlgili makine đrenimi literatr incelendiđinde; gerek dnya verilerinde sıklıkla karřılařılan sınıf dengesizliđi probleminin, algoritmaların đrenme srecinde azınlık sınıfını ihmal ederek ođunluk sınıfına ađırlık veren tahminler retmesine neden olabildiđi ifade edilmektedir (Kendirkıran ve Dođan, 2024). Dengesiz veri setlerinde nadir olayların (rneđin mortalite oranlarının) ngrlebilmesi iin torbalama (bagging) temelli topluluk algoritmalarının, varyansı dřrerek ođunluk sınıfının baskınlıđını belirli lde dengeleyebildiđi belirtilmektedir. Literatrdeki bu kuramsal ereve, alıřmamızda milyonlarca hafif yaralanma vakasına karřılık sayıca az olan lm vakalarının Random Forest modelinde daha dengeli sonular vermesi bulgusuyla uyum gstermektedir.

Veri setinin tahmin performansına etki eden bir diđer yapısal zelliđi ise ierdiđi idari veri grlts ve belirsizliklerdir. Analize dhil edilen kaza trleri arasında, yz binlerce vakayı kapsayan "Kod 000: Tr Bilinmeyen/Belirtilmemiř" kayıtlarının bulunması, veri setinin yapısal olarak grltl (noisy) ve eksik tanımlanmıř alanlar barındırdıđını gstermektedir. Bu bađlamda, hataları ardıřık olarak dzeltmeye odaklanan artırma (boosting) algoritmalarından LightGBM ve XGBoost'un, verideki bu idari belirsizliklere ve

yığılmalara daha duyarlı bir yapı sergileyebildiği ve tahmin kararlılığında dalgalanmalara yol açabildiği düşünülmektedir.

Büyük veri kümelerinde eksik, belirsiz veya gürültülü idari kayıtların bulunmasının algoritmalar üzerindeki etkisini inceleyen çalışmalar değerlendirildiğinde; aşırı duyarlı modellerin bu tür veri problemlerinden olumsuz etkilenerek genelleme performansında düşüş yaşayabildiği vurgulanmaktadır (Gümüştas ve Çakmak Pehlivanlı, 2023). Doğal yollarla elde edilen ve hem sınıf dengesizliği hem de eksik veya belirsiz gözlem içeren yapıların, algoritmaları aşırı uyuma (overfitting) itebileceği raporlanmaktadır. Literatürde yer alan bu bulgular, çalışmamızda XGBoost ve LightGBM'in veri setindeki belirsiz kodlama yığılmalarına daha duyarlı sonuçlar üretebileceği öngörüsünü desteklemektedir. Ayrıca bu durum, ilgili algoritmaların hata oranlarının veri setinin yapısal özelliklerinden etkilenmiş olabileceğine ilişkin değerlendirmelerimizle de uyum göstermektedir.

Sonuç olarak; SGK veri setinin devasa hacmi, barındırdığı sınıf dengesizlikleri ve "Türü Bilinmeyen" gibi gürültü içeren kayıtları, algoritmaların performansının yalnızca matematiksel kapasitesinden değil, veri kusurlarına karşı dayanıklılığından (robustness) da etkilendiğini ortaya koymuştur. Elde edilen bulgular, iş sağlığı ve güvenliği alanındaki makine öğrenimi projeksiyonlarında veri setinin içsel doğasının, model performansını doğrudan yönlendiren bir parametre olarak değerlendirilmesi gerektiğine işaret etmektedir.

4.4. Modellerin Karşılaştırmalı Olarak Değerlendirilmesi

Çalışma kapsamında oluşturulan zaman serisi projeksiyonlarında, makine öğrenimi modellerinin performansı karşılaştırmalı olarak değerlendirildiğinde; Random Forest algoritmasının en düşük hata metriklerine (RMSE: 933.78, MAE: 387.813) ulaşarak veri setini en iyi temsil eden model olduğu saptanmıştır. Özellikle iş göremezlik süreleri ile ölüm vakaları arasındaki yapısal dengesizliğin ve idari kayıt hatalarının yoğun olduğu SGK veri setinde, Random Forest'ın torbalama (bagging) mimarisi sayesinde daha dengeli ve kararlı tahminler ürettiği değerlendirilmektedir.

İlgili makine öğrenimi literatürü incelendiğinde; torbalama temelli topluluk öğrenme algoritmalarının, karmaşık ve gürültülü (noisy) veri setlerinde birden fazla karar ağacının ortalamasını alarak genelleme yeteneğini artırdığı ifade edilmektedir. Hedef değişkenler arasında aşırı dengesiz dağılımların bulunduğu veri yapılarında, Random Forest gibi algoritmaların varyansı düşürerek daha dengeli sonuçlar ürettiği görülmektedir (Bilenler, 2021). Literatürdeki bu metodolojik çerçeve, çalışmamızda Random Forest modelinin

gürültülü İSG verilerinde en düşük hata oranlarına ulaşması bulgusuyla uyum göstermektedir.

Öte yandan, analiz sürecine dâhil edilen artırma (boosting) temelli algoritmaların hata metrikleri incelendiğinde; XGBoost (RMSE: 1311.79, MAE: 616.05) orta seviyede kalırken, LightGBM'in (RMSE: 1640.72, MAE: 818.59) karşılaştırmalı olarak en yüksek tahmin hatalarını ürettiği tespit edilmiştir. Bu algoritmaların, hataları ardışık olarak düzeltmeye odaklanan çalışma prensibinin, veri setindeki belirsiz kayıtlara ve aykırı değerlere (outliers) daha duyarlı bir yapı sergileyebildiği düşünülmektedir. Bu durumun, artırma temelli modellerin veri setindeki yapısal kusurlardan daha fazla etkilenmesine yol açmış olabileceği ve tahmin kararlılığında dalgalanmalara neden olduğu değerlendirilmektedir.

Artırma ve torbalama algoritmalarının çalışma mekanizmalarını inceleyen araştırmalar değerlendirildiğinde; XGBoost ve LightGBM gibi modellerin güçlü tahmin yeteneklerine sahip olmalarına rağmen, sırayla bir öncekinin hatasına göre ağırlıklandırma yapmalarının gürültülü veri setlerinde dezavantaj yaratabildiği raporlanmaktadır (Turan ve Polat, 2024). İlgili modellerin, hatalı tahminlere odaklanarak öğrenme süreçlerinde veri setindeki istisnai durumlara aşırı hassasiyet gösterebildikleri ve bu durumun model performansını düşürebildiği belirtilmektedir (Kızıltepe ve Gülbandılar, 2024). Literatürdeki bu bulgular, çalışmamızda artırma algoritmalarının SGK veri setinin içerdiği yapısal gürültülere karşı daha duyarlı sonuçlar üreterek hata oranlarını yükselttiği yönündeki değerlendirmelerimizi desteklemektedir.

Sonuç olarak, modellerin karşılaştırmalı performans hiyerarşisi; iş sağlığı ve güvenliği alanındaki geniş ölçekli ve çoklu hedef değişkenli veri setlerinde, algoritmaların veri kusurlarına karşı gösterdiği dayanıklılığın (robustness) tahmin başarısını doğrudan etkilediğini ortaya koymaktadır. Elde edilen bulgular, SGK verileri gibi sınıf dengesizliği ve idari belirsizlikler içeren yapılarda, bu çalışma kapsamında torbalama temelli modellerin artırma temelli modellere kıyasla daha dengeli bir tahmin çerçevesi sunduğunu düşündürmektedir.

4.5. Bulguların İş Sağlığı ve Güvenliği Açısından Değerlendirilmesi

Çalışma kapsamında 2025-2033 periyodu için elde edilen makine öğrenimi projeksiyonları İSG disiplini çerçevesinde değerlendirildiğinde; bir, iki, üç, dört gün ile beş gün ve üzeri iş göremezlikle sonuçlanan yaralanmaların ve ölümlü iş kazalarının istikrarlı

bir artış eğilimi göstereceği öngörülmektedir. Ortaya çıkan bu makro düzeydeki artış tablosu, mevcut çalışma ortamlarında kaza önleme stratejilerinin gözden geçirilmesi gerektiğine ve risklerin kaynağında kontrolüne ilişkin uygulamalarda geliştirilmesi gereken alanlar bulunduğu işaret etmektedir.

İlgili iş sağlığı ve güvenliği literatürü incelendiğinde; 6331 sayılı İş Sağlığı ve Güvenliği Kanunu'nun temel felsefesinin, kazalar yaşandıktan sonra devreye giren reaktif yaklaşımlar yerine, tehlikeleri henüz risk aşamasına gelmeden öngören proaktif bir sistematığı zorunlu kıldığı ifade edilmektedir (Kacı ve Taçgın, 2017). Literatürdeki bu yasal ve kuramsal çerçeve, elde edilen kaza projeksiyonları karşısında yapay zekâ destekli analizlerin İSG yönetim sistemlerinde proaktif karar destek süreçleri açısından önemli bir potansiyel taşıdığı yönündeki değerlendirmelerimizle uyum göstermektedir.

Araştırmanın kaza türleri bazındaki bulguları değerlendirildiğinde, Kod 000: Türü Bilinmeyen/Belirtilmemiş kategorisinde yer alan vakaların SGK bildirimleri içerisinde oransal olarak yüksek bir hacim kapladığı saptanmıştır. İş kazası bildirimlerinde kaza türünün belirsiz bırakılması, kaza kök nedenlerinin yeterince ayrıntılı biçimde sınıflandırılmadığına işaret etmektedir.

Kaza sebep teorilerini ve olay araştırma metodolojilerini inceleyen çalışmalar değerlendirildiğinde; kaza kök nedenlerinin tespit edilememesinin ve raporlama süreçlerindeki veri eksikliklerinin, Domino Teorisi bağlamında zincirin ilk halkası olan "yönetim denetimi eksikliğine" karşılık geldiği raporlanmaktadır (Özbucak Albar, 2024). Alan yazınındaki bu kuramsal tespit, çalışmamızda Kod 000 verilerindeki yüksek yığılmanın yalnızca veri kalitesiyle sınırlı olmayan, aynı zamanda İSG yönetim denetimindeki sistemsel gelişim ihtiyacını yansıttığını düşündürmektedir.

Öte yandan, çalışmadaki iş göremezlik sürelerini besleyen spesifik kaza türleri incelendiğinde; Kod 011: Yüzeysel Yaralanmalar ve Kod 032: Burkulmalar ve İncinmeler gibi şiddeti görece düşük ancak frekansı yüksek olayların tahmin eğrisinde üst sıralarda yer aldığı saptanmıştır. Ölümle sonuçlanmayan ancak doğrudan 1 ile 5 gün ve üzeri iş gücü kaybına neden olan bu yaralanma örüntüleri, işletmelerde kişisel koruyucu donanım kullanımı, ergonomik düzenlemeler ve günlük risk kontrol uygulamaları açısından geliştirilmesi gereken alanlar bulunduğunu düşündürmektedir.

Endüstriyel iş kazalarının sektörel analizini gerçekleştiren çalışmalar incelendiğinde; ölümle sonuçlanmayan ancak yüksek frekanslı tekrarlanan yaralanmaların, işletmelerde kronik iş gücü kayıplarına ve üretim kesintilerine bağlı gizli maliyetlere yol açtığı belirtilmektedir (Horozoğlu, 2017). Literatürdeki bu bulgular, çalışmamızın

projeksiyonlarında öne çıkan hafif ve orta şiddetli yaralanma yığılmalarının, İSG politikalarının planlanmasında yalnızca ölümlü vakaların değil, sık tekrarlanan günlük iş göremezlik kayıplarının da stratejik bir risk bileşeni olarak ele alınması gerektiğine işaret etmektedir.

4.6. Araştırmanın Sınırlılıkları

Bu araştırma, Türkiye genelinde iş kazası projeksiyonları için makine öğrenimi tekniklerini kullanan kapsamlı bir model sunsa da bulguların yorumlanmasında dikkate alınması gereken bazı bilimsel sınırlılıklar barındırmaktadır. Bu sınırlılıkların ilki, çalışmanın ana veri kaynağı olan SGK idari kayıtlarının yapısından kaynaklanmaktadır. Analiz edilen 2016-2024 dönemi verileri, yalnızca Sosyal Güvenlik Kurumu'na resmi olarak bildirilmiş ve kayıt altına alınmış vakaları kapsamaktadır. Bu durum, kayıt dışı istihdam edilen çalışanların uğradığı iş kazalarının ve bildirim süreçlerinde yaşanan aksaklıklar nedeniyle sisteme yansımayan olayların analiz dışında kalmasına neden olmuştur. Dolayısıyla, elde edilen projeksiyonların gerçek vaka düzeyini tam olarak yansıtamama ihtimali, araştırmanın kapsamsal sınırlılıklarından biri olarak değerlendirilmelidir.

İkinci temel sınırlılık, veri setindeki tanımlama ve kodlama belirsizlikleridir. "Kod 000: Türü Bilinmeyen/Belirtilmemiş" kategorisindeki vakaların yüksek oranı, modellerin kaza türleri özelindeki öğrenme sürecini doğrudan etkilemiştir. Ayrıca, iş kazası ve meslek hastalığına ilişkin bazı kayıtların sınıflandırma düzeyinde her zaman net ayrışmaması, analizlerin spesifik kaza odağındaki hassasiyetini belirli ölçüde sınırlandırmıştır. Makine öğrenimi algoritmalarının başarısının veri kalitesiyle doğrudan ilişkili olduğu göz önüne alındığında, idari kayıtlardaki bu tip nitel sınıflandırma belirsizlikleri, tahminlerin hata payı üzerinde etkili bir parametre olarak kabul edilmektedir.

Son olarak, projeksiyon dönemi olan 2025-2033 yılları için yapılan tahminler, 2016-2024 dönemindeki trendlerin ve yapısal koşulların sabit kalacağı varsayımına dayanmaktadır. Gelecekte gerçekleşebilecek radikal mevzuat değişiklikleri, ekonomik dalgalanmalar, küresel pandemiler veya teknolojik devrimlerin iş süreçlerinde yaratacağı ani değişimler, zaman serisi modellerinin öngörü kapasitesinin dışında kalan dışsal faktörlerdir. Modellerin yorumlanabilirliğinin sınırlı olması nedeniyle, tahminlerin matematiksel olarak tutarlı olmasına rağmen sosyo-ekonomik dinamiklerdeki beklenmedik kırılmaları tam olarak yansıtamaması, bu tür uzun vadeli projeksiyon çalışmalarının doğasında bulunan metodolojik bir kısıttır.

5. SONUÇ VE ÖNERİLER

5.1. Sonuç

Bu çalışmada, 2016-2024 yıllarına ait SGK iş kazası verileri temel alınarak, 2025-2033 dönemi için çoklu hedef değişkenli bir makine öğrenimi projeksiyon modeli geliştirilmiştir. Elde edilen bulgular, Türkiye genelindeki iş kazası vaka sayılarının ve buna bağlı gelişen iş göremezlik sürelerinin gelecek dokuz yıllık periyotta istikrarlı bir artış eğilimi içerisinde olacağını göstermektedir. Özellikle bir ila dört gün ile beş gün ve üzeri iş göremezlik kategorilerindeki yığılmalar, çalışma hayatında iş gücü kaybının yapısal bir sorun alanı olmaya devam edeceğine işaret etmektedir.

Metodolojik açıdan Random Forest, XGBoost ve LightGBM algoritmalarının karşılaştırmalı performansları incelendiğinde; Random Forest algoritmasının en düşük hata metriklerine ulaşarak veri setini karşılaştırmalı olarak en iyi temsil eden model olduğu görülmüştür. Torbalama (bagging) mimarisinin, SGK veri setindeki sınıf dengesizliği ve idari kayıt belirsizliklerine karşı artırma (boosting) temelli algoritmalarla kıyasla daha dengeli sonuçlar verdiği saptanmıştır. Bu durum, iş sağlığı ve güvenliği gibi gürültülü ve uç değerler barındıran büyük veri kümelerinde, modellerin yapısal dirençlerinin tahmin başarısında önemli bir rol oynadığını göstermektedir.

Cinsiyet ve vaka şiddeti bağlamındaki projeksiyonlar, hem yaralanmalı hem de ölümlü iş kazalarında erkek çalışanların sayısal ağırlığını koruduğunu, ancak toplam hacim içerisinde beş gün ve üzeri yaralanmaların baskın bir paya sahip olacağını ortaya koymaktadır. Ayrıca, Kod 011: Yüzeysel Yaralanmalar ve Kod 032: Burkulmalar ve İncinmeler gibi yüksek frekanslı vaka türlerinin tahmin eğrisindeki sürekliliği, ergonomik düzenlemeler ile proaktif risk yönetimi uygulamalarının önemini koruduğunu göstermektedir. Sonuç olarak bu araştırma; yapay zekâ destekli projeksiyonların, İSG politikalarının veri temelli biçimde desteklenmesinde analitik bir araç olarak değerlendirilebileceğini göstermiştir.

5.2. Araştırmanın Alana Katkıları

Bu araştırma, Türkiye'deki iş sağlığı ve güvenliği (İSG) literatürüne ve uygulama alanına çeşitli katkılar sunmaktadır. Çalışmanın başlıca katkılarından biri, geleneksel tek değişkenli tahmin yöntemlerinin ötesine geçerek çoklu hedef değişkenli (multi-target) bir makine öğrenimi mimarisini İSG verilerine entegre etmiş olmasıdır. Türkiye literatüründeki

mevcut çalışmaların büyük çoğunluğu kaza sayılarını toplam hacim üzerinden tahminlemeye odaklanırken; bu çalışma, vaka sayılarını cinsiyet, kaza türü ve iş göremezlik süreleri bazında aynı anda projekte ederek daha granüler ve çok boyutlu bir analiz çerçevesi sunmaktadır.

Metodolojik açıdan çalışma, torbalama (bagging) ve artırma (boosting) temelli ileri düzey algoritmaların (Random Forest, XGBoost, LightGBM) SGK idari kayıtları üzerindeki performans hiyerarşisini ortaya koyarak veri bilimi literatürüne de katkı sağlamaktadır. İSG verileri gibi sınıf dengesizliği ve gürültü içeren büyük veri kümelerinde hangi algoritmik yapının daha dirençli sonuçlar ürettiğinin saptanması, gelecekteki benzer çalışmalar açısından yöntemsel bir referans çerçevesi sunmaktadır. Ayrıca, 2016-2024 dönemini kapsayan geniş veri setinin işlenmesi ve 2033 yılına kadar uzanan uzun vadeli bir tahmin ufku sunulması, çalışmanın ampirik derinliğini ve zamansal kapsayıcılığını artırmıştır.

Uygulama sahası açısından ise araştırma, İSG profesyonelleri ve karar vericiler için proaktif yönetime geçişte analitik bir karar destek çerçevesi sunmaktadır. Özellikle, projeksiyonlarda vaka hacmi bakımından öne çıkan Kod 011 (Yüzeysel Yaralanmalar) ve Kod 032 (Burkulmalar ve İncinmeler) ile ciddi iş günü kayıplarının gelecek dönemdeki seyri üzerine sunulan öngörüler, işletmelerin ve politika yapıcıların kaynaklarını daha verimli kullanmalarına zemin hazırlamaktadır. Sonuç olarak bu çalışma; SGK bünyesindeki ulusal ölçekli idari kayıtların stratejik İSG politikalarının desteklenmesinde kullanılabilirliğine işaret etmekte ve veri temelli İSG yaklaşımının geliştirilmesine katkı sağlayabilecek bir çerçeve sunmaktadır.

5.3. Uygulamaya Yönelik Öneriler

Bu araştırma kapsamında elde edilen bulgular ve 2033 yılına kadar uzanan projeksiyon sonuçları doğrultusunda, Türkiye’deki iş sağlığı ve güvenliği (İSG) sisteminin geliştirilmesine katkı sağlayabilecek bazı uygulama önerileri aşağıda sunulmuştur.

5.3.1. Veri Yönetimi ve Dijital Kayıt Standartlarının İyileştirilmesi

Araştırmada saptanan “Kod 000: Türü Bilinmeyen/Belirtilmemiş” vakalarındaki yüksek yoğunluk, kaza kök neden analizlerinin sağlıklı yapılabilmesi önünde önemli bir kısıt oluşturmaktadır. Bu gerekçeyle, resmi iş kazası bildirim sistemlerinde “belirsiz” kategori kullanımının sınırlandırılması ve veri giriş alanlarının standardize edilmesi önerilmektedir.

Kayıtların veri kalitesinin artırılmasının, gelecekte geliştirilecek yapay zekâ modellerinin tahmin performansına katkı sağlayabileceği değerlendirilmektedir.

İş güvenliğinde kazaların önlenmesi, kök nedenlerin doğru tespit edilmesine ve neden-sonuç ilişkilerinin eksiksiz kurulmasına dayanmaktadır (Tunca ve Utlı, 2016). Ayrıca, Türkiye'deki iş kazaları ve işgünü kayıplarına yönelik veri analizlerinde sınıflandırma kalitesinin artırılması, risk değerlendirme süreçlerinin güvenilirliği açısından önemli görülmektedir (Özdemir, 2025).

5.3.2. Yüksek Frekanslı Yaralanmalara Yönelik Teknik ve Ergonomik Müdahaleler

Projeksiyon sonuçlarında vaka hacmi bakımından öne çıkan Kod 011 (Yüzeysel Yaralanmalar) ve Kod 032 (Burkulmalar ve İncinmeler) vakaları, işletmelerde ergonomik düzenlemeler ve günlük risk kontrolleri açısından geliştirilmesi gereken alanlar bulunduğunu düşündürmektedir. Bu doğrultuda, özellikle fiziksel zorlanmanın yoğun olduğu alanlarda ergonomik risk analizi süreçlerinin ve periyodik saha kontrollerinin önceliklendirilmesi önerilmektedir. Bu tür hedefe yönelik müdahalelerin, yüksek hacimli iş göremezlik sürelerinin azaltılmasına katkı sağlayabileceği öngörülmektedir.

İş kazası türleri ile geçici iş göremezlik süreleri arasındaki ilişkinin incelendiği çalışmalarda, sık karşılaşılan yaralanma tiplerine yönelik çalışma ortamı iyileştirmelerinin iş gücü kayıplarını belirgin şekilde düşürdüğü vurgulanmaktadır (Kandemir ve Şimşek, 2019). Ek olarak, farklı sektör uygulamalarında denetimli makine öğrenimi yaklaşımları kullanılarak elde edilen risk profilleri, iş kazalarının önlenmesinde alana özgü ergonomik ve teknik önlemlerin önemini desteklemektedir (Karabulut vd., 2024).

5.3.3. Yapay Zekâ Destekli Stratejik Karar Destek Mekanizmalarının Yapılandırılması

Bu çalışmada makine öğrenimi algoritmalarının sergilediği karşılaştırmalı tahmin performansı, söz konusu modellerin ulusal İSG politikalarında analitik bir araç olarak kullanılabilirliğine işaret etmektedir. Bu bağlamda, idari kayıtları analiz ederek riskli sektör veya dönemleri önceden saptayabilecek yapay zekâ destekli bir erken uyarı sistemi benzeri yapının değerlendirilmesi önerilmektedir. Veri temelli bir denetim yaklaşımının, sınırlı kamu kaynaklarının yüksek risk taşıyan alanlara yönlendirilmesine katkı sağlayacağı düşünülmektedir.

Zaman serisi tahminlemelerinde makine öğrenmesi yaklaşımlarının kullanılması, gelecekteki eğilimlerin öngörülmesini sağlayarak karar vericilere stratejik bir avantaj sunmaktadır (Doğan ve Büyükkör, 2022). Benzer şekilde, kaza tahmin modellerinin hibrit makine öğrenimi yapılarıyla sisteme entegre edilmesi, İSG yönetiminde tehlikelerin gerçekleşmeden önce fark edilmesini sağlayan temel araçlardan biri olarak değerlendirilmektedir (Koc vd., 2022).

5.3.4. Bildirim Kültürü ve Sosyal Güvenlik Farkındalığının Geliştirilmesi

Araştırmanın sınırlılıkları arasında belirtilen, resmi kayıtlara yansımayan vakaların da İSG sistemine dâhil edilebilmesi için tüm paydaşların raporlama sorumluluğu konusundaki farkındalığının artırılmasının yararlı olacağı değerlendirilmektedir. İş kazası bildirim süreçlerinin yalnızca yasal bir yükümlülük olarak değil, aynı zamanda proaktif iyileştirme için veri üreten bir mekanizma olarak görülmesini destekleyecek uygulamaların yaygınlaştırılması önerilmektedir.

İş sağlığı ve güvenliği kültürünün tesis edilmesinde, tüm paydaşların risk ve kaza bildirim süreçlerine aktif katılımı temel bir bileşen olarak öne çıkmaktadır (Karabal, 2021). Kazaların ve olayların doğru raporlanarak araştırılması, mevcut tehlikelerin analiz edilip gelecekteki benzer olayların önlenmesine yönelik kurumsal bir hafıza oluşturulmasını sağlamaktadır (Çalışma ve Sosyal Güvenlik Bakanlığı, 2025).

5.3.5. Gelecek Çalışmalar İçin Öneriler

Bu araştırma, SGK idari kayıtları üzerinden makine öğrenimi algoritmaları kullanılarak Türkiye genelindeki iş kazaları ve iş göremezlik süreleri için makro ölçekli bir projeksiyon çerçevesi sunmuştur. Elde edilen bulgular ve karşılaşılan metodolojik kısıtlar doğrultusunda, alanda çalışacak araştırmacılara yönelik çeşitli metodolojik ve tematik öneriler sunulmuştur.

İlk olarak, bu çalışmada Random Forest, XGBoost ve LightGBM gibi ağaç temelli topluluk algoritmaları kullanılmış ve karşılaştırmalı olarak anlamlı sonuçlar elde edilmiştir. Gelecek çalışmalarda, zaman serisi verilerindeki karmaşık ve doğrusal olmayan ilişkileri modelleme kapasitesi yüksek olan Uzun Kısa Süreli Bellek (LSTM), Geçitli Tekrarlayan Birim (GRU) veya Transformer tabanlı derin öğrenme (deep learning) mimarilerinin test edilmesinin, tahmin performansını daha ileri seviyelere taşıyabileceği değerlendirilmektedir.

İkinci olarak, araştırmada öne çıkan "Kod 000: Türü Bilinmeyen/Belirtilmemiş" kategorisinin yarattığı veri gürültüsünü aşabilmek adına, gelecek çalışmalarda kaza raporlarının serbest metin (free-text) kısımları üzerinde Doğal Dil İşleme (NLP) tekniklerinin kullanılması önerilmektedir. Buna ek olarak, ölümlü iş kazaları gibi azınlık sınıflarının tahmin gücünü artırmak amacıyla SMOTE (Sentetik Azınlık Aşırı Örneklemme Tekniği) veya ADASYN gibi gelişmiş veri dengeleme algoritmalarının veri setine dâhil edilmesi, yöntemsel çeşitliliğe katkı sunabilecektir.

Üçüncü bir araştırma yönü olarak, Türkiye genelindeki tüm iş kazalarını bütüncül bir yaklaşımla ele alan bu çalışmanın ötesine geçilerek sektörel ve bölgesel odaklı mikro analizlerin yapılması yararlı olacaktır. Gelecekteki araştırmaların, NACE kodları üzerinden inşaat, madencilik veya metal gibi kaza riskinin yapısal olarak yüksek olduğu spesifik sektörlerle odaklanması ve il bazlı coğrafi segmentasyonlar gerçekleştirmesi, yerel İSG politikalarının planlanması açısından daha granüler risk profilleri sunabilecektir.

Son olarak, mevcut projeksiyonlar geçmiş kaza verilerinin kendi içsel trendlerine dayanmaktadır. Gelecek projeksiyon çalışmalarında; sektörel istihdam oranları, makroekonomik göstergeler, iklim koşulları ve yıllık İSG denetim frekansları gibi dışsal değişkenlerin modellere entegre edilmesinin, tahmin algoritmalarının yorumlanabilirlik ve açıklayıcılık kapasitesini artırabileceği öngörülmektedir. Bu araştırmanın, yapay zekâ teknolojilerinin iş sağlığı ve güvenliği alanındaki stratejik kullanımına dair çok disiplinli gelecek çalışmalar için bir başlangıç çerçevesi sunduğu değerlendirilmektedir.

KAYNAKLAR

- Akaner, M. ve Özdemir, V. (2022). Yapay zeka kullanılarak faaliyet alanları tehlike sınıflarının belirlenmesi için örnek bir çalışma. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(1), 123-139. <https://doi.org/10.17341/gazimmfd.564803>
- Atalay, B. A. ve Zor, K. (2025). XGBoost (aşırı gradyan artırımı karar ağaçları) ile hidroelektrik enerji tahmini. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 40(1), 205-218. <https://doi.org/10.21605/cukurovaumfd.1666062>
- Ayan, B., Taşçı, S. ve Köksal, E. B. (2024). İş sağlığı ve güvenliği alanında kullanılan yapay zeka teknolojilerine ilişkin inceleme. *Çalışma İlişkileri Dergisi*, 15(2), 20-33.
- Azizoğlu, M. E. (2025). *Makine öğrenmesi algoritmaları ile Hakkâri Yüksekova Selahaddin Eyyubi Havalimanı doğalgaz tüketim miktarının tahmin edilmesi* [Yüksek lisans tezi, Haliç Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=960848>
- Bilenler, B. (2021). Sigorta hukuk verisi üzerinde karar ağacı ve rastgele orman algoritmalarının performans karşılaştırması. *21. Yüzyılda Fen ve Teknik*, 7(12), 25-36.
- Canbaz, S. ve İşsever, H. (2024). İş sağlığı. N. Bilir ve A. N. Yıldız (Ed.), 6. Bölüm / Chapter 6. İstanbul Üniversitesi. <https://doi.org/10.26650/B/LSB30LSB60.2024.032.006>
- Çabuk, M., Yücalar, F. ve Toçoğlu, M. A. (2025). Video oyunları kullanıcı yorumlarının makine öğrenmesi ile tahmini: Veri bilimi perspektifinden bir inceleme. *MTÜ Sosyal ve Beşeri Bilimler Dergisi*, 6(1), 112-128. <https://dergipark.org.tr/tr/pub/mtusbbder/article/1666802>
- Çalışma ve Sosyal Güvenlik Bakanlığı. (2025). *Kazaları ve olayları araştırma el kitabı*. İş Sağlığı ve Güvenliği Genel Müdürlüğü Yayınları. <https://www.csgeb.gov.tr/Media/ratbskwr/kazalar%C4%B1-ve-olaylar%C4%B1-ara%C5%9Ft%C4%B1rma-el-kitab%C4%B1.pdf/> (22 Ocak 2026 tarihinde erişildi).
- Doğan, S. ve Büyükkör, Y. (2022). Makine öğrenmesi ile finansal zaman serisi tahminleme. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 24(3), 1205-1230. <https://doi.org/10.26745/ahbvuibfd.1191080>

- Ergül, B. (2018). Türkiye'deki iş kazalarının zaman serisi analiz teknikleri ve yapay sinir ağları tekniği ile incelenmesi. *Karaelmas İş Sağlığı ve Güvenliği Dergisi*, 2(2), 63-74. <https://doi.org/10.33720/kisgd.395338>
- Eşidir, K. A. (2025). Makine öğrenimi modelleri ile yetişkin eğitimi analizi: Modellerin karşılaştırmalı performansı. *Elektronik Sosyal Bilimler Dergisi*, 24(2), 946-964. <https://doi.org/10.17755/esosder.1589887>
- Gökalp, Ö. M. (2022). Makine öğrenmesi. *Gazi Bilişim Enstitüsü Adli Bilişim Bölümü Çalışmaları*, 1-14.
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15. <https://doi.org/10.31590/ejosat.530347>
- Gümüştaş, E. ve Çakmak Pehlivanlı, A. (2023). Dengesiz sınıf dağılımında kayıp gözlem sorunu için topluluk öğrenmesi sonuçlarının istatistiksel değerlendirmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 27(2), 181-190. <https://doi.org/10.19113/sdufenbed.1090596>
- Horozoğlu, K. (2017). İş kazalarının iş sağlığı ve güvenliği açısından analizi. *Karabük Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(1), 265-281.
- İlgin, M. C. ve Timuralp, Ç. (2024). Türkiye’de 2013-2023 yılları arasında makine sektöründe yaşanan iş kazalarının maliyet analizi. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 32(3), 1537-1546. <https://doi.org/10.31796/ogummf.1550211>
- Kacı, E. ve Taçgın, E. (2017). 6331 sayılı İş Sağlığı ve Güvenliği Kanunu kapsamında proaktif yaklaşım üzerine risk değerlendirme ve bazı öneriler. *Marmara Sosyal Araştırmalar Dergisi*, (12), 1-16.
- Kandemir, A. Ş. ve Şimşek, M. (2019). Geçici iş göremezlik süresi, cinsiyet, çalışılan ortam ve iş kazası türleri etkileşimlerinin istatistiksel analizi. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*, 7(1), 239-245. <https://doi.org/10.18506/anemon.421997>
- Karabal, H. (2021). İş sağlığı ve iş güvenliği. *Uluslararası Batı Karadeniz Sosyal ve Beşerî Bilimler Dergisi*, 5(1), 1-21.
- Karabulut, A., Baran, M. ve Eraslan, E. (2024). Denetimli makine öğrenme algoritmalarıyla iş kazası ve meslek hastalıklarının önlenmesi: Farklı sektör uygulamaları. *Journal of Turkish Operations Management*, 8(1), 39-59. <https://doi.org/10.56554/jtom.1245965>

- Karaahmetoğlu, A. (2021). Sosyal güvenlik sisteminde iş kazasına uğrayan sigortalıya ve sigortalının ölümü halinde hak sahiplerine tanınan haklar. *Sosyal Siyaset Konferansları Dergisi*, 81, 213-244. <https://doi.org/10.26650/jspc.2021.81.876998>
- Karaahmetoğlu, A. (2022). Türkiye Cumhuriyeti'nde iş sağlığı ve güvenliği sisteminin temel dinamikleri ve uygulama alanı. *Uluslararası Batı Karadeniz Sosyal ve Beşerî Bilimler Dergisi*, 6(2), 123-147. <https://doi.org/10.46452/baksoder.1136795>
- Karakaya Özkan, E. ve Ulaş, H. B. (2023). Türkiye metal sektöründe yaşanan iş kazalarının rassal orman algoritmasıyla tahminlenmesi. *Journal of the Institute of Science and Technology*, 13(3), 1983-1997. <https://doi.org/10.21597/jist.1285239>
- Kendirkıran, G. ve Doğan, S. (2024). Makine öğrenimi teknikleri ile kredi risk tahmininde yeniden örnekleme yöntemlerinin karşılaştırılması. *Söke İşletme Fakültesi Dergisi*, 1(2), 48-60.
- Kalkış, İ. (2013). İş sağlığı ve güvenliği'nde yeni bir dönem: 6331 sayılı İş Sağlığı ve Güvenliği Kanunu (İSGK). *ISGUC The Journal of Industrial Relations and Human Resources*, 15(1), 17-42.
- Kızıltepe, R. ve Gülbandır, E. (2024). Keylogger ve gizlilik: Makine öğrenimi modellerinin performansı üzerine bir karşılaştırma. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 1188-1200.
- Koc, K., Ekmekcioğlu, Ö. ve Gurgun, A. P. (2022). Accident prediction in construction using hybrid wavelet-machine learning. *Automation in Construction*, 133, 103987. <https://doi.org/10.1016/j.autcon.2021.103987>
- Köse, N. ve Ersöz, F. (2020). Veri madenciliğinde karar ağacı algoritmaları ile demir çelik endüstrisinde iş kazaları üzerine bir uygulama. *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 397-407. <https://doi.org/10.31590/ejosat.843387>
- Künteş, Ö. ve Bezek Güre, Ö. (2024). Yapay Sinir Ağı Kullanılarak Petrol Sektöründe Yaşanan İş Kazalarının İncelenmesi. *Journal of the Institute of Science and Technology*, 14(3), 1000-1012. <https://doi.org/10.21597/jist.1502928>
- Özbucak Albar, B. (2024). İş kazalarının önlenmesinde kaza sebep teorilerinin önemi. *EJONS International Journal on Mathematic, Engineering and Natural Sciences*, 8(1), 174-182. <https://doi.org/10.5281/zenodo.10814620>
- Özdemir, M. (2025). Türkiye'deki iş kazaları, meslek hastalıkları ve işgünü kayıplarının cinsiyet temelli analizi. *Lokman Hekim Tıp Tarihi ve Folklorik Tıp Dergisi*, 15(1), 349-361. <https://doi.org/10.31020/mutftd.1585541>

- Şen, M. (2015). İş sağlığı ve güvenliği kavramı, tarihsel gelişimi ve dayanakları. *Melikşah Üniversitesi Hukuk Fakültesi Dergisi*, 4(1), 117-142.
- Şengöz, T. E. ve Bozkurt, Y. (2025). İş sağlığı ve güvenliği kapsamında sektörel iş kazalarının yapay zekâ teknolojileri ve uzman sistem uygulamaları yönünden incelenmesi. *Sürdürülebilir Mühendislik Uygulamaları ve Teknolojik Gelişmeler Dergisi*, 8(1), 17-44. <https://doi.org/10.51764/smutgd.1678632>
- Şimşek, F. F. (2024). Hızlandırılmış makine öğrenmesi algoritmaları ile tarım parseli tabanlı ürün desen sınıflandırması. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 29(1), 314-330. <https://doi.org/10.53433/yyufbed.1416820>
- Sosyal Güvenlik Kurumu. (2024). *İş kazası ve meslek hastalığı istatistikleri (2016-2024 dönemi)*. T.C. Çalışma ve Sosyal Güvenlik Bakanlığı. <https://www.sgk.gov.tr/Istatistik/Yillik/fcd5e59b-6af9-4d90-a451-ee7500eb1cb4/> (18 Aralık 2025 tarihinde erişildi).
- Tokmak, M. (2023). XGBoost algoritması ile ikili parçacık sürü optimizasyonu öznetelik seçme tabanlı jar kötü amaçlı yazılımlarının tespiti. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 10(1), 140-152. <https://doi.org/10.35193/bseufbd.1194460>
- Tunca, F. ve Utlı, Z. (2016). İş güvenliğinde kök, neden-sonuç ilişkisi. *İstanbul Aydın Üniversitesi Dergisi*, 8(31), 1-14.
- Turan, A. K. ve Polat, H. (2024). Yarı denetimli makine öğrenmesi yöntemini kullanarak müzik türlerinin tespiti. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 12(1), 92-107.
- Yağımlı, M. ve İzci, F. (2017). Türkiye’de makine ve teçhizatı hariç fabrikasyon metal ürünleri imalatı sektöründe yaşanan iş kazaları ve ölümlü iş kazası sayılarının tahmini. *Karaelmas İş Sağlığı ve Güvenliği Dergisi*, 1(1), 1-15.
- Yavuz, A. A., Ergül, B. ve Aşık, E. G. (2021). Trafik kazalarının makine öğrenmesi yöntemleri kullanılarak değerlendirilmesi. *International Journal of Engineering Research and Development*, 13(1), 66-73.
- Yılmaz, H. (2014). *Random Forests yönteminde kayıp veri probleminin incelenmesi ve sağlık alanında bir uygulama* [Yüksek lisans tezi, Eskişehir Osmangazi Üniversitesi]. YÖK Ulusal Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=352861>
- Zilyas, D. ve Yılmaz, A. (2023). Makine öğrenmesi yöntemleri ile eğitim başarısının tahmini modeli. *Dicle University Journal of Engineering*, 14(3), 437-447. <https://doi.org/10.24012/dumf.1322273>