

MEHMET YILDIRIM

KOCAELİ SAĞLIK VE TEKNOLOJİ ÜNİVERSİTESİ

KOCAELİ 2025

İŞ SAĞLIĞI VE GÜVENLİĞİ KAPSAMINDA YAPAY ZEKÂ  
DESTEKLİ GENEL RİSK YÖNETİMİ SİSTEMİ TASARIMI  
VE UYGULAMASI

KOCAELİ SAĞLIK VE TEKNOLOJİ ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEHMET YILDIRIM

DANIŞMAN

DR. ÖĞRETİM ÜYESİ FATMA DAĞDELEN

YÜKSEK LİSANS TEZİ  
İŞ SAĞLIĞI VE GÜVENLİĞİ ANA BİLİM DALI  
İŞ SAĞLIĞI VE GÜVENLİĞİ TEZLİ YÜKSEK LİSANS  
PROGRAMI

KOCAELİ 2025

**İŞ SAĞLIĞI VE GÜVENLİĞİ KAPSAMINDA YAPAY ZEKÂ DESTEKLİ GENEL  
RİSK YÖNETİMİ SİSTEMİ TASARIMI VE UYGULAMASI**

KOCAELİ SAĞLIK VE TEKNOLOJİ ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEHMET YILDIRIM

DANIŞMAN

DR. ÖĞRETİM ÜYESİ FATMA DAĞDELEN

YÜKSEK LİSANS TEZİ

İŞ SAĞLIĞI VE GÜVENLİĞİ ANA BİLİM DALI

İŞ SAĞLIĞI VE GÜVENLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

KOCAELİ 2025

## Onay Sayfası

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

Doç. Dr. Burak GÖKALP  
Enstitü Müdürü

Bu tezin Kocaeli Sağlık ve Teknoloji Üniversitesi, İş Sağlığı Ve Güvenliği Anabilim Dalında Yüksek Lisans derecesinin tüm gerekliliklerini karşıladığını onaylıyorum.

Dr. Öğr. Üyesi Ahmet ŞEN  
Bölüm Başkanı

Mehmet YILDIRIM tarafından teslim edilen İŞ SAĞLIĞI VE GÜVENLİĞİ KAPSAMINDA YAPAY ZEKÂ DESTEKLİ GENEL RİSK YÖNETİMİ SİSTEMİ TASARIMI VE UYGULAMASI başlıklı bu tezin kapsam ve kalite bakımından Yüksek Lisans derecesi için yeterli olduğunu değerlendirmektedir.

Dr. Öğr. Üyesi Fatma DAĞDELEN  
Danışman

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

Prof. Dr. Ali Talip AKPINAR

İşletme Fakültesi, Kocaeli Üniversitesi

Dr. Öğretim Üyesi Fatma DAĞDELEN

Eczacılık Fakültesi, Kocaeli Sağlık ve Teknoloji Üniversitesi

Dr. Öğretim Üyesi Ahmet ŞEN

İş Sağlığı ve Güvenliği Programı, Kocaeli Sağlık ve Teknoloji Üniversitesi

Doç. Dr. Derya DEMİRDİZEN

Ali Rıza Veziroğlu Meslek Yüksekokulu, Kocaeli Üniversitesi

Dr. Öğretim Üyesi Seval ÇINAR

Eczacılık Fakültesi, Kocaeli Sağlık ve Teknoloji Üniversitesi

**Tarih: 17.06.2025**

## **Orijinallik Sayfası**

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

MEHMET YILDIRIM

İMZA

## ÖZ

# İŞ SAĞLIĞI VE GÜVENLİĞİ KAPSAMINDA YAPAY ZEKÂ DESTEKLİ GENEL RİSK YÖNETİMİ SİSTEMİ TASARIMI VE UYGULAMASI

YILDIRIM, Mehmet

Yüksek Lisans, İş Sağlığı ve Güvenliği Anabilim Dalı

Tez Yöneticisi: Dr. Öğretim Üyesi Fatma DAĞDELEN

Haziran 2025, 101 sayfa

Bu tez çalışmasında, İş Sağlığı ve Güvenliği (İSG) alanında farklı sektörlerde karşılaşılabilecek fiziksel, kimyasal, biyolojik, ergonomik ve psikososyal riskleri değerlendirebilen yapay zekâ (YZ) destekli bir risk yönetim modeli geliştirilmiştir. Geliştirilen risk yönetim modeli ile geleneksel risk değerlendirme yöntemlerinin sınırlılıklarının aşılmasıyla daha dinamik, açıklanabilir ve duruma özgü bir karar destek mekanizmasının oluşturulması hedeflenmiştir. Simüle veri setiyle eğitilen bu modelde, karar ağacı tabanlı topluluk algoritmaları kullanılmış; XGBoost algoritması %88 doğruluk ve 0,92 AUC skoru ile yüksek sınıflandırma başarısı göstermiştir. Random Forest algoritması ise benzer doğruluk düzeyine ek olarak özellik önem düzeylerini belirleyerek modelin yorumlanabilirliğini artırmıştır. Model, genel risk sınıflandırması yapmakla birlikte, her bir gözlem için sürekli ve nümerik olasılık skorları üreterek daha hassas ve önceliklendirilebilir analiz imkânı sunmuştur. Eğitim ve hiperparametre optimizasyon süreçleri Google Colab platformunda, yerel sistemlere kıyasla 3 ila 6 kat daha hızlı tamamlanmış; model, cron tabanlı betiklerle periyodik olarak güncellenebilir biçimde yapılandırılmıştır. Geliştirilen model, Fine–Kinney ve 5×5 risk matrisi gibi klasik yöntemlerle karşılaştırıldığında, veri temelli analiz kapasitesiyle daha yüksek çözünürlükte değerlendirmeler yapabilmış; risk nedenlerini daha açık biçimde ortaya koyarak önleyici stratejilerin etkinliğini artırmıştır. Ayrıca, geleneksel yöntemlerle çelişmeyen, onları tamamlayıcı nitelikte tasarlanan hibrit yapısıyla yasal uyum korunmuş; İSG süreçlerine öngörü, esneklik ve duyarlılık kazandırılmıştır. Sonuç olarak, bu çalışma kapsamında geliştirilen YZ tabanlı İSG risk değerlendirme modeli; açıklanabilirlik, esneklik ve sektörel uyarlanabilirlik gibi nitelikleriyle dijital dönüşüm sürecine katkı sağlayan, öğrenilebilir ve sürdürülebilir bir karar destek sistemi olarak literatüre katkı sunmaktadır.

**Anahtar Kelimeler:** İş Sağlığı ve Güvenliği, Yapay Zekâ, Risk Değerlendirmesi, Makine Öğrenmesi, Karar Destek Sistemi

## ABSTRACT

### DESIGN AND IMPLEMENTATION OF AN ARTIFICIAL INTELLIGENCE-SUPPORTED GENERAL RISK MANAGEMENT SYSTEM WITHIN THE SCOPE OF OCCUPATIONAL HEALTH AND SAFETY

YILDIRIM, Mehmet

Master's Thesis, Department of Occupational Health and Safety

Thesis Supervisor: Asst. Prof. Dr. Fatma DAĞDELEN

June 2025, 101 pages

This thesis presents the development of an artificial intelligence (AI)-based risk management model capable of evaluating physical, chemical, biological, ergonomic, and psychosocial hazards across various sectors within the domain of Occupational Health and Safety (OHS). The proposed model aims to overcome the limitations of traditional risk assessment methods by delivering a more dynamic, interpretable, and context-specific decision support mechanism. Trained on a simulated dataset, the model employs ensemble tree-based algorithms, notably the XGBoost classifier, which achieved a high classification performance with an accuracy of 88% and an AUC score of 0.92. Complementarily, the Random Forest algorithm provided comparable accuracy while enhancing model interpretability through feature importance analysis. Beyond categorical risk classification, the model generates continuous and numerical probability scores for each observation, enabling a more precise and prioritized risk evaluation. Training and hyperparameter optimization processes were conducted on the Google Colab platform, resulting in a 3 to 6-fold acceleration compared to local systems. Furthermore, the model architecture incorporates cron-based scripting for periodic updates, ensuring adaptability and sustainability in dynamic workplace environments. Compared to classical methods such as Fine–Kinney and the 5×5 risk matrix, the AI-driven model offers higher-resolution, data-driven analyses that more transparently elucidate risk causality and enhance the efficacy of preventive strategies. Designed as a hybrid system that complements rather than conflicts with conventional approaches, the model maintains regulatory compliance while introducing foresight, flexibility, and sensitivity to OHS management processes. In summary, the developed AI-supported OHS risk assessment model, characterized by interpretability, flexibility, and sectoral adaptability, contributes to digital transformation initiatives as a learnable and sustainable decision support system.

**Keywords:** Occupational Health and Safety, Artificial Intelligence, Risk Assessment, Machine Learning, Decision Support System

## İÇİNDEKİLER

|                                                                        |      |
|------------------------------------------------------------------------|------|
| ÖZ.....                                                                | iii  |
| ABSTRACT.....                                                          | iv   |
| İÇİNDEKİLER.....                                                       | v    |
| TABLO LİSTESİ.....                                                     | vii  |
| ŞEKİL LİSTESİ.....                                                     | viii |
| SEMBOL/KISALTMA LİSTESİ.....                                           | ix   |
| TEŞEKKÜR.....                                                          | xii  |
| GİRİŞ.....                                                             | 1    |
| 1 TEZİN AMACI, KATKISI VE İÇERİĞİ.....                                 | 2    |
| 1.1 Tezin Amacı.....                                                   | 2    |
| 1.2 Literatüre Katkısı.....                                            | 3    |
| 1.3 Problem Durumu ve Araştırma Soruları.....                          | 4    |
| 1.4 Araştırmanın Kapsamı ve Sınırlılıkları.....                        | 5    |
| 2. KURAMSAL TEMELLER.....                                              | 6    |
| 2.1 İş Sağlığı ve Güvenliği Kavramı.....                               | 6    |
| 2.2 Risk Yönetimi ve Risk Değerlendirme Süreçleri.....                 | 9    |
| 2.2.1 Klasik/Statik Risk Matrisleri.....                               | 9    |
| 2.2.2 REDECA Modeli ve Dinamik Yaklaşım.....                           | 10   |
| 2.2.3 Algoritmik Tehlikeler ve Psiko-Sosyal Riskler.....               | 11   |
| 2.2.4 Dinamik Risk Matrisi Parametre Seti.....                         | 11   |
| 2.3 YZ Temelleri ve MÖ Yaklaşımları.....                               | 12   |
| 2.4 İş Sağlığı ve Güvenliğinde YZ Uygulamaları.....                    | 15   |
| 2.5 Literatürde Yer Alan İSG'ye Yönelik Yapay Zeka Uygulamaları.....   | 18   |
| 2.5.1 Kazaların MÖ ile Öngörülmesi ve Risk Analizi.....                | 19   |
| 2.5.2 Tehlikeli Durum ve Davranışların Görüntü İşleme ile Tespiti..... | 20   |
| 2.5.3 Sensör Verileri ve IoT Tabanlı İSG Uygulamaları.....             | 21   |
| 2.5.4 İşbirlikçi Robotik ve Diğer Uygulamalarda Güvenlik.....          | 22   |
| 2.5.5 Literatürdeki Boşluklar ve Bu Çalışmanın Yeri.....               | 23   |
| 3. GEREÇ ve YÖNTEM.....                                                | 25   |
| 3.1 Araştırma Modeli ve Yaklaşımı.....                                 | 25   |
| 3.2 Veri Kaynakları ve Veri Toplama Süreci.....                        | 29   |
| 3.3 Geliştirilen YZ Modeli.....                                        | 32   |
| 3.4 Kullanılan Algoritmalar.....                                       | 34   |

|                                                                                                       |    |
|-------------------------------------------------------------------------------------------------------|----|
| 3.4.1 Algoritma Tanıtımları.....                                                                      | 34 |
| 3.4.2 Hiperparametre Optimizasyonu .....                                                              | 39 |
| 3.5 Performans Ölçütleri ve Doğrulama Yöntemi .....                                                   | 41 |
| 4. BULGULAR VE TARTIŞMA .....                                                                         | 46 |
| 4.1 Uygulama Ortamı ve Senaryolar.....                                                                | 46 |
| 4.2 Elde Edilen Risk Skorları ve Sınıflandırmalar.....                                                | 47 |
| 4.3 Modelin Performans Analizi .....                                                                  | 48 |
| 4.4 Geliştirilen Modelin Geleneksel Yöntemlerle Karşılaştırılması .....                               | 52 |
| 4.4.1 Karşılaştırmalı Analizin Temeli.....                                                            | 52 |
| 4.4.2 Uygulamalı Senaryo Kıyaslaması .....                                                            | 53 |
| 4.4.3 Yerel ve Bulut Tabanlı Uygulama Performanslarının Karşılaştırılması .....                       | 55 |
| 4.4.4 Avantaj ve Sınırlılıkların Karşılaştırmalı Değerlendirmesi .....                                | 56 |
| 4.4.5 Önerilen Entegrasyon.....                                                                       | 57 |
| 5. SONUÇLAR VE ÖNERİLER.....                                                                          | 59 |
| KAYNAKÇA.....                                                                                         | 62 |
| EKLER.....                                                                                            | 68 |
| EK A – Python Kodları (riskanaliz.py) .....                                                           | 68 |
| EK B – Model Eğitimi, ROC Analizleri ve Kod Çıktıları (Riskanaliz.ipynb ve Riskanaliz.pdf).....       | 70 |
| EK C – Web Arayüzü Kodu ve Uygulama Görünümü (Yapay Zekâ Destekli İSG Risk Yönetimi).....             | 81 |
| EK D – Tahmin Sonuçları Arayüzü, Görsel Çıktılar ve Açıklamalı Kod (Risk Tahmin Sonuçları.html) ..... | 82 |
| ÖZGEÇMİŞ .....                                                                                        | 85 |

## TABLO LİSTESİ

|                                                                                                                                             |    |
|---------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tablo 3.1 – Simülasyon Tabanlı İSG Veri Kümesinden Örnek Kayıtlar.....                                                                      | 30 |
| Tablo 4.1 Çalışan profiline göre model tarafından tahmin edilen risk skorları ve karşılık gelen risk seviyeleri .....                       | 48 |
| Tablo 4.2 10-fold çapraz doğrulama yöntemi ile elde edilen Random Forest ve XGBoost algoritmalarına ait ortalama performans metrikleri..... | 49 |
| Tablo 4.3 Uygulamalı senaryo için farklı risk değerlendirme yöntemlerinin karşılaştırılması .....                                           | 54 |
| Tablo 4.4 Yerel sistem ile Google Colab ortamının işlenme süresi ve optimizasyon kapasitesi açısından karşılaştırılması.....                | 56 |
| Tablo 4.5 Yerel CPU ve Google Colab GPU'nun hiperparametre tarama süreleri bakımından karşılaştırılması.....                                | 56 |
| Tablo 4.6. Yapay zekâ tabanlı ve geleneksel risk değerlendirme yöntemlerinin karşılaştırmalı analizi.....                                   | 57 |

## ŞEKİL LİSTESİ

|                                                                                      |    |
|--------------------------------------------------------------------------------------|----|
| Şekil 3.1 Model eğitim–test diyagramı (CRISP-DM adımları).....                       | 28 |
| Şekil 4.1 Random Forest algoritması ile elde edilen özellik önem skoru grafiği ..... | 50 |
| Şekil 4.2 XGBoost algoritması ile hesaplanan ağırlıklı özellik önem düzeyleri.....   | 51 |
| Şekil 4.3 XGBoost algoritması ile elde edilen özellik önem skoru grafiği .....       | 52 |

## SEMBOL/KISALTMA LİSTESİ

|         |                                                                                                            |
|---------|------------------------------------------------------------------------------------------------------------|
| AI      | Artificial Intelligence (Yapay Zekâ)                                                                       |
| ANN     | Artificial Neural Network (Yapay Sinir Ağı)                                                                |
| SVM     | Support Vector Machines (Destek Vektör Makineleri)                                                         |
| FMEA    | Failure Mode and Effects Analysis (Hata Türü ve Etkileri Analizi)                                          |
| PHA     | Preliminary Hazard Analysis (Ön Tehlike Analizi)                                                           |
| SHAP    | SHapley Additive exPlanations (SHapley Katkı Açıklamaları)                                                 |
| LIME    | Local Interpretable Model-Agnostic Explanations (Yerel Yorumlanabilir Modelden Bağımsız Açıklamalar)       |
| IoT     | Internet of Things (Nesnelerin İnterneti)                                                                  |
| OSHA    | Occupational Safety and Health Administration (İş Sağlığı ve Güvenliği İdaresi – ABD)                      |
| HSE     | Health and Safety Executive (Birleşik Krallık Sağlık ve Güvenlik İdaresi)                                  |
| EASE    | Estimation and Assessment of Substance Exposure (Kimyasal Maruziyetin Tahmini ve Değerlendirme Sistemi)    |
| RF      | Random Forest                                                                                              |
| XGBoost | Extreme Gradient Boosting (Aşırı Dereceli Artırmalı Öğrenme Algoritması)                                   |
| kNN     | k-Nearest Neighbors (k-En Yakın Komşu Algoritması)                                                         |
| AUC     | Area Under Curve (Eğri Altı Alan; sınıflandırma modellerinin performansını ölçmekte kullanılan bir metrik) |
| Optuna  | Optimization Framework for Hyperparameter Tuning (Hiperparametre Ayarlama Optimizasyon Çerçevesi)          |
| YOLOX   | You Only Look Once X (Tek Seferde Nesne Tanıma – X Versiyonu)                                              |
| mAP     | mean Average Precision (Ortalama Ortalama Doğruluk)                                                        |
| LSTM    | Long Short-Term Memory (Uzun Kısa Süreli Bellek Ağı)                                                       |

|                  |                                                                                                       |
|------------------|-------------------------------------------------------------------------------------------------------|
| WTD              | Wavelet Threshold Denoising (Dalgacık Eşikleme ile Gürültü Giderme)                                   |
| PSR              | Phase Space Reconstruction (Faz Uzayı Yeniden Yapılandırma)                                           |
| MAE              | Mean Absolute Error (Ortalama Mutlak Hata)                                                            |
| RMSE             | Root Mean Squared Error (Kök Ortalama Kare Hatası)                                                    |
| ISO 45001        | Occupational Health and Safety Management Systems (İş Sağlığı ve Güvenliği Yönetim Sistemi Standardı) |
| ISO/TS 15066     | ISO Technical Specification 15066 (İşbirlikçi Robotlar için Teknik Şartname)                          |
| XAI              | Explainable Artificial Intelligence (Açıklanabilir Yapay Zekâ)                                        |
| CPU              | Central Processing Unit (Merkezi İşlem Birimi)                                                        |
| GPU              | Graphics Processing Unit (Grafik İşlem Birimi)                                                        |
| Tesla T4 / P100  | Tesla GPU Models (NVIDIA Gelişmiş GPU Modelleri)                                                      |
| GridSearchCV     | Grid Search Optimization (Izgara Arama ile Hiperparametre Ayarlama)                                   |
| 10-Fold CV       | 10-Fold Cross Validation (10 Katlı Çapraz Doğrulama)                                                  |
| Colab Notebook   | Google Colaboratory Notebook (Google Tabanlı Kod Ortamı)                                              |
| cron             | Zamanlanmış Görev Yürütücüsü                                                                          |
| S                | Severity (Şiddet)                                                                                     |
| F                | Frequency (Maruz Kalma Sıklığı)                                                                       |
| L                | Likelihood (Olasılık)                                                                                 |
| R                | Risk Score (Risk Puanı)                                                                               |
| NPV              | Negative Predictive Value (Negatif Öngörü Değeri)                                                     |
| Confusion Matrix | Confusion Matrix (Karmaşıklık Matrisi)                                                                |
| CRISP-DM         | Cross-Industry Standard Process for Data Mining (Sektörler Arası Veri Madenciliği Süreci Standardı)   |
| KVKK             | Kişisel Verilerin Korunması Kanunu                                                                    |
| GDPR             | General Data Protection Regulation (Genel Veri Koruma Tüzüğü – Avrupa Birliği)                        |
| IMU              | Inertial Measurement Unit (Ataletsel Ölçüm Birimi)                                                    |

Faster R-CNN

Faster Region-based Convolutional Neural Network Hızlı Bölge  
Tabanlı Evrişimli Sinir Ağı

İSG

İş Sağlığı ve Güvenliği



## TEŞEKKÜR

Tez çalışmam süresince bilgi birikimi, yönlendirmeleri ve kıymetli katkılarıyla bana rehberlik eden tez danışmanım Dr. Öğr. Üyesi Fatma DAĞDELEN'e teşekkürlerimi sunarım.

Ayrıca tez jürisinde yer alarak değerlendirmeleriyle çalışmama katkı sağlayan Prof. Dr. Ali Talip AKPINAR'a ve Dr. Öğr. Üyesi Ahmet ŞEN'e teşekkür ederim.

Son olarak, araştırmamı yürüttüğüm süreçte bana anlayış gösteren oğlum Muhammed Yusuf YILDIRIM'a, kızım Zeyneb Betül YILDIRIM'a ve her aşamada sabır ve desteğini esirgemeyen eşim Ayşenur YILDIRIM'a şükranlarımı sunarım.

Mehmet YILDIRIM

## GİRİŞ

İş sağlığı ve güvenliği (İSG), çalışanların işyerinde sağlıklı, güvenli ve insana yakışır koşullarda çalışmasını sağlamayı amaçlayan sistemli bir disiplindir. Bu alanın temel hedefi, iş kazalarını ve meslek hastalıklarını önleyerek hem çalışanların sağlığını korumak hem de iş verimliliğini artırmaktır.

Sanayileşmenin hızlanması, çalışma alanlarının çeşitlenmesi ve teknolojinin iş hayatına daha fazla entegre olmasıyla birlikte işyerlerinde karşılaşılan tehlike ve risklerin sayısı ve çeşitliliği de artmıştır. Artık sadece fiziksel yaralanmalar değil, kimyasal maruziyetler, psikososyal sorunlar, ergonomik problemler ve dijital riskler gibi çok yönlü tehditler İSG kapsamında ele alınmaktadır. Bu gelişmeler, risklerin doğru bir şekilde değerlendirilmesi ve hızlıca önlem alınmasını her zamankinden daha önemli hâle getirmiştir.

Geleneksel risk değerlendirme yöntemleri genellikle gözleme, deneyime ve uzman yorumlarına dayanır. Ancak bu yaklaşım, bazı durumlarda kişisel yorum farklılıklarına ve insan hatalarına açık olabilir. Ayrıca bu süreçler genellikle zaman alıcıdır ve değişen iş koşullarına her zaman yeterince hızlı uyum sağlayamaz. Bu noktada, son yıllarda hayatın birçok alanında olduğu gibi İSG alanında da yapay zekâ (YZ) teknolojilerinin sunduğu imkânlar dikkat çekmektedir.

Yapay zekâ, çok büyük veri kümelerini analiz edebilme, örüntüleri tanıyabilme ve geleceğe yönelik tahminlerde bulunabilme gibi önemli yeteneklere sahiptir. Bu yönüyle İSG alanında da risklerin daha hızlı, objektif ve etkili bir şekilde değerlendirilmesine katkı sunabilir. Özellikle makine öğrenmesi (MÖ) algoritmaları, geçmiş kaza kayıtları, işyeri türleri, tehlike sınıfları ve çalışan verileri gibi çok yönlü bilgileri işleyerek, potansiyel riskleri önceden tespit edebilir. Böylece İSG uzmanları olaylar yaşanmadan önce önlem alabilir, daha proaktif ve bilinçli kararlar verebilir.

Bu tez kapsamında, İSG alanında farklı sektörlerde karşılaşılabilecek tüm risk türlerini dikkate alan, kapsamlı ve YZ destekli bir risk yönetimi sistemi geliştirilmiştir. Tasarlanan bu sistem, işyerlerinden elde edilen temel verileri analiz ederek risklerin seviyesini belirlemekte ve bu riskleri sınıflara ayırmaktadır. Ayrıca, belirlenen risklerin önceliğine göre alınması gereken önlemler hakkında sistematik öneriler sunmaktadır. Böylece, işyerlerinde sadece mevcut risklerin tespiti değil, aynı zamanda

bu risklere ne düzeyde ve ne hızda müdahale edilmesi gerektiği de bilimsel bir temele oturtulmuştur.

Bu çalışmanın dikkat çeken yönlerinden biri, sistemin eğitiminde dış kaynaklı hazır veri setleri yerine, doğrudan çalışma amacına uygun biçimde oluşturulmuş simüle veri setlerinin kullanılmasıdır. Bu yaklaşım, modelin belirli sektörlerle veya örneklem kümelerine bağımlı kalmadan daha geniş bir uygulama alanına uyarlanabilmesini sağlamıştır. Aynı zamanda modelin geliştirilme sürecine özgünlük katmış ve sistemin farklı iş kollarında kullanılabilirliğini artırmıştır.

Yürütülen bu çalışma, yalnızca teknik bir model geliştirmekle kalmamış; aynı zamanda yapay zekânın İSG uygulamalarında nasıl etkin ve anlamlı biçimde kullanılabileceğine dair uygulanabilir bir örnek ortaya koymuştur. Geliştirilen sistemin, İSG profesyonellerine dijital karar destek aracı olarak katkı sunması, risk analiz süreçlerini hızlandırması ve insan hatasını en aza indirerek daha güvenli iş ortamları oluşturması hedeflenmiştir. Bu yönüyle çalışma, hem akademik alanda bilimsel bir kaynak hem de iş dünyası için pratik bir çözüm önerisi niteliğindedir.

## **1 TEZİN AMACI, KATKISI VE İÇERİĞİ**

### **1.1 Tezin Amacı**

Bu tez çalışmasının temel amacı, İSG alanında farklı sektörlerde karşılaşılabilecek tehlikeleri YZ destekli bir sistemle analiz edebilen, geniş kapsama sahip bir risk yönetimi modeli geliştirmektir. Çalışma, yalnızca belirli bir iş koluna özgü bir çözüm üretmeyi değil; fiziksel, kimyasal, biyolojik, ergonomik ve psikososyal tehlike türlerinin tümünü dikkate alarak genel geçerliliği olan bir yapı kurmayı hedeflemektedir.

Geliştirilen sistem, işyerlerine ait temel verileri analiz ederek her bir tehlikenin niteliğini ve olasılığını değerlendirmekte, bu değerlendirmeler sonucunda risk düzeylerini hesaplamaktadır. Hesaplanan risk dereceleri, karar vericilere hangi riskin daha acil önlem gerektirdiğini gösteren bir önceliklendirme imkânı sunmaktadır. Bu şekilde, kurumlar hem kaynaklarını daha verimli kullanabilmekte hem de potansiyel tehlikelere karşı daha hazırlıklı hâle gelmektedir.

YZ tabanlı bu modelin amacı yalnızca tehlikeleri sınıflandırmak değil, aynı zamanda mevcut veriler ışığında anlamlı sonuçlar üretmek ve bu sonuçları karar vericilere açık, yorumlanabilir ve uygulanabilir şekilde sunmaktır. Böylece geleneksel yöntemlerde görülen zaman kaybı, uzmanlar arası yorum farkları gibi sorunlar en aza indirilmiş; değerlendirme süreci daha hızlı, daha nesnel ve veri temelli bir yapıya kavuşturulmuş olmaktadır.

Ayrıca, bu çalışmanın temel amacı; iş kazalarının ve meslek hastalıklarının önlenmesine yönelik daha proaktif bir yaklaşım sunmak, İSG uzmanlarının ve yöneticilerin karar alma süreçlerini güçlendirmek ve dijitalleşmenin sunduğu imkânlarla İSG yönetiminde yeni bir çerçeve oluşturmaktır. Geliştirilen modelin, gerek akademik araştırmalar için temel bir örnek teşkil etmesi, gerekse pratik uygulamalarda kullanılabilecek bir karar destek aracı olarak işlev görmesi hedeflenmektedir.

## **1.2 Literatüre Katkısı**

Araştırmada önerilen model, yalnızca belirli bir sektöre yönelik çözümler sunmakla kalmayıp; fiziksel, kimyasal, biyolojik, ergonomik ve psikososyal tehlikeleri bir arada ele alan kapsamlı bir sistem yaklaşımı geliştirmektedir. Bu yönüyle, literatürde sıklıkla karşılaşılan sektörel odaklı veya yalnızca tekil risk türlerine odaklanan çalışmalardan önemli ölçüde ayrılmaktadır. Geniş kapsamlı yapısıyla, farklı iş kollarında karşılaşılabilecek risklerin bütünsel biçimde değerlendirilmesine olanak tanımaktadır.

İSG alanında YZ entegrasyonuna yönelik mevcut araştırmalar incelendiğinde, genellikle yalnızca geçmiş kazaların analizi, belirli görev gruplarındaki maruziyetlerin puanlanması ya da dar kapsamlı sınıflandırma algoritmalarının performansı gibi sınırlı uygulamalara odaklanıldığı görülmektedir. Oysa burada geliştirilen sistem, yalnızca farklı tehlike gruplarını birlikte değerlendirmekle kalmamakta; aynı zamanda çeşitli sektörlerde uygulanabilir esnek bir yapı da sunmaktadır. Böylece hem bilimsel anlamda özgünlük hem de pratik uygulamalarda genişletilebilirlik özellikleri bir arada sağlanmaktadır.

Ayrıca, sistemin eğitim ve test aşamalarında kullanılan veri yapısı, dış kaynaklı hazır veri setleri yerine, çok çeşitli iş ortamlarını yansıtan özgün simülasyonlarla oluşturulmuştur. Bu tercih, hem modelin sektörel fark gözetmeksizin

uyarlanabilirliğini artırmakta hem de akademik katkı açısından özgün veri üretimi yoluyla literatüre farklı bir yöntemsel yaklaşım sunmaktadır.

Genel olarak, çalışma; kapsayıcılığı yüksek bir model önerisi ortaya koyması, YZ uygulamalarını İSG'nin tüm temel risk alanlarına yaygınlaştırması ve simüle veri üretimiyle özgün bir yöntem kullanması bakımından literatürdeki sınırlı sayıda çalışmayı tamamlayıcı ve geliştirici niteliktedir.

### **1.3 Problem Durumu ve Araştırma Soruları**

İSG, çalışanların fiziksel ve ruhsal bütünlüğünü korumayı, iş kazalarını ve meslek hastalıklarını en aza indirmeyi amaçlayan bir disiplindir. İşyerlerinde yürütülen risk değerlendirme çalışmaları, bu koruyucu yaklaşımın temelini oluşturmaktadır. Ancak uygulamada yaygın olarak kullanılan geleneksel yöntemler, sabit risk matrislerine, sınırlı sayıda parametreye ve büyük ölçüde uzman görüşlerine dayalı bir yapıya sahiptir.

Bu yöntemlerin önemli avantajları olmakla birlikte, hızla değişen iş ortamlarına ve karmaşık risk yapılarına uyum sağlama noktasında çeşitli sınırlılıklar taşıdığı gözlenmektedir. Özellikle farklı sektörlerde karşılaşılan çok boyutlu risklerin aynı sistem içerisinde nesnel biçimde değerlendirilmesi konusunda geleneksel yaklaşımlar çoğu zaman yetersiz kalmaktadır. Uzman görüşlerine dayalı subjektif değerlendirmeler, aynı risk durumunun farklı kişiler tarafından farklı şekilde yorumlanmasına neden olabilmekte ve karar süreçlerinde tutarsızlıklara yol açabilmektedir.

Son yıllarda gelişen YZ teknolojileri, bu sorunlara karşı güçlü çözümler sunabilecek kapasitededir. MÖ algoritmaları; geçmiş kaza kayıtları, işyeri ortam verileri, çalışan profilleri ve maruziyet süreleri gibi çok çeşitli verileri birlikte analiz ederek, insan öngörüsünün ötesine geçen sonuçlar elde etme imkânı tanımaktadır. Bu sayede, hem değerlendirme süreçleri hızlanmakta hem de risk tespiti daha tutarlı ve sistematik bir yapıya kavuşmaktadır.

Ancak literatür incelendiğinde, YZ temelli modellerin çoğunun belirli sektörlerle ya da belirli tehlike türlerine odaklandığı; bu nedenle farklı iş kollarında genellenebilir yapılar sunmakta yetersiz kaldığı görülmektedir. Bunun yanı sıra, çok sayıda tehlike

türünü bir arada değerlendiren ve sonuçlara dayalı çözüm önerileri üretebilen sistem tasarımlarına literatürde sınırlı düzeyde yer verilmektedir.

Bu kapsamda, bu tezde ele alınan başlıca problem; farklı sektör ve tehlike gruplarında karşılaşılan İSG risklerinin, YZ destekli bir sistemle ne derece doğru sınıflandırılabilceğı ve bu sistemin geleneksel yöntemlere kıyasla ne tür avantajlar sağlayabileceğidir.

Bu çerçevede aşağıdaki temel araştırma sorularına yanıt aranmıştır:

- Farklı sektörlerde ortaya çıkan İSG riskleri, YZ destekli sistemler aracılığıyla nasıl analiz edilebilir ve hangi sınıflandırma modelleri daha yüksek başarı sağlamaktadır?
- MÖ algoritmaları arasında, risk değerlendirme performansı açısından öne çıkan yöntemler hangileridir?
- Önerilen sistemin ürettiğı risk skorları ile geleneksel yöntemlerle elde edilen skorlar arasında anlamlı farklar var mıdır? Bu farklar hangi durumlarda daha belirgindir?
- YZ tabanlı bir yaklaşım, İSG uzmanlarının karar alma süreçlerini nasıl etkileyebilir ve hangi noktalarda destekleyici rol oynar?
- Geliştirilen model, farklı sektörlerde kullanılabilecek kadar esnek ve genellenebilir bir yapıya sahip midir?

Araştırma, bu sorulara bilimsel yöntemlerle sistematik yanıtlar arayarak, İSG alanında dijitalleşmenin ve akıllı sistemlerin etkili bir şekilde nasıl kullanılabileceğini ortaya koymayı hedeflemektedir.

#### **1.4 Araştırmanın Kapsamı ve Sınırlılıkları**

Bu araştırmanın kapsamı, İSG alanında farklı sektörlerde karşılaşılan temel risk türlerini YZ destekli bir sistemle analiz etmeye yöneliktir. Geliştirilen model, fiziksel, kimyasal, biyolojik, ergonomik ve psikososyal tehlike gruplarını dikkate alarak genel geçer bir risk sınıflandırma altyapısı oluşturmayı amaçlamaktadır. Sistemin yazılım altyapısı Python programlama diliyle geliştirilmiş; Decision Tree, Random Forest ve XGBoost gibi yaygın ve güçlü MÖ algoritmaları kullanılmıştır.

Uygulamada kullanılan veri setleri, gerçek saha verilerine erişim kısıtlı olduğu için özel olarak simüle edilmiştir. Bu simülasyon sürecinde, farklı iş kollarında ve çalışma ortamlarında karşılaşılabilecek risk faktörleri göz önünde bulundurulmuş, çeşitlendirilmiş ve dengeli bir veri yapısı oluşturulmuştur. Bu yöntem, modelin hem eğitim sürecini denetimli hale getirmiş hem de farklı durumlara uyarlanabilirliğini artırmıştır.

Ancak bu yaklaşımın bazı sınırlılıkları da bulunmaktadır. Öncelikle, gerçek işyeri koşullarına ait veriler kullanılmadığı için, modelin bazı mikro düzeydeki değişkenleri (çalışan davranış kalıpları, kurumsal kültür farkları veya sektör dinamikleri gibi) tam olarak yansıtması mümkün olmamıştır. Ayrıca, YZ algoritmalarının performansı doğrudan veri kalitesine ve temsiliyetine bağlı olduğu için, sonuçların güvenilirliği de bu faktörlere göre değişebilir.

Geliştirilen sistem, mevcut haliyle hem akademik hem de pratik uygulamalara örnek teşkil edecek temel bir model sunmaktadır. Ancak gelecekte, gerçek saha verileriyle desteklenen yeni versiyonlar geliştirilerek sistemin doğruluğu, güvenilirliği ve kullanılabilirliği daha da artırılabilir. Ayrıca farklı sektörlerden gelecek kullanıcı geri bildirimleri ile sistem sürekli güncellenebilir ve iş güvenliği profesyonelleri için daha etkili bir karar destek aracına dönüşebilir.

## **2. KURAMSAL TEMELLER**

### **2.1 İş Sağlığı ve Güvenliği Kavramı**

İSG, çalışanların işyerlerinde karşı karşıya kaldığı her türlü tehlikeye karşı korunmasını, iş ortamının güvenli hâle getirilmesini ve sağlıklarının sürdürülebilir biçimde korunmasını hedefleyen disiplinlerarası bir çalışma alanıdır. Bu kavram yalnızca iş kazalarının azaltılmasıyla sınırlı olmayıp; meslek hastalıklarının önlenmesinden, ergonomik risklerin azaltılmasına, psikososyal destekten yönetsel politikaların şekillendirilmesine kadar oldukça geniş bir alanı kapsar. Uluslararası düzeyde en çok kabul gören tanımlardan biri, Dünya Sağlık Örgütü (WHO) ve Uluslararası Çalışma Örgütü (ILO) tarafından 1950 yılında benimsenmiştir. Söz konusu tanıma göre İSG; “çalışanların fiziksel, zihinsel ve sosyal açıdan tam iyilik hallerini sağlamak ve sürdürmek; çalışma koşullarından kaynaklanan sağlık bozulmalarını önlemek; çalışanları işle ilgili risklerden korumak ve işe uygun çalışan,

çalışana uygun iş sağlamak” olarak ifade edilmektedir (ILO, 2025). Bu tanım, İSG’nin yalnızca hastalık ve kazaların engellenmesi değil, aynı zamanda bireyin tüm yönleriyle refahının hedeflenmesini vurgular.

Özetle, İSG; sadece bir mevzuat yükümlülüğü değil, aynı zamanda işin niteliğini ve işyeri ortamının kalitesini geliştiren bir sistem yaklaşımıdır. Bu yaklaşım, risk yönetiminin yanı sıra çalışanların iş tatmini, psikolojik dayanıklılığı ve örgütsel bağlılığını da artırır. Mühendislik bilimleri aracılığıyla tehlikelerin kaynaktan yok edilmesi, tıbbın sunduğu erken tanı ve koruyucu sağlık hizmetleri, ergonomi ile işyeri koşullarının insan bedenine uygun hâle getirilmesi, hukuk bilimi ile normların düzenlenmesi ve psikoloji disipliniyle bireylerin davranış kalıplarının anlaşılması gibi çeşitli alanlardan faydalanılır (Azzi, 2019). Bu disiplinlerarası doğa, İSG’yi statik bir kavramdan ziyade dinamik ve sürekli gelişen bir uygulama alanı hâline getirmiştir.

İSG kavramı tarihsel açıdan değerlendirildiğinde, insanlık tarihinin üretimle ilişkili evrelerine paralel bir gelişim seyri izlediği görülmektedir. Özellikle Sanayi Devrimi ile birlikte, üretimin fabrikalara taşınması ve makineleşmenin yaygınlaşması, iş kazalarının ve meslek hastalıklarının ciddi boyutlara ulaşmasına neden olmuştur. Bu dönemde çalışanlar, yeterli koruma önlemleri olmaksızın ağır koşullarda çalışmaya zorlanmış, bu da toplumsal tepkilere ve yasal düzenlemelere zemin hazırlamıştır. 19. yüzyılda başta İngiltere olmak üzere birçok sanayileşmiş ülkede çocuk işçiliği, uzun çalışma saatleri ve sağlıksız iş ortamlarına karşı ilk İSG yasaları çıkarılmıştır. Bu yasal düzenlemeler, modern İSG sistemlerinin temelini oluşturmuş ve zamanla tüm dünyaya yayılmıştır (Azzi, 2019).

Türkiye’de ise İSG’nin tarihsel gelişimi, küresel akımlarla uyumlu olmakla birlikte yerel koşullara göre şekillenmiştir. Osmanlı döneminde İSG’ye dair ilk kapsamlı yasal düzenleme, 1865 yılında çıkarılan Dilaver Paşa Nizamnamesi olmuştur. Bu düzenleme, Zonguldak bölgesindeki maden ocaklarında çalışan işçilerin sağlık ve güvenliğini korumaya yönelik hükümler içermektedir (Şen, 2015). Bu belge, aynı zamanda Türkiye’de İSG alanında devletin ilk müdahalesi olarak kabul edilebilir. Cumhuriyetin ilanından sonra 1930 tarihli 1593 sayılı Umumi Hıfzıssıhha Kanunu ile kamu sağlığı ve işçi sağlığına ilişkin genel ilkeler belirlenmiş, 1936 tarihli 3008 sayılı İlk İş Kanunu ile işveren ve işçi haklarına dair kurallar oluşturulmuştur. Ancak bu

düzenlemeler genellikle dağınık ve sektör bazlıydı; bütüncül bir sistem yaklaşımından uzaktı.

Uzun yıllar boyunca İSG ile ilgili hükümler, çeşitli tüzük ve yönetmeliklerde parçalı olarak yer almıştır. Bu nedenle uygulamada bir birlik sağlanamamış, denetim ve cezai yaptırımlarda istikrar sağlanamamıştır. Bu eksiklik, ancak 30 Haziran 2012 tarihinde yürürlüğe giren 6331 sayılı İş Sağlığı ve Güvenliği Kanunu ile giderilmiştir. Bu yasa ile İSG ilk kez müstakil bir hukuk dalı olarak tanımlanmış; işverenlerin risk değerlendirmesi yapma yükümlülüğü, çalışanların eğitilmesi zorunluluğu, önleyici tedbirlerin alınması gibi çok sayıda kural açıkça belirlenmiştir. Aynı zamanda çalışanların da sorumluluk taşıdığı bir anlayış benimsenmiştir (Karaahmetoğlu, 2022).

Kanunun yürürlüğe girmesinden sonra çıkarılan ikincil mevzuatlar ile uygulama detaylandırılmış; “Risk Değerlendirmesi Yönetmeliği”, “İşyeri Hekimi ve Diğer Sağlık Personelinin Görev, Yetki ve Sorumlulukları Hakkında Yönetmelik”, “Acil Durumlar Hakkında Yönetmelik” gibi düzenlemelerle İSG alanında uygulanabilir bir yapı kurulmuştur. Ayrıca çalışan temsilcisi görevlendirme, çalışanların görüşlerinin alınması, periyodik sağlık muayeneleri gibi pek çok uygulama da bu çerçevede yasal zemine oturtulmuştur. Öte yandan Türkiye, ILO’nun iş sağlığına ilişkin temel sözleşmelerinden olan 155 ve 161 nolu sözleşmeleri imzalayarak ulusal mevzuatını uluslararası standartlarla uyumlu hâle getirme yolunda önemli bir adım atmıştır (Karaahmetoğlu, 2022). Bu çerçevede, Türkiye’nin küresel İSG normlarına entegrasyonunu da güçlendirmiştir.

Sonuç olarak, Türkiye’de İSG kavramı, 2012 yılından sonra kurumsal ve hukuki yönden büyük bir dönüşüm geçirmiştir. Bu dönüşüm sayesinde işveren, çalışan ve devlet üçlüsüne dayalı bir sorumluluk yapısı oluşmuş; İSG yalnızca bir mevzuat yükümlülüğü olmaktan çıkıp, kurum kültürünün ayrılmaz bir parçası hâline gelmiştir. Günümüzde İSG, hem iş kazalarının azaltılması hem de işletmelerin sürdürülebilirliği ve verimliliği açısından stratejik bir unsur olarak değerlendirilmektedir (ÇSGB, t.y.). Özellikle yeni nesil İSG yaklaşımları, teknolojik gelişmelerle desteklenmekte ve YZ gibi ileri teknolojilerin risk öngörüsü ve önleme süreçlerinde kullanımı giderek yaygınlaşmaktadır.

## 2.2 Risk Yönetimi ve Risk Değerlendirme Süreçleri

Bu bölümde öncelikle klasik–statik risk değerlendirme teknikleri özetlenecek, ardından REDECA gibi YZ destekli dinamik yaklaşımlar ve algoritmik/psiko-sosyal tehlikeleri içeren bütünleşik modeller tartışılacaktır.

### 2.2.1 Klasik/Statik Risk Matrisleri

İSG’de risk yönetimi; işyerinde mevcut tehlikelerin sistematik bir şekilde belirlenmesi, analiz edilmesi ve uygun önlemlerle kabul edilebilir seviyeye indirilmesi sürecidir. Bu sürecin ilk adımı, tehlikelerin tanımlanmasıdır. Tehlike, çalışanların yaralanmasına veya hastalanmasına yol açabilecek potansiyel bir kaynak, durum veya eylem olarak tanımlanmaktadır (İSG Risk Değerlendirmesi Yönetmeliği, 2012, md. 4).

İkinci adım olan risk analizi ise, belirlenen tehlikelerin gerçekleşme olasılığı ile sonuçlarının ciddiyetinin değerlendirilmesini içerir. Uygulamada sık kullanılan yöntemlerden biri, risk değerlendirme matrisi yöntemidir. Risk matrisi, olasılık ve şiddet kategorilerini tablo üzerinde eşleştirerek her bir tehlikenin risk seviyesini görsel olarak sınıflandırır (Canadian Centre for Occupational Health and Safety [CCOHS], 2022). Örneğin, 5x5’lik L tipi risk matrisi yaklaşımında bir olayın olasılığı (çok düşükten çok yükseğe 1–5 arası) ve etkisinin şiddeti (önemsizden katastrofik düzeye kadar 1–5) çarpılarak veya kombine edilerek değerlendirilir. Bu hesaplama sonucunda risk seviyeleri “düşük”, “orta” veya “yüksek” gibi kategorilere ayrılır. Böylece, hangi risklerin öncelikle kontrol altına alınması gerektiği sistematik biçimde belirlenmiş olur (ILO, 2021).

$\text{Risk} = \text{Olasılık} \times \text{Şiddet}$  formülü, temel risk değerlendirme mantığını basit şekilde ifade eder. Bu yaklaşım, özellikle küçük ölçekli değerlendirmelerde hızlı ve anlaşılır sonuçlar sunar. Ancak, daha sistematik ve detaylı analizler için sayısal puanlama yöntemleri geliştirilmiştir. Fine-Kinney yöntemi bu kapsamda yaygın olarak kullanılan nicel tekniklerden biridir. Bu yöntemde risk puanı; tehlikenin gerçekleşme olasılığı, maruziyet sıklığı ve etkilenme şiddetinin çarpımıyla hesaplanır ve böylece sayısal bir risk skoru elde edilir (Bayram ve Çelenk Kaya, 2022). Bu statik yapıdaki puana mevcut kontrol önlemlerinin etkinlik katsayısını dâhil eden bir genişletilmiş matris önerisi ise (Gündüz ve Laitinen, 2018) tarafından geliştirilmiştir.

Geleneksel risk deęerlendirme teknikleri arasında kontrol listeleri (Checklist), Ön Tehlike Analizi (Preliminary Hazard Analysis, PHA), Hata Türü ve Etkileri Analizi (Failure Mode and Effects Analysis, FMEA) ve “Olursa Ne Olur” (What-If) gibi yöntemler yer almaktadır. Bu teknikler, sistematik risk yönetimi yaklaşımının bir parçası olarak İSG politikalarının uygulanmasında önemli araçlar sunar (Kanten, 2019).

### **2.2.2 REDECA Modeli ve Dinamik Yaklaşım**

Risk analizi sonucunda her tehlike için elde edilen risk seviyesi, üçüncü adım olan risk deęerlendirmesi aşamasında yorumlanır. Bu aşamada risklerin kabul edilebilir olup olmadığına karar verilir ve riskler önceliklendirilir. Risk kontrolü ise kabul edilemez düzeydeki riskler için önleyici tedbirlerin planlanması ve uygulanması sürecini kapsar.

İSG’de risklerin kontrolü, genellikle hiyerarşik bir yaklaşımı takip eder. Bu hiyerarşi; tehlikeyi kaynağında ortadan kaldırma, ikame etme (daha az tehlikeli malzeme veya süreç ile deęiştirme), mühendislik önlemleri (koruyucu bariyerler, havalandırma sistemleri), idari önlemler (eğitimler, prosedür deęişiklikleri) ve en son kişisel koruyucu donanımların kullanımını içerir. Bu yaklaşım, riskleri en üst düzeyde azaltmayı ve çalışanları etkin şekilde korumayı hedefler.

Türkiye’de işyerlerinde risk deęerlendirmesi yapılması, 6331 sayılı İSG Kanunu kapsamında yasal bir zorunluluktur. Bu kapsamda çıkarılan İş Sağlığı ve Güvenliği Risk Deęerlendirmesi Yönetmelięi’ne (2012) göre; işverenlerin risk deęerlendirme süreçlerini yazılı olarak yürütmeleri, gerektiğinde güncellemeleri ve alınan tedbirleri belgelemeleri gerekmektedir. Yönetmelik, risk deęerlendirmesinin “hazırlık, risklerin tanımlanması, analiz ve derecelendirme, kontrol tedbirlerinin belirlenmesi ve dokümantasyon” olmak üzere beş aşamadan oluştuğunu belirtmiştir.

İSG’de risk yönetimi ve deęerlendirmesi, önleyici yaklaşımın temel taşıdır. Doğru ve sistematik bir risk deęerlendirme süreci sayesinde, işyerinde potansiyel tehlikeler önceden belirlenerek kontrol altına alınabilir; böylece hem çalışanların sağlığı korunur hem de üretim kesintileri ve mali kayıplar azaltılabilir. Güncel çalışmalar, sistematik risk analizinin YZ ve görsel veri teknikleriyle entegre edilmesi durumunda daha öngörülebilir ve dinamik bir İSG yönetimi sağlanabileceğini ortaya koymaktadır (Tang ve Golparvar-Fard, 2021; Motorcu ve Murat, 2021).

Pishgar vd. (2021) tarafından geliştirilen REDECA modeli, “İsviçre peyniri” yaklaşımını genişleterek R1 (düşük risk)–R3 (zarar gerçekleşti) durumları arasındaki geçişleri *olasılık-zaman-müdahale* ekseninde nicel olarak tanımlamaktadır. Böylece geleneksel matris-temelli risk değerlendirmesine dinamik bir boyut kazandırılır; sahadan toplanan sensör verileri ve MÖ çıktıları doğrudan risk matrisine entegre edilebilir. (Pishgar vd., 2021).

### 2.2.3 Algoritmik Tehlikeler ve Psiko-Sosyal Riskler

Dijitalleşmiş iş-ortamlarında YZ temelli izleme ve takip, mikro-yönetim uygulamalarını keskinleştirerek “stres ve anksiyeteyi tetikleyen birincil unsur” hâline gelebilir (Moore, 2019). Dahası, “tek başına teknoloji değil, onun uygulanma biçimi risk yaratır ya da azaltır” (Moore, 2019). Bu bulgular, REDECA’nın dinamik matrisine yalnızca fiziksel arıza olasılıklarını değil, algoritmik yönetim kaynaklı psiko-sosyal tehlikeleri de dâhil etmeyi zorunlu kılar. Çalışmamızda kalp-ritim değişkenliği (HRV), klavye-fare paternleri ve iş-yükü metriklerinden türetilen P\_psy göstergesi, R1→R2 eşiklerini gerçek-zamanlı güncellemek için kullanılacak; böylece stres ve benzeri psiko-sosyal riskler fiziksel (P\_fiziksel) parametrelerle aynı “olasılık-zaman-müdahale” ekseninde yönetilecektir.

### 2.2.4 Dinamik Risk Matrisi Parametre Seti

Bu çalışmada kullanılan dinamik risk değerlendirme yaklaşımı, geleneksel yöntemlerin ötesine geçerek riskin sadece sabit bir anda değil, zaman içinde değişebileceğini kabul eden çok boyutlu bir çerçeve sunmaktadır. REDECA modelinin temelini oluşturan bu yaklaşım, olasılık, zaman ve müdahale gibi üç ana unsur etrafında yapılandırılmış ve toplamda dört parametreyle desteklenmiştir. Bu parametreler; fiziksel arızaların olasılığı, psikososyal stres etkisi, tehlikenin ortaya çıkış süresi ve müdahalenin etkinliği olarak özetlenebilir.

İlk parametre olan fiziksel risk olasılığı, makinelerden ya da ekipmanlardan kaynaklanabilecek teknik arızaların ne ölçüde muhtemel olduğunu ifade eder. Örneğin, sıcaklık artışı, titreşim seviyeleri ya da basınç değişimleri gibi sensör verileri sürekli olarak izlenerek sistemin bu tür arızaları önceden tahmin etmesi sağlanmaktadır. Bu sayede, riskin olasılığı sabit bir değer olarak değil, gerçek zamanlı olarak sürekli güncellenebilen bir ölçü hâline gelmiştir.

İkinci parametre olan psikososyal stres düzeyi, doğrudan gözlemlenmesi zor olan zihinsel ve duygusal yükleri tespit etmeyi amaçlar. Çalışanların iş yükü, dikkat dağınıklığı, stres belirtileri gibi durumları; örneğin kalp atış hızındaki değişimler ya da bilgisayar kullanım davranışları üzerinden analiz edilerek değerlendirilir. Bu analizler sayesinde sistem, örneğin yoğun stres altında çalışan bir personele mola verilmesi ya da görev değişikliği yapılması gibi erken önlemler önerebilir.

Üçüncü parametre olan tehlikenin ortaya çıkış gecikmesi, bir olayın algılanmasıyla sistemin buna tepki vermesi arasında geçen süreyi kapsar. Gecikme ne kadar kısa olursa, sistem bu durumu daha yüksek risk olarak değerlendirir. Bu da erken uyarı sistemlerinin önemini artırmakta, ani tehlikeler karşısında hızlı karar almayı gerektiren durumların önceliklendirilmesini sağlamaktadır.

Son olarak müdahale etkinliği, belirli bir riske karşı alınan önlemlerin sahada ne kadar başarılı olduğunu gösterir. Örneğin; bir makineye yönelik alınan mühendislik önlemleri ya da çalışanlara verilen kişisel koruyucu ekipmanların gerçekten işe yarayıp yaramadığı, saha verileriyle değerlendirilmektedir. Eğer bu önlemler yeterince etkili değilse, sistem ilgili riskin seviyesini otomatik olarak yükseltecek şekilde kendini güncelleyebilmektedir. Bu dört parametre, birlikte çalışarak dinamik bir risk değerlendirme sistemi oluşturur. Bu sistem, yalnızca geçmiş verilere dayalı olarak değil, aynı zamanda mevcut saha koşullarını da hesaba katarak anlık değerlendirmeler yapabilir. Özellikle sanayi 4.0 teknolojilerinin sunduğu sensör ağları ve büyük veri altyapısı sayesinde, risk parametreleri gerçek zamanlı olarak izlenebilmekte ve değerlendirme sonuçları sürekli olarak güncellenebilmektedir. Bu bütünlük yapı, klasik risk matrislerinin sabit ve sınırlı değerlendirmelerine kıyasla çok daha esnek, duyarlı ve sahaya uygun bir sistem sunmaktadır. Böylece hem ekipman arızaları gibi teknik tehditler hem de çalışan kaynaklı psikososyal riskler aynı sistem içerisinde değerlendirilebilir hâle gelmiştir. Sonuç olarak bu yaklaşım, risk değerlendirmesini daha dinamik, daha insana odaklı ve daha gerçekçi kılarak iş sağlığı ve güvenliği kültüründe önemli bir ilerleme sağlamaktadır.

### **2.3 YZ Temelleri ve MÖ Yaklaşımları**

YZ, insan zekâsı gerektiren görevleri bilgisayar sistemleri aracılığıyla gerçekleştirmeyi amaçlayan disiplinler arası bir bilim dalıdır. Problem çözme, karar verme, doğal dil işleme ve görsel algılama gibi bilişsel işlevleri makinelerin taklit

etmesine olanak saęlayan algoritmalar ve sistemler geliřtirilmesini kapsar. (Kaplan ve Haenlein 2019) yapay zekâyı, “çevresinden gelen verileri doęru biçimde algılayarak bu verilerden öğrenen ve elde ettięi bilgilerle belirli hedeflere yönelik esnek biçimde hareket eden sistemler” olarak tanımlamaktadır. Bu tanım, YZ sistemlerinin öğrenme kabiliyeti ve çevresel uyum yeteneklerini vurgular.

YZ genel olarak iki ana kategoriye ayrılabilir: Dar YZ (narrow AI) ve genel YZ (general AI). Günümüzde yaygın olarak kullanılan YZ uygulamaları, genellikle belirli bir görevi yerine getirmek üzere tasarlanmış dar YZ örnekleridir (örneğin yüz tanıma sistemleri, öneri motorları) (Russell ve Norvig, 2020).

YZ'nın en önemli alt alanlarından biri olan MÖ, bilgisayarların açıkça programlanmaksızın verilerden öğrenerek performanslarını artırmalarını saęlayan bir yöntemdir. Mitchell (1997), MÖ 'ni, “deneyim yoluyla performansını iyileřtiren bilgisayar programlarının geliřtirilmesi” olarak tanımlamıştır.

MÖ algoritma

ları genel olarak dört ana grupta sınıflandırılmaktadır (Sarker, 2021):

- **Denetimli Öğrenme (Supervised Learning):** Girdi verilerine karşılık doęru çıktıların bilindięi veri kümeleri kullanılarak model eğitilir. Sınıflandırma ve regresyon problemleri bu gruba dahildir. Örneęin, bir çalıřanın "yüksek risk" veya "düşük risk" sınıfına atanması bir sınıflandırma problemidir. Decision Tree, destek vektör makineleri (support vector machines, SVM), yapay sinir aęları (ANN) ve Naive Bayes algoritmaları denetimli öğrenmede sıkça kullanılmaktadır.
- **Denetimsiz Öğrenme (Unsupervised Learning):** Veriler üzerinde etiket bulunmadan desenlerin keřfedilmesi amaçlanır. Kümeleme (clustering) yöntemleri buna örnektir; benzer iş kazası senaryolarının gruplanması gibi.
- **Yarı Denetimli Öğrenme (Semi-supervised Learning):** Az miktarda etiketli ve bol miktarda etiketsiz veri kullanılarak model eğitilir. Özellikle etiketli verinin az olduęu alanlarda etkin çözüm sunar.

- **Pekiştirmeli Öğrenme (Reinforcement Learning):** Model, çevresiyle etkileşime girerek ve ödül-ceza mekanizmasına dayalı öğrenme stratejileri geliştirir. Robotik ve otonom sistemlerde yaygın olarak kullanılmaktadır (Sutton ve Barto, 2018).

MÖ modellerinin etkili olabilmesi için geniş ve kaliteli veri setlerine ihtiyaç duyulmaktadır. Eğitim sürecinde model, verideki örüntüleri öğrenirken, ayrı bir doğrulama veya test seti ile genel performansı ölçülür. Modelin aşırı öğrenme (overfitting) yapmaması için çapraz doğrulama, erken durdurma (early stopping) ve düzenlileştirme (regularization) gibi teknikler kullanılmaktadır (Goodfellow, Bengio, ve Courville, 2016).

İSG alanında MÖ uygulamaları çeşitlidir. İş kazası kayıtları, sensör verileri, çalışan davranış verileri, çevresel ölçümler ve ekipman bakım kayıtları gibi farklı veri kaynakları MÖ modellerine girdi oluşturabilir (Khanzode, Sarvade, ve Ralegaonkar, 2021). Bu alandaki kapsamlı bir sistematik incelemede, (Maheronnaghsh, Zolfagharnasab, Gorgich ve Duarte, 2023), İSG'de kullanılan MÖ yaklaşımlarını sınıflandırarak en yaygın uygulama alanlarını ve karşılaşılan zorlukları raporlamıştır. Bu çalışma, veri temelli İSG karar destek sistemlerinin yaygınlaşmasında MÖ'nin rolünü vurgulamaktadır. Tahmin problemlerinde ise model, örneğin "önümüzdeki ay kaç iş kazası meydana gelebileceğini" öngörebilir. Ayrıca MÖ modelleri, işyerinde ekipman arızalarını öngörerek bakım yönetimini iyileştirebilir.

Son yıllarda derin öğrenme (deep learning) yöntemleri de dikkat çekici başarılar elde etmiştir. Derin öğrenme, çok katmanlı yapay sinir ağları kullanarak büyük veri setleri üzerinden karmaşık örüntüleri öğrenme kapasitesine sahiptir. Görüntü tanıma, ses tanıma ve doğal dil işleme gibi alanlarda devrim yaratmıştır (Goodfellow vd., 2016). İSG alanında da derin öğrenme, örneğin iş yerinde kamera görüntülerinden tehlikeli durumların otomatik tespitinde kullanılmaktadır. Literatürde derin öğrenmenin evrimi 1940'lardaki McCulloch-Pitts devrelerinden 2010'ların GAN mimarilerine kadar ayrıntılı biçimde haritalanmıştır (Patel ve Thakkar, 2020). Bu kronoloji, zayıf-AI → dar-AI ekseninde REDECA gibi 'narrow AI' çözümlerinin yerini de netleştirmektedir."

MÖ'nin İSG'ye uygulanmasında sadece yüksek doğruluk değil, aynı zamanda modelin açıklanabilirliği (explainability) de önem arz etmektedir. Yönetici ve uzmanların bir modelin neden belirli bir tahminde bulunduğunu anlayabilmeleri, modelin pratik kullanımını ve güvenilirliğini artırmaktadır. Bu amaçla SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-Agnostic Explanations) gibi yöntemler geliştirilmiştir (Xanthopoulou, Bakas, ve Triantafyllopoulos, 2021). Bununla birlikte, açıklanabilir YZ sistemlerinin üretim ortamlarında etkin ve güvenilir bir şekilde kullanılabilmesi için teknik, kurumsal ve etik zorlukların aşılması gerektiği belirtilmektedir. Veiber., Kazıl., Röder ve Binnig, 2020), açıklanabilir MÖ modellerinin karar vericiler tarafından anlaşılabilir hâle getirilmesinde karşılaşılan başlıca engelleri sistematik biçimde ele almıştır.

YZ ve MÖ teknikleri, veriden öğrenme ve öngörü üretme kabiliyeti sayesinde İSG alanında yeni ve proaktif uygulamalar geliştirilmesine imkân tanımaktadır. Bu potansiyelin somut örnekleri ilerleyen bölümlerde detaylı olarak ele alınacaktır.

#### **2.4 İş Sağlığı ve Güvenliğinde YZ Uygulamaları**

YZ ve MÖ tekniklerinin İSG alanındaki uygulamaları son yıllarda hızlı bir gelişim göstermiştir. Bu dönüşüm, sensör-IoT ağları, siber-fiziksel sistemler, büyük veri analitiği ve işbirlikçi robotik gibi Dördüncü Sanayi Devrimi bileşenlerinin sahaya girmesiyle ivme kazanmıştır (Malomane vd., 2022). YZ'nin entegrasyonu yalnızca güvenlik protokollerini iyileştirmekle kalmaz, aynı zamanda iş süreçlerinin dijitalleşmesini hızlandırarak tehlike tespiti, olay önleme ve müdahale sürelerinde önemli iyileşmeler sağlar.

YZ ve MÖ tekniklerinin İSG alanındaki uygulamaları son yıllarda hızlı bir gelişim göstermiştir. Bu dönüşüm, sensör-IoT ağları, siber-fiziksel sistemler, büyük veri analitiği ve işbirlikçi robotik gibi Dördüncü Sanayi Devrimi bileşenlerinin sahaya girmesiyle ivme kazanmıştır (Malomane vd., 2022). YZ'nin entegrasyonu yalnızca güvenlik protokollerini iyileştirmekle kalmaz, aynı zamanda çalışan refahına bütüncül bir yaklaşımı ilerleterek İSG alanında verimlilik ve hassasiyeti artıran köklü bir paradigma değişimi yaratır (El-Helaly, 2024). Benzer şekilde YZ güdümlü teknolojiler, kuruluşların sağlık ve güvenlik yaklaşımını kökten değiştirerek öngörücü içgörüler, gerçek zamanlı izleme ve risk azaltma stratejileri sunmakta; bu da yalnızca

kazaları ve tehlikeleri en aza indirmekle kalmayıp iş gücünün korunmasına yönelik daha proaktif ve hızlı tepki veren bir yaklaşımın yolunu açmaktadır (Shah ve Mishra, 2024). Bu teknolojilerin temel hedefleri; iş kazalarını ve meslek hastalıklarını önceden öngörmek, tehlikeli durumları gerçek zamanlı olarak algılamak ve İSG yönetiminde karar destek mekanizmaları sağlamaktır. Literatürde öne çıkan YZ destekli İSG uygulamaları üç ana başlık altında incelenebilir:

#### **(i) Kaza ve Yaralanma Öngörü Modelleri**

MÖ algoritmaları kullanılarak geçmiş iş kazası verilerinden gelecekteki risklerin tahmin edilmesi önemli bir uygulama alanıdır. Khairuddin ve arkadaşları (2022), ABD OSHA veri tabanındaki 66.405 iş kazası kaydını kullanarak kaza sonuçlarını (örneğin hastane yatışı veya uzuv kaybı) öngören bir model geliştirmiştir. Çalışmada, Support Vector Machines, Naive Bayes, Decision Tree, Random Forest, algoritmaları karşılaştırılmış; en yüksek doğruluk ve F1 skoru %89,5 oranıyla Random Forest modeli ile elde edilmiştir (Khairuddin vd., 2022).

You ve arkadaşları (2021), inşaat sahalarında iş güvenliğini artırmak amacıyla derin öğrenme tabanlı bir bilgisayarla görme sistemi geliştirmiştir. Bu sistem, çalışanların varlığını tespit etme, düşme risklerini değerlendirme ve kişisel koruyucu ekipman kullanımını izleme gibi işlevleri yerine getirmektedir. Özellikle, sanal ortamda oluşturulan sentetik veri setleri kullanılarak geliştirilen model, gerçek zamanlı izleme ve proaktif güvenlik yönetimi için etkili bir araç olarak önerilmektedir. Bu yaklaşım, iş kazalarının önlenmesine katkı sağlayarak inşaat sahalarında güvenliğin artırılmasına olanak tanımaktadır (You vd., 2021).

Bu öngörücü modeller, iş güvenliği uzmanlarının riskli durumları önceden tespit ederek koruyucu önlemler almasına olanak sağlamaktadır. Örneğin, gece vardiyalarında yeni işe başlayan çalışanlar için kaza riskinin yüksek olduğu tespit edildiğinde, eğitim ve vardiya planlamalarında düzenlemeler yapılabilir.

#### **(ii) Sensör Sistemleri ve Gerçek Zamanlı İzleme**

YZ, Nesnelerin İnterneti (IoT) tabanlı sensör sistemleri ile birlikte işyerlerinde gerçek zamanlı tehlike tespiti imkânı sunmaktadır. Ortam sensörlerinden (ısı, gaz, gürültü) ve

giyilebilir cihazlardan (akıllı baretler, bileklikler) elde edilen veriler, YZ algoritmaları ile analiz edilerek anlık riskler belirlenebilmektedir (Gao vd., 2022).

Örneğin, kamera destekli derin öğrenme sistemleri (örneğin YOLO, Faster R-CNN), çalışanların Kişisel Koruyucu Donanım (KKD) kullanımını otomatik olarak algılayarak uygunsuzluk durumunda uyarı verebilmektedir (Global Infrastructure Hub, 2020). Ayrıca, akıllı sensörler ile gaz sızıntısı, sıcaklık artışı gibi kritik durumlar tespit edilmekte ve anında alarm mekanizmaları devreye sokulmaktadır (Taproot, 2021).

Giyilebilir teknolojiler de İSG alanında yaygınlaşmaktadır. Biyometrik veri toplayan cihazlar sayesinde çalışanların kalp atış hızı, vücut sıcaklığı ve hareket verileri izlenmekte; YZ algoritmaları bu verilerden yorgunluk, stres ve uygunsuz duruş gibi risk faktörlerini belirleyebilmektedir. Çeşitli araştırmalar, akıllı baret ve giyilebilir algılayıcıların iş yerinde çarpışma riskini azaltmada etkili olduğunu göstermektedir. Geliştirilen görüntü tabanlı akıllı baret sistemi, çalışan ile operatöre eş-zamanlı görsel ve dokunsal uyarılar vererek tehlikelerin erkenden fark edilmesini ve güvenli şekilde uzaklaşmasını sağlamaktadır (Kim ve Choi, 2022). Buna paralel olarak, Bluetooth Low Energy işaretçileriyle entegre akıllı gözlükler 10 m'lik güvenlik yarıçapı içinde yaklaşan ekipmanı %100 başarıyla algılayarak yayalara gerçek zamanlı görsel alarm sunmakta ve yaya-makine çarpışmalarını önlemede yüksek potansiyel göstermektedir (Baek ve Choi, 2020). Çeşitli araştırmalar, akıllı baret ve giyilebilir algılayıcıların iş yerinde çarpışma riskini azaltmada etkili olduğunu göstermektedir. Hong Kong'da yürütülen yakın tarihli bir FDM çalışması, IoT tabanlı güvenlik uygulamalarında en kritik engellerin "giyilebilir sensörlerin verimlilik düşüşü", "teknik eğitim ihtiyacı" ve "sürekli izleme zorunluluğu" olduğunu göstermiştir (Tabatabaee vd., 2022). Huber ve arkadaşları (2025), endüstriyel iş güvenliği kapsamında YZ tabanlı sistemlerin kullanıcı güvenliği üzerindeki etkilerini değerlendirdikleri sistematik derlemede, sahada kullanılan sistemleri "önleyici", "tepkiyel" ve "olay sonrası müdahale" kategorilerinde sınıflandırmıştır. Giyilebilir cihazlardan çevresel sensörlere kadar farklı teknolojilerin; sadece fiziksel güvenliği değil, aynı zamanda kullanıcının stres, dikkat dağınıklığı ve karar yorgunluğu gibi psikolojik parametrelerini de etkilediği vurgulanmıştır. ISO/IEC 23894:2023 çerçevesinde 11 farklı güvenlik kriterine göre yapılan analizde, özellikle

açıklanabilirlik, veri gizliliği ve sürekli denetim eksikliklerinin pratik sahalarda hâlâ birer risk unsuru oluşturduğu bildirilmiştir. Bu bulgular, YZ destekli İSG sistemlerinin yalnızca teknolojik değil, aynı zamanda insan-merkezli tasarıma da ihtiyaç duyduğunu ortaya koymaktadır (Huber vd., 2025).

### **(iii) Karar Destek ve Yönetim Sistemleri**

Yapay zekâ, İSG profesyonellerinin karar alma süreçlerini desteklemek amacıyla veri analitiği ve uzman sistemler geliştirilmesinde de kullanılmaktadır. Örneğin, Birleşik Krallık Sağlık ve Güvenlik İdaresi (HSE) tarafından geliştirilen EASE (Estimation and Assessment of Substance Exposure) sistemi, kimyasal maruziyet tahmini için YZ tekniklerini kullanmaktadır (HSE, 2010).

Öngörücü bakım (predictive maintenance) sistemleri de makine ve ekipman arızalarını önceden tahmin ederek iş kazası riskini azaltmada önemli rol oynamaktadır. Sensörlerden gelen titreşim ve sıcaklık verileri analiz edilerek, ekipmanın arızaya yakın olduğu durumlar belirlenebilmekte ve erken müdahale imkânı sağlanmaktadır (Tixier vd., 2016).

Ayrıca doğal dil işleme (NLP) teknikleri kullanılarak kaza raporları ve risk değerlendirme dokümanları analiz edilmekte; ortak risk faktörleri ve kök nedenler otomatik olarak çıkarılmaktadır. Bu yöntem, yöneticilere daha hızlı ve etkili kararlar alabilme imkânı sunmaktadır.

Son yıllarda gelişen bütünleşik İSG yönetim platformları, sensör izleme, kaza analitiği ve görsel raporlama gibi özellikleri YZ destekli modüllerle birleştirerek İSG yönetiminde kapsamlı çözümler sunmaktadır.

## **2.5 Literatürde Yer Alan İSG'ye Yönelik Yapay Zeka Uygulamaları**

İş YZ ve veri analitiği, İSG alanında son yıllarda kazaların önceden tahmini, risk değerlendirmesi ve tehlikeli durumların tespiti için yaygın şekilde kullanılmaktadır. Literatürde, farklı sektörlerde (inşaat, madencilik, imalat, kimya vb.) MÖ, derin öğrenme ve uzman sistemler gibi YZ tabanlı yaklaşımlarla gerçekleştirilmiş çeşitli uygulama örnekleri mevcuttur. Bu bölümde, Türkçe literatür ve Türkiye’de yayımlanmış çalışmalar başta olmak üzere, İSG risk analizinde YZ’nin kullanıldığı benzer model ve yöntemler incelenmiştir. İncelenen çalışmalar kapsamında kullanılan

yöntemler, veri kaynakları, başarı ölçütleri ve teknik zorluklar özetlenerek sunulmaktadır.

### 2.5.1 Kazaların MÖ ile Öngörülmesi ve Risk Analizi

İş kazalarının önceden tahminine yönelik veri madenciliği ve MÖ uygulamaları literatürde önemli bir yer tutmaktadır. Örneğin, Atatürk Üniversitesi kaynaklı bir çalışmada yapay sinir ağları tabanlı bir karar destek sistemi geliştirilerek geçmişte yapılan risk değerlendirmeleri bilgisayara öğretilmiş; böylece sistem her yeni kararla kendini iyileştirerek risklerin zararını en aza indirecek öneriler sunabilmiştir. Benzer şekilde, Taçgın ve Sağır (2020) geçmiş kaza örneklerini içeren “Akıllı Bilgi Tabanı” adlı bir program geliştirmiş ve bu program ile kaza nedenlerini yüksek doğrulukla tahmin edebilmiştir. Bu uzman sistem, literatürdeki bir modele dayanarak kazaların kök nedenlerini otomatik olarak saptayabilmekte ve İSG profesyonellerine karar destek aracı sağlamaktadır.

Daha yakın tarihli çalışmalar, geniş ölçekli kaza verilerinin işlenmesiyle kazaların oluşumu veya sonuçlarını öngörmeyi hedeflemektedir. Karakaya Özkan ve Ulaş (2023), Türkiye’nin metal sektöründe 2007–2016 yılları arasında meydana gelen iş kazalarına ait verileri kullanarak Random Forest algoritması ile kazaların neden ve sonuçlarını tahmin etmeye çalışmışlardır. 10 katlı çapraz doğrulama ile model doğruluğunu artırarak yaklaşık %91.7 gibi yüksek bir doğruluk oranına ulaşmışlardır. Ayrıca yorumlanabilir MÖ literatüründe XGBoost tabanlı bir modelle şantiye kaynaklı “kayıp iş günü (LWD)” sayısını öngören, yaş, vardiya düzeni ve ekipman türünü en kritik belirleyiciler olarak rapor eden bir çalışma da bulunmaktadır (Kang vd., 2022). Bu özellik-önem sıralaması, dinamik risk matrislerindeki parametre ağırlıklarının veriye dayalı biçimde kalibre edilebileceğini göstermesi bakımından dikkate değerdir.

Benzer şekilde Tunçman ve arkadaşları (2024), tekstil sektöründe 89.963 iş kazası kaydını (2019–2021) analiz ederek iş kazası risk faktörlerini değerlendirmiş ve kaza sonucu oluşan yaralanma türlerini tahmin etmek üzere çeşitli yöntemler karşılaştırmıştır. SVM, Random Forest, XGBoost gibi algoritmaların denenip makro F-skor metriğine göre değerlendirildiği bu çalışmada, veri dengeleme ve hiperparametre optimizasyonu sonrasında en yüksek başarı %70 ile XGBoost modeliyle elde edilmiştir; SVM (%69) ve Extra Trees (%68) algoritmaları da yakın

yüksek performans göstermiştir. Model çıktılarının incelenmesiyle tahmin sonuçlarına en çok etki eden özelliklerin *kaza sebebi, kazaya neden olan maddesel etken, alt sektör ve firma büyüklüğü* olduğu belirlenmiştir. Bu tür sonuçlar, iş kazalarının nedenlerine dair önemli içgörüler sunarak proaktif önlemlerin alınmasına katkı sağlamaktadır.

### 2.5.2 Tehlikeli Durum ve Davranışların Görüntü İşleme ile Tespiti

Görsel veri üzerinden tehlikeli durumların tespiti ve kural ihlallerinin izlenmesi, yapay zekânın İSG'deki bir diğer önemli uygulama alanıdır. Özellikle iş yerlerinde kamera görüntülerinin otomatik analiziyle kişisel koruyucu donanım kullanımı, tehlikeli davranışlar veya oluşabilecek tehlikeler tespit edilebilmektedir. Bu kapsamda, Ferdous ve Ahsan (2022) inşaat sahalarında kişisel koruyucu donanım (KKD) denetimini otomatikleştirmek için YOLO algoritmasına dayalı bir derin öğrenme modeli geliştirmiştir. Yazarlar, farklı renkte baretler, iş yeleği ve güvenlik gözlüğü gibi toplam 8 sınıf içeren yeni bir görüntü veri seti oluşturmuş ve anchor-free bir nesne algılama modeli olan YOLOX ile eğiterek çeşitli versiyonlarını karşılaştırmışlardır. En iyi model yaklaşık %89–90 oranında ortalama doğruluk (mAP) elde ederek sahadaki KKD kullanımının tespitinde oldukça başarılı bulunmuştur. Bu sayede, kalabalık ve dinamik şantiye ortamlarında dahi çalışanların baret ve diğer KKD ekipmanlarını takıp takmadığı gerçek zamanlı izlenebilir hale gelmiştir. Literatürde benzer şekilde baret ve iş güvenliği ekipmanı tespiti üzerine farklı derin öğrenme yaklaşımları da geliştirilmiş ve genellikle %85–90 bandında doğruluklarla yüksek performans rapor edilmiştir.

Görüntü işlemenin bir diğer kullanım alanı, endüstriyel ortamlarda tehlikeli durumların erken saptanmasıdır. Özellikle kimya ve enerji sektörlerinde, gaz kaçaqları gibi tehlikelerin gerçek zamanlı tespiti hayati önemdedir. Shi ve arkadaşları (2020), kızılötesi kameralarla izlenen endüstriyel ortamlarda tehlikeli gaz sızıntılarını anında belirlemek amacıyla Faster R-CNN tabanlı bir derin öğrenme modeli geliştirmiştir. Bu model, kızılötesi görüntülerdeki gaz bulutu emarelerini öğrenerek gerçek zamanlı kaçak tespiti yapabilmekte ve olası patlayıcı/toksik gaz birikimlerini hızla saptayabilmektedir. Söz konusu çalışmada, yüksek başarı elde edilmesine rağmen bazı teknik zorluklar da not edilmiştir: Örneğin, derin öğrenme modelinin eğitimi için geniş ve dengeli bir görüntü verisi gerekmekte, ancak farklı koşulları kapsayan standart bir gaz kaçak görüntü veri seti bulunmamaktadır. Ayrıca düşük yoğunluklu gaz

bulutlarının kızılötesi görüntülerde arka plan gürültüsüyle karışması ve gaz bulutu kenarlarının belirsiz olması, algılama performansını olumsuz etkileyebilecek unsurlar olarak belirtilmiştir. Bu bağlamda, daha yeni araştırmalarda YOLO gibi daha hızlı algılama yapan algoritmalar ve veri artırma, görüntü iyileştirme teknikleriyle bu sorunların aşılmasına çalışılmaktadır.

### 2.5.3 Sensör Verileri ve IoT Tabanlı İSG Uygulamaları

İş güvenliği risk analizinde giyilebilir sensörler, IoT cihazları ve zaman serisi verilerin kullanımı da literatürde yaygın şekilde incelenmiştir. Özellikle ortamdaki fiziksel büyüklüklerin sürekli izlenmesi ve anomali tespiti, kazaları önlemede kritik rol oynar. İnşaat ve bakım işlerinde yüksekte çalışma kaynaklı düşme tehlikelerini önlemek amacıyla, ivmeölçer, jiroskop ve barometre gibi sensörler içeren akıllı sistemler geliştirilmiştir. Örneğin, Choo ve diğerleri (2023) yüksekte çalışan işçilerin durumunu takip eden ve gerektiğinde otomatik emniyet önlemleri alan bir giyilebilir cihaz sistemi tasarlamıştır. Bu sistemde, barometrik basınç sensörü ile işçinin rakımı ölçülmekte, IMU (Inertial Measurement Unit) sensöründen alınan ivme ve açısal hız verileriyle de hareket durumu izlenmektedir. Elde edilen veriler yorumlanarak bir işçinin belirli bir yüksekliğe çıktığı otomatik olarak algılanabilmekte ve emniyet kancası gibi koruyucu ekipmanlar devreye sokulabilmektedir. Çalışma, gerçek saha denemeleriyle yüksekte çalışma ve normal zemin faaliyetlerini başarıyla ayırt edebilmiştir. Bu tür sensör tabanlı erken uyarı sistemleri, özellikle düşme olaylarının en sık ve ölümcül kazalardan olduğu inşaat sektöründe, ciddi yaralanmaların önüne geçmek için umut vaat etmektedir.

Madencilik gibi sektörlerde ise ortam sensörlerinden gelen gaz, sıcaklık, basınç verilerinin analiziyle tehlikeli durumların öngörülmesi hedeflenir. Gao ve arkadaşları (2024), kömür madenlerinde metan gazı birikimi gibi riskleri önceden tahmin edebilmek amacıyla uzun kısa süreli bellek ağları (LSTM) ile gelişmiş bir zaman serisi analiz modeli geliştirmiştir. Bu yaklaşımda, sensör verilerine dalgacık eşikli gürültü giderme (WTD) uygulanarak parazitler temizlenmiş, ardından faz uzayı yeniden yapılandırma (PSR) yöntemiyle verinin kaotik davranışı daha iyi temsil edilmiştir. Elde edilen işlenmiş veri, LSTM derin öğrenme modeliyle eğitilerek gelecekteki gaz konsantrasyon seviyeleri yüksek doğrulukla tahmin edilmiştir. Önerilen WTD-PSR-LSTM modeli, geleneksel yöntemlere kıyasla tahmin hatasını (MAE ve RMSE

değerlerini) %80'in üzerinde azaltarak gaz birikimi trendlerini çok daha isabetli bir şekilde öngörebilmiştir. Bu sayede, özellikle madencilik ortamlarında gaz tehlikelerine karşı erken uyarılar daha güvenilir bir temele kavuşmaktadır. Modelin sağladığı bu iyileşme, saha uygulamalarında ventilasyon kontrolü ve acil tahliye gibi hayati kararların zamanında alınmasına destek olabilecek önemli bir kazanımdır.

#### **2.5.4 İşbirlikçi Robotik ve Diğer Uygulamalarda Güvenlik**

YZ teknikleri, yalnızca doğrudan kaza tahmini veya algılama için değil, işyeri ortamının genel güvenliğinin sağlanmasında da kullanılmaktadır. İnsan-robot işbirliğinin bulunduğu akıllı üretim ortamlarında, sensör füzyonu, bilgisayarlı görü ve karar destek sistemleriyle işçilerin güvenliğinin temin edilmesi üzerine çalışmalar mevcuttur. Örneğin, Segura ve çalışma arkadaşları (2022) imalat sektöründe insan-robot etkileşimli sistemlerde güvenlik konusunda bir derleme sunmuş, mevcut güvenlik standartlarına ek olarak YZ destekli izleme teknolojilerinin entegrasyonunu incelemiştir. Bu kapsamlı araştırmada, işbirlikçi robotlu ortamlarda halen teknoloji merkezli yaklaşımların baskın olduğu ancak nihai hedefin insan merkezli bir güvenlik yaklaşımı olması gerektiği vurgulanmaktadır. Yazarlar, üretim hatlarında sensörler, vizyon sistemleri ve gelişmiş denetim algoritmaları ile kazaların önlenebileceğini belirtirken, YZ uygulamalarının ISO/TS 15066 gibi kollaboratif robot güvenlik standartları ile birlikte ele alınması gerektiğine dikkat çekmiştir. Bu tür çalışmalar, Endüstri 4.0 süreçlerinde “*önce güvenlik*” prensibinin sürdürülebilmesi için YZ'nin nasıl bir rol oynayacağına dair yol göstericidir.

Sonuç olarak, literatürde YZ destekli İSG uygulamalarının pek çok örneği bulunmaktadır. Kazaların öngörülmesi için sınıflandırma ve tahminleme algoritmaları, tehlikelerin tespiti için derin öğrenme tabanlı görüntü işleme ve gerçek zamanlı sensör analizleri, iş ortamının denetimi için uzman sistemler ve akıllı karar destek araçları giderek artan bir şekilde kullanılmaktadır. Bu çalışmaların ortak noktası, İSG performansını iyileştirmesi ve önleyici yaklaşımları güçlendirmesidir. Ancak literatürde sıkça belirtildiği üzere, YZ uygulamalarının başarısı büyük ölçüde kaliteli veri teminine, doğru model seçimine ve insan faktörünün hesaba katılmasına bağlıdır. Gelecekte, daha kapsamlı veri setlerinin oluşturulması, farklı sektörler arasında bilgi paylaşımı ve YZ sistemlerinin İSG profesyonellerinin deneyimiyle bütünleştirilmesi sayesinde, işyerlerinde sıfır kaza hedefine bir adım daha yaklaşılması beklenmektedir.

### 2.5.5 Literatürdeki Boşluklar ve Bu Çalışmanın Yeri

Son yıllarda İSG alanında yapay zeka uygulamaları artış gösterse de, literatürde bir dizi önemli boşluk bulunmaktadır. Öne çıkan boşluklar şunlardır:

- **Sektör-üstü entegre sistem eksikliği:** Literatürde genellikle sektöre özgü yapay zeka temelli çözümler önerilirken, birden çok sektörü kapsayan genel bir İSG risk yönetimi platformuna dair çalışmalar sınırlıdır. Örneğin Niu ve ark. (2018), inşaat sektöründe “üçüncü dalga” olarak tanımladıkları AI destekli bir İSG yönetim sistemi önerse de, bu yaklaşım hâlâ başlangıç aşamasında olup geniş çapta benimsendiği söylenemez (Niu vd., 2018). Bu durum, farklı iş kolları arasında ortak bir yapay zeka tabanlı İSG sisteminin eksik olduğunu göstermektedir.

- **Modellerin genellenebilirlik ve transfer öğrenme sınırlamaları:** Mevcut çalışmalar genellikle belirli işletme veya coğrafi konfigürasyonlara dayandığından, geliştirilen modellerin farklı koşullara aktarımı zor olmaktadır. Örneğin, literatürdeki yapay zeka sistemleri genellikle sınırlı sayıdaki işyerinde incelenmiş, coğrafi çeşitlilik kısıtlı olduğundan sonuçların genellenebilirliği azalmakta; küçük işletmeler veya kırsal bölgelerde aynı performansın sağlanması belirsiz kalmaktadır (Fisher vd., 2023).

- **Veri kalitesi, standartlaştırma ve Türkiye’ye özgü veri eksikliği:** Yapay zeka modellerinin başarısı büyük ölçüde veri kalitesine bağlıdır. Literatürde iş kazası ve risk verilerinin içeriğinde tutarsızlıklar, eksik etiketlemeler gibi sorunlar bulunmakta, bu verilerin daha kapsamlı ve doğru kayıtlar içerecek şekilde iyileştirilmesi gerektiği vurgulanmaktadır (Tiikkaja vd., 2024). Ayrıca, güvenlik yönetiminde endüstri özelinde standart protokoller ve veri formatları henüz olgunlaşmamıştır; standartlaştırılmış veri yapıları ve yönergeler geliştirildiğinde teorik çalışmalardan pratik uygulamalara köprü kurulacağı belirtilmiştir (Bérastégui, 2024). Türkiye özelinde ise İSG verilerinin toplanması ve paylaşılması konusunda sınırlı altyapı ve kaynak bulunmaktadır.

- **Etik, gizlilik ve yasal düzenlemelerin yetersizliği:** Yapay zeka uygulamalarının etik ve yasal boyutları çoğu çalışmada göz ardı edilmektedir. Mevcut literatür, şirketlerin AI projelerini planlarken etik, yasal ve toplumsal etkileri dikkate alması gerektiğini vurgulamaktadır. Veri gizliliği ve mahremiyet konularının (kişisel verilerin

korunması, anonimleştirme vb.) ihmal edilmesi, sisteme güveni zedeleyen önemli bir boşluktur. Ayrıca, şeffaf izleme mekanizmaları ve algoritma denetimleri gibi düzenleyici yaklaşımlar henüz yeterince ele alınmamıştır (Fiegler-Rudol vd., 2025). Bu bağlamda, Huber ve arkadaşları (2025) tarafından gerçekleştirilen sistematik incelemede, endüstriyel iş güvenliğinde kullanılan YZ tabanlı sistemlerin kullanıcı güvenliği üzerindeki etkileri çok boyutlu olarak ele alınmıştır. Çalışmada, sistemlerin yalnızca fiziksel güvenliği değil; aynı zamanda kullanıcı üzerindeki stres, dikkat dağınıklığı ve karar yorgunluğu gibi psikolojik etkileri de içermesi gerektiği vurgulanmıştır. Ayrıca, ISO/IEC 23894:2023 standardı çerçevesinde yapılan değerlendirmede, açıklanabilirlik, izlenebilirlik ve veri güvenliği konularında ciddi yapısal eksiklikler olduğu ve bu eksikliklerin sahadaki kullanıcı güvenliğini azalttığı belirtilmiştir. Bu sonuçlar, YZ sistemlerinin sadece teknik doğruluk değil, kullanıcı deneyimi ve etik tasarım açısından da değerlendirilmesi gerektiğini göstermektedir (Huber vd., 2025).

- **Açıklanabilir Yapay Zeka (XAI) ve kullanıcı güven eksikliği:** Kullanıcılar ve İSG uzmanları, yapay zeka modellerinin karar mekanizmalarını anlamakta zorlanmaktadır. Literatür, model iç işleyişinin karanlık kutu etkisinin güveni zayıflattığını; bu nedenle, açıklanabilir AI yöntemleri ile sistem çıktılarının anlaşılabilir kılınmasının güveni artıracığına dikkat çekmektedir (Fisher, Flynn, Pratap ve Vietas, 2023). Özetle, kullanıcı dostu ve şeffaf bir yapay zeka altyapısı eksiktir.

**Bu çalışmada geliştirilecek YZ Destekli Genel Risk Yönetimi Sistemi**, yukarıdaki boşlukların kapatılmasına katkı sunacak şekilde tasarlanmıştır. Örneğin:

- **Çok sektörlü entegre yapı:** Tasarlanan sistem, yalnızca tek bir iş koluna değil, farklı sektörlerde uygulanabilecek modüler bir mimariye sahiptir. Bu sayede, mevcut örneklerdeki gibi tek bir sektöre odaklanmak yerine genel bir risk yönetimi çerçevesi oluşturularak “sektör-üstü” bir çözüm sunulacaktır (Segura vd., 2022).

- **Genişletilmiş model genellenabilirliği:** Sistem, mümkün olduğunca çeşitli işletme ve koşullardan derlenen veri setleri ile eğitilecek ve test edilecektir. Böylece modelin farklı işyeri tiplerine ve Türkiye’ye özgü şartlara uyumu güçlendirilmiş olacak; gerektiğinde transfer öğrenme teknikleriyle yeni senaryolara adapte olma kabiliyeti geliştirilecektir (Gao vd., 2024).

- **Yüksek veri kalitesi ve standartlaştırma:** Sistem kapsamında kullanılacak verilerin doğruluğu ve tutarlılığı için veri ön işleme, temizleme ve etiketleme süreçleri özenle gerçekleştirilecektir. Ayrıca, İSG verilerinin tek tip formatta toplanması ve veri standardı oluşturulması hedeflenecektir. Bu sayede, literatürde önerilen veri kalitesi gereksinimleri karşılanacak (Tiikkaja vd., 2024) ve standart protokollerin uygulamasıyla hem analiz doğruluğu hem de pratik fayda artırılabilecektir (Bérastégui, 2024). Özellikle Türkiye’den temin edilen yerel veriler sisteme entegre edilerek bölgesel gereksinimler gözetilecektir.

- **Etik ve yasal uyumluluk:** Sistem tasarımında kullanıcı gizliliği ve veri güvenliği ön planda tutulacaktır. Kişisel veriler anonimleştirilerek işlendiği için KVKK ve diğer düzenlemelere uyum sağlanacaktır. Ayrıca algoritmaların adil ve tarafsız olması için gerekli etik kontroller ve denetimler planlanacaktır.

- **Dijital İkiz (Digital Twin) Uygulamaları Eksikliği:** Fiziksel varlıkların ve süreçlerin gerçek zamanlı veri akışı ile güncellenen sanal kopyalarını oluşturan dijital ikiz teknolojileri, ekipman arızası, yangın veya patlama gibi “ne olur” senaryolarını simüle ederek proaktif risk yönetimi imkânı sunar. Ancak literatürde hâlen ölçeklenebilir, sektörler arası dijital ikiz çözümleri sınırlıdır; bu çalışma, oluşturulacak modüler mimari ile dijital ikiz entegrasyonunu da destekleyerek bu boşluğu kapatmayı hedefleyecektir (Tang, 2024).

- **Açıklanabilirlik ve kullanıcı güveni:** Geliştirilecek sistem, kararları kullanıcıya açıklayan bileşenler içerecektir. Örneğin, risk tahminlerinin temelini oluşturan faktörler görsel ve metinsel olarak raporlanacak, kullanıcı arayüzünde alınan kararlar net olarak gösterilecektir. Böylece “karanlık kutu” etkisi azaltılarak kullanıcıların sisteme olan güveni artırılabilecektir (Fisher, Flynn, Pratap ve Vietas, 2023; Fiegler-Rudol vd., 2025).

### 3. GEREÇ ve YÖNTEM

#### 3.1 Araştırma Modeli ve Yaklaşımı

Bu tez çalışması, İSG alanında YZ tabanlı bir risk yönetimi sisteminin tasarımı ve uygulanmasını hedefleyen uygulamalı (applied) nitelikte bir araştırmadır. Araştırmanın temel amacı, farklı iş kollarında karşılaşılabilecek risk türlerini YZ

destekli bir modelle analiz ederek, daha hızlı, doğru ve proaktif risk değerlendirme süreçleri geliştirmektedir.

Araştırmada benimsenen yaklaşım, veri odaklı analitik bir çerçeve üzerine kurulmuştur. Model geliştirme süreci, iş kazası ve tehlike senaryolarına ilişkin verilerin analiz edilmesiyle başlamış; bu süreçte hem literatürde yer alan örnek veri kümelerinden yararlanılmış hem de yüksek doğrulukta öğrenme sağlamak amacıyla çeşitli sektör ve risk gruplarını temsil eden simüle veri setleri oluşturulmuştur. Veri üretimi, Google Colab ortamında Python dili kullanılarak yapılmış, bu sayede düşük donanımlı cihazlarda dahi yüksek kapasiteli analizlerin gerçekleştirilmesi mümkün olmuştur.

Geliştirilen sistemin modeli, denetimli öğrenme (supervised learning) yaklaşımı temel alınarak inşa edilmiştir. Giriş (input) verileri; çalışan yaşı, deneyimi, maruz kalınan fiziksel, kimyasal, biyolojik, ergonomik ve çevresel risk faktörlerini içermektedir. Hedef (output) değişkenler ise beşli bir etki sınıflaması çerçevesinde tanımlanmıştır: “Yaralanma”, “Ölüm”, “İşten Uzaklaştırma”, “Transfer” ve “Diğer Vakalar”. Bu sınıflar, çoklu hedefli (multi-output) sınıflandırma problemine uygun olarak yapılandırılmıştır.

Modelleme sürecinde CRISP-DM (Cross Industry Standard Process for Data Mining) metodolojisi temel alınmıştır. Süreç şu aşamalardan oluşmaktadır:

1. **İş Probleminin Tanımlanması:** İSG uzmanlarının karar süreçlerini destekleyecek, sektör bağımsız çalışabilecek bir tahmin modeli gereksinimi belirlenmiştir.
2. **Veri Toplama ve Hazırlama:** Simüle veriler oluşturulmuş, özellik mühendisliği (feature engineering) ile model girişleri optimize edilmiştir.
3. **Modelleme:** Random Forest, XGBoost, kalibre edilmiş XGBoost ve hiperparametre optimizasyonu yapılmış modeller denenmiştir.
4. **Değerlendirme:** Model başarıları doğruluk, F1 skoru gibi metriklerle karşılaştırılmış; ayrıca açıklanabilirlik ve öneri üretme kapasitesi dikkate alınmıştır.


**5. Uygulama:** Geliştirilen modelin sonuçları bir web arayüzü ile görselleştirilmiş, kullanıcılara yönelik önerilerle desteklenmiştir.

Bu beş aşamalı sürecin bütüncül işleyişi, Şekil 3.1’de şematik olarak sunulmuştur. Şekilde, simülasyon verisinin önce ön-işleme ve özellik mühendisliği adımlarından geçirildiği, ardından verinin %80’inin hiperparametre araması (GridSearchCV + Optuna) ve 10-fold CV içeren eğitim-doğrulama kümesine, %20’sinin ise modelin nihai performansını ölçmek amacıyla saklanan hold-out test kümesine ayrıldığı görülmektedir. En iyi ayarlanmış Random Forest ve XGBoost modelleri, hem çapraz doğrulama metrikleri hem de hold-out test sonuçları üzerinden değerlendirildikten sonra Flask tabanlı web arabirime gömülmüş ve böylece saha uygulamaları için gerçek-zamanlı tahmin servisi hâline getirilmiştir. Ayrıca diyagram, özellik önem analizi adımının değerlendirme aşamasına entegre edildiğini göstererek karar vericilere hangi risk faktörlerinin model çıktısına en fazla etki ettiğini görsel olarak sunmaktadır. Bu açıklanabilirlik katmanı, modeli “kara kutu” olmaktan çıkarıp İSG uzmanlarının müdahale stratejilerini veri-temelli biçimde planlamasına olanak tanır.

Bu bağlamda, model çıktılarının yalnızca analiz edilen verilere dayalı sonuçlar üretmesi değil, aynı zamanda kullanıcıya açık, sezgisel ve yorumlanabilir biçimde sunulması hedeflenmiştir. Bu sayede, teknik altyapıya sahip olmayan saha personelinden stratejik karar verici konumdaki yöneticilere kadar geniş bir kullanıcı yelpazesi, sistemin sunduğu çıktıları doğrudan anlayabilmekte ve hızla eyleme geçirebilmektedir. Görsel destekli bu yaklaşım, yalnızca sayısal doğrulukla sınırlı kalmamakta; aynı zamanda kullanıcıyı karar sürecinin aktif bir bileşeni hâline getirerek, sistem ile insan arasındaki etkileşimi daha güçlü kılmaktadır. Bu da yalnızca tahmin yapan bir yazılım tasarımı değil, aynı zamanda bilgi akışını sadeleştiren ve karar süreçlerini şeffaflaştıran bir yönetim aracı üretildiği anlamına gelmektedir.

İş sağlığı ve güvenliği gibi çok boyutlu, sürekli değişen ve insan hayatını doğrudan etkileyen bir alanda, model çıktılarının nasıl sunulduğu en az ne kadar doğru tahmin ettiğimiz kadar önemlidir. Bu nedenle kullanıcı arayüzü, yalnızca görsel estetik kaygılarla değil; bilişsel yükü azaltacak biçimde, dikkat dağıtmayan sade bir yapıda tasarlanmıştır. Kullanıcıların risk senaryolarını farklı algoritmalarla karşılaştırabilmesi, risk sınıflarına ait olasılıkları grafiklerle görebilmesi ve her bir

tahmin sonucunu tablo formatında inceleyebilmesi; modelin yalnızca teknik değil aynı zamanda operasyonel başarısının da artırılmasına katkı sağlamaktadır. Modelin tahminleme sürecini kullanıcıya saydam şekilde aktarması, açıklanabilir yapay zekâ (XAI) ilkesinin pratikteki karşılığıdır. Bu sayede, sistem yalnızca bir analiz aracı değil, aynı zamanda veri temelli önlem planlarının geliştirilebileceği, önleyici İSG stratejilerinin oluşturulabileceği bir karar destek platformuna dönüşmektedir. Kullanıcı geri bildirimleri ve saha verileriyle desteklenerek sürdürülebilirliği sağlanan bu yapı, dijital İSG uygulamaları arasında fark yaratan yenilikçi bir örnek olarak değerlendirilebilir.



Şekil 3.1 Model eğitim–test diyagramı (CRISP-DM adımları)

Son olarak, eğitim-test boru hattına eklenen geri besleme oku, web arayüzünden toplanacak yeni saha verilerinin belirli periyotlarda sisteme yüklenerek modelin yeniden eğitilmesini ve performansın canlı tutulmasını temin eden döngüsel geliştirme mantığını temsil etmektedir. Çalışma, yalnızca teknik model geliştirmeye sınırlı kalmamış, aynı zamanda Flask tabanlı bir kullanıcı arayüzü aracılığıyla işlevsel bir web prototipi de sunmuştur. Bu sayede, model çıktıları sadece akademik bağlamda değil, saha uygulamaları için de yorumlanabilir ve kullanılabilir hale getirilmiştir. Sonuç olarak bu araştırma modeli, İSG alanında YZ tabanlı risk değerlendirme süreçlerini hem kuramsal hem de pratik olarak geliştirmeyi hedefleyen, uygulanabilirliği yüksek ve tekrarlanabilir bir yapıya sahiptir.

### 3.2 Veri Kaynakları ve Veri Toplama Süreci

Bu çalışmada kullanılan veriler, hazır veri setlerinden değil, araştırmacı tarafından geliştirilen simülasyon temelli iş sağlığı ve güvenliği (İSG) senaryolarına dayanmaktadır. Gerçek iş kazası kayıtlarına erişimin sınırlı olması, aynı zamanda bu verilerin etik, hukuki ve veri güvenliği düzenlemelerine tabi olması nedeniyle, Python programlama dili aracılığıyla yapay ancak gerçeklik düzeyi yüksek veri kümeleri oluşturulmuştur. Bu veri kümeleri, İSG alanında literatür taramasıyla belirlenen temel tehlike sınıfları, risk faktörleri ve kazaya yol açabilecek maruziyet koşulları esas alınarak kurgulanmıştır.

Veri üretim sürecinde, bireysel demografik değişkenler (örneğin yaş ve deneyim yılı), ortamsal koşullar (gürültü, sıcaklık, aydınlatma yetersizliği vb.), kimyasal ve biyolojik maruziyetler (gaz, toz, solvent, bakteri, virüs, mantar, parazit gibi) ve fiziksel riskler (düşme, sıkışma, kesilme, elektriksel tehlikeler vb.) birlikte değerlendirilmiştir. Her bir değişkenin, gerçekteki olasılık dağılımlarına ve risk oluşum senaryolarına dayalı olarak modellenmesine dikkat edilmiştir. Örneğin, genç ve deneyimsiz bireylerin yüksek sıcaklık ve izolasyon eksikliği gibi faktörlere maruz kalma olasılığı arttıkça, ciddi bir kazanın meydana gelme riski de artırılarak veriler ağırlıklandırılmıştır. Bu yaklaşım sayesinde oluşturulan veri seti, hem teorik geçerliliğe hem de pratikteki karşılıklara uygun şekilde yapılandırılmıştır. Simüle edilen bu veri kümesinde yer alan değişkenler, yalnızca makine öğrenimi algoritmalarını beslemekle kalmamış; aynı zamanda İSG bağlamında çok boyutlu risk analizi yapılabilmesine de olanak sağlamıştır.

Tablo 3.1 Simülasyon tabanlı İSG veri kümesinden örnek kayıtlar

| Değişkenler          | Örnek 1 | Örnek 2 | Örnek 3 | Örnek 4 | Örnek 5 |
|----------------------|---------|---------|---------|---------|---------|
| Deneyim (Yıl)        | 14      | 28      | 7       | 35      | 21      |
| Yaş                  | 63      | 43      | 60      | 64      | 48      |
| Gürültü              | 1       | 0       | 0       | 0       | 0       |
| Titreşim             | 0       | 1       | 1       | 0       | 0       |
| Ergonomi             | 0       | 0       | 0       | 0       | 1       |
| Sıcaklık             | 0       | 0       | 1       | 1       | 1       |
| Aydınlatma Eksikliği | 0       | 1       | 1       | 1       | 0       |
| Solvent              | 0       | 0       | 1       | 1       | 0       |
| Gaz                  | 0       | 1       | 1       | 1       | 1       |
| Toz                  | 0       | 1       | 1       | 0       | 0       |
| Yanıcı Madde         | 0       | 1       | 0       | 1       | 0       |
| Bakteri              | 1       | 1       | 0       | 0       | 1       |
| Virüs                | 0       | 0       | 1       | 1       | 1       |
| Mantar               | 0       | 0       | 1       | 0       | 0       |
| Parazit              | 1       | 1       | 0       | 1       | 0       |
| Ezilme               | 0       | 0       | 1       | 1       | 0       |
| Kesilme              | 1       | 1       | 0       | 0       | 1       |
| Sıkışma              | 0       | 1       | 1       | 0       | 0       |
| Delinme              | 1       | 0       | 1       | 1       | 1       |
| Kaçak Akım           | 0       | 1       | 1       | 0       | 1       |
| İzolasyon Eksikliği  | 1       | 1       | 1       | 1       | 1       |
| Yıldırım Riski       | 0       | 1       | 0       | 0       | 0       |
| İskele               | 1       | 0       | 1       | 0       | 1       |
| Merdiven             | 1       | 0       | 0       | 1       | 1       |
| Çatı Çalışması       | 0       | 0       | 1       | 1       | 0       |
| Düşme                | 0       | 1       | 0       | 0       | 1       |
| Sektör               | Sağlık  | Çevre   | İnşaat  | Üretim  | Çevre   |
| Yaralanma            | 1       | 0       | 0       | 1       | 0       |
| Ölüm                 | 0       | 0       | 0       | 0       | 0       |
| İşten Uzaklaştırma   | 0       | 1       | 1       | 1       | 1       |
| Transfer             | 1       | 0       | 0       | 0       | 0       |
| Diğer Vakalar        | 0       | 0       | 0       | 1       | 0       |

Modelin eğitiminde kullanılan veri yapısına ilişkin beş temsili örnek kayda ait içerik, Tablo 3.1’de gösterilmiştir. Sütunlar, modelin giriş değişkenlerini; satırlar ise çeşitli iş ortamlarını ve kaza senaryolarını temsil eden simülasyonları ifade etmektedir. Veri kümesinin tamamı bu tezde sınırlı sayıda örnek ile temsil edilmekle birlikte, model eğitimi için toplamda yüzlerce kayıt üretilmiştir.

Ek bölümde ayrıca genişletilmiş veri yapısına ve kodlara yer verilmesi planlanmış olsa da, son yapılandırmada tüm örnekler doğrudan gövde metin içerisinde aktarılmıştır. Modeli besleyen eğitim ve test verilerinin ayrımı, ön işleme adımları ve ilgili Python kodu ise Ek B’de ayrıntılı biçimde sunulmuştur.

- **Veri Üretimi Süreci**

Simüle veriler, İSG literatüründe yer alan temel risk faktörleri ve kaza türleri dikkate alınarak oluşturulmuştur. Özellikle aşağıdaki değişken grupları simülasyonlara dahil edilmiştir:

- **Demografik Veriler:** Yaş, deneyim yılı gibi bireysel özellikler,
- **Ortamsal Risk Faktörleri:** Gürültü, sıcaklık, aydınlatma eksikliği, ergonomi sorunları vb.,
- **Kimyasal ve Biyolojik Tehlikeler:** Gaz, toz, solvent, bakteri, virüs gibi maruziyetler,
- **Fiziksel Riskler:** Düşme, ezilme, kesilme, elektriksel tehlikeler vb.,
- **Hedef Değişkenler:** Yaralanma, ölüm, işten uzaklaştırma, transfer gibi kaza sonuçları.

Bu veriler, **rastgele sayı üreticileri** ile değil; her değişkenin gerçeklik düzeyi ve olasılık dağılımı gözetilerek yapay olarak modellenmiştir. Örneğin, yüksek sıcaklık ortamında çalışan deneyimsiz bireylerin ciddi kaza geçirme olasılığı daha yüksek olacak şekilde ağırlıklandırılmıştır. Bu sayede model eğitiminde kullanılacak veri seti, teorik olarak geçerli ve tutarlı olacak biçimde kurgulanmıştır.

- **Veri Hazırlama ve Ön İşleme**

CSV dosyasının okunması, sütun seçimi ve eksik değer bulunmadığının doğrulanması işlemleri Bkz. Ek A. Simüle edilen veri setleri üzerinde şu işlemler gerçekleştirilmiştir:

- **Eksik veri kontrolü:** Simülasyon aşamasında boş veri üretilmediği için klasik eksik veri problemleri gözlenmemiştir.
- **Aykırı değer analizi:** Anlamlı olmayan aşırı değerler filtrelenmiş, istatistiksel tutarlılık kontrolü sağlanmıştır.
- **Etiket kodlama ve dönüştürme:** Niteliksel değişkenler (örneğin "Var/Yok" türü faktörler) binary sayısal forma dönüştürülmüştür.
- **Özellik mühendisliği:** İlgili değişkenler arasında korelasyon analizi yapılmış, çoklu doğrusal bağlantı riski azaltılmıştır.
- **Veri bölme işlemi:** Simüle edilen veri seti, eğitim ve test olmak üzere %80–%20 oranında bölünmüştür. Eğitim verisi ayrıca çapraz doğrulama amacıyla 5-fold veya 10-fold olarak tekrar ayrıştırılmıştır.
- **Etik ve Hukuki Uygunluk:** Bu çalışmada kullanılan tüm veriler, gerçek bireylere ait kayıtlar içermeyen, anonim ve kurgu veriler olduğundan Kişisel Verilerin Korunması Kanunu (KVKK) ve GDPR gibi mevzuatlara tamamen uygundur. Araştırmada herhangi bir üçüncü kişiye ait özel veri toplanmamış ya da işlenmemiştir.

Veri oluşturma ve ön işleme süreci, YZ destekli risk sınıflandırma sisteminin sağlıklı biçimde eğitilmesi ve test edilmesi için gerekli altyapıyı oluşturmuştur. Simülasyon temelli yaklaşım, literatürdeki birçok benzer çalışmada da görüldüğü üzere, gerçek verilere erişimin kısıtlı olduğu durumlarda geçerli ve uygulanabilir bir yöntem olarak kabul edilmektedir.

### **3.3 Geliştirilen YZ Modeli**

Yürütülen çalışma kapsamında, İSG için bir YZ destekli risk tahmin modeli geliştirilmiştir. Modelin genel amacı, geçmiş verilerden öğrenerek gelecekte hangi iş ortamlarında veya koşullarında yüksek kaza riski bulunduğunu öngörebilmektir. Bu

bağlamda model, iş yerlerine ait çeşitli girdi özelliklerini alıp bunlara dayanarak bir risk skoru veya risk seviyesi sınıfı çıktısı üretmektedir. Örneğin modelin girdi vektörü bir işin özelliklerini (sektör, çalışma saatleri, çalışan tecrübesi, ekipman durumu vb.) temsil ederken, çıktı bu iş ortamı için kaza riskinin “düşük”, “orta” veya “yüksek” olduğuna dair bir sınıflandırma olabilir. Alternatif bir senaryoda çıktı, belirli bir süre içinde kaza yaşanıp yaşanmayacağına ilişkin bir tahmin (örneğin “kaza gerçekleşecek/gerçekleşmeyecek” şeklinde ikili sınıflandırma) de olabilir. Bu tez kapsamında modelin çıktısı, önleyici risk yönetimine katkı sunacak şekilde yorumlanabilir kaza olasılığı bilgisi olarak tasarlanmıştır.

**Modelin giriş-çıkış yapısı:** Girdi değişkenleri, veri setlerinde ayrıntıları verilen faktörlerden oluşmaktadır. Bu girdiler yüksek boyutlu bir özellik uzayında model tarafından işlenir. Model, bu girdilere ilişkin daha önce gördüğü binlerce kayıt üzerinden öğrenilmiş olan örüntüleri kullanarak bir karar mekanizması oluşturur. Çıktı ise yukarıda belirtildiği gibi bir risk puanı veya sınıfıdır. Örneğin model bir iş kaydını değerlendirerek “yüksek risk” sınıfına atama yaparsa, bu çıktı o iş koşullarında ciddi bir iş kazası yaşanma olasılığının yüksek olduğuna işaret eder. Modelin verdiği kararlar, daha sonra iş güvenliği uzmanları tarafından detaylı olarak incelenebilir ve gerekli önleyici adımlar (ek eğitim, teçhizat iyileştirmesi, vb.) planlanabilir.

**Modelin işleyişi ve karar süreci:** Geliştirilen model bir denetimli MÖ algoritmasıyla uygulanmıştır. Öncelikle geçmiş verilerde hangi koşulların kazayla sonuçlandığı, hangilerinin sonuçlanmadığı öğrenilmiştir. Bu öğrenme süreci, seçilen algoritmanın verideki ilişkileri yakalaması ile gerçekleşir. Örneğin bir Decision Tree modeli söz konusu olduğunda, model veriyi if-then karar kuralları şeklinde bölerek riskli durumları belirleyen koşulları ortaya çıkarır. Basit bir kurguyla, model şu tür bir kural öğrenmiş olabilir: “Eğer çalışan tecrübesi < 1 yıl VE iş pozisyonu = yüksekte çalışma ise kaza riski = Yüksek”. Bu gibi kurallar, modelin iç mantığını oluşturur ve her yeni iş kaydı değerlendirildiğinde ilgili kurallar zinciri çalıştırılarak sonuç üretilir. Daha karmaşık bir model olan Random Forest kullanıldığında ise, yüzlerce böyle ağaç bir arada çalışarak çoğunluk oylaması yoluyla bir karar verir; bu sayede tek bir ağaçta olabilecek hatalar azaltılarak daha genelleştirilebilir (robust) bir tahmin elde edilir.

**Modelin amacı ve kullanım şekli:** Model, risk sınıflandırma ve tahmin amacıyla kurulmuştur. Böylece iş güvenliği uzmanları, modelin çıktılarını kullanarak hangi iş

birimlerinin veya koşullarının daha fazla dikkat gerektirdiğini önden tespit edebileceklerdir. Örneğin model, belirli bir şantiyede yüksekte düşme tehlikesinin çok yüksek olduğunu skorlayabilir; bu bilgi ilgili şantiyede ek önlemler (emniyet halatlarının kontrolü, çalışanlara ek eğitim vb.) alınmasını sağlamak için kullanılabilir. Modelin çıktıları, yönetim sistemi içinde bir gösterge paneli aracılığıyla sunulabilir ve zaman içinde risk skorlarındaki değişimler takip edilebilir. Bu bakımdan model, İSG yönetim sistemine entegre edilerek erken uyarı mekanizması rolü oynayacaktır.

Güvenilirlik açısından modelin doğrulukla kalibre edilmesi büyük önem taşır. Bu nedenle, model geliştirirken eğitilen algoritmanın aşırı uyum (overfitting) göstermemesine dikkat edilmiş, parametre ayarları çapraz doğrulama ile optimize edilmiştir. Ayrıca, modelin şeffaflığı da göz önünde bulundurulmuştur: Decision Tree tabanlı bir yöntem tercih edilmesinin sebeplerinden biri, böylelikle modelin öngörülerinin altında yatan etkenlerin daha kolay açıklanabilmesidir. Örneğin Random Forest modeli, değişken önem düzeylerini sunarak hangi faktörlerin risk üzerinde ne kadar etkili olduğunu ortaya koyabilir. Bu sayede model, açıklanabilir YZ ilkelerine de uygunluk gösterecektir.

Geliştirilen YZ modeli; geçmiş iş kazası verilerinden beslenen, uygulamalı bir MÖ yaklaşımıyla kurulan ve iş güvenliği risklerinin öngörülmesini hedefleyen bir sistemdir. Bu sistem, literatürdeki benzer çalışmaların (ör. inşaat sektöründe iş kazası türlerinin sınıflandırılmasında Random Forest kullanımı gibi) başarıyla uyguladığı yöntemlerin İSG genel risk yönetimine uyarlanmış halidir. Model çıktılarının doğruluğu ve güvenilirliği performans metrikleriyle değerlendirilecek; böylece modelin pratikteki faydası somut olarak ortaya konacaktır.

### **3.4 Kullanılan Algoritmalar**

#### **3.4.1 Algoritma Tanımları**

Bu tez çalışmasında, YZ destekli İSG risk sınıflandırma modeli oluşturulurken farklı MÖ algoritmaları değerlendirilmiştir. Amaç; veriye dayalı, güvenilir ve açıklanabilir bir sınıflandırma modeli geliştirerek iş kazası riski yüksek olan durumları önceden belirleyebilmektir. Bu kapsamda öncelikli olarak Random Forest algoritması temel alınmış; karşılaştırma ve doğrulama amacıyla Decision Tree, Naive Bayes, k-Nearest

Neighbors (kNN), Support Vector Machines (SVM) ve XGBoost gibi algoritmalar da uygulanmıştır.

- **Random Forest**

Random Forest algoritması, çok sayıda karar ağacının farklı alt veri kümeleri üzerinde rastgele olarak eğitilmesiyle çalışan, güçlü bir MÖ yöntemidir. Her bir ağaç kendi başına eğitilir ve sistemin nihai kararı, bu ağaçların oy çokluğu ile belirlenir. Bu yaklaşım, özellikle genelleme yeteneği yüksek modeller elde etmeye olanak tanır; çünkü bireysel ağaçların yaptığı hatalar diğer ağaçlar tarafından dengelenir. Ayrıca, hem sayısal hem de kategorik verilerle etkili biçimde çalışabilmesi sayesinde, geniş veri setlerinde esnek bir kullanım sunar. Bir başka önemli özelliği de, modelin hangi değişkenlere daha fazla ağırlık verdiğini analiz edebilmesidir; bu durum, özellikle iş sağlığı ve güvenliği gibi alanlarda kritik risk faktörlerini belirlemek açısından faydalı olabilir. Ancak tüm bu avantajlarına rağmen, Random Forest modelleri açıklanabilirlik açısından sınırlıdır. Çok sayıda ağacın birlikte karar vermesi, karar sürecinin takip edilmesini zorlaştırır ve modelin içsel mantığının yorumlanmasını karmaşık hale getirir. Ayrıca, yüksek sayıda ağaç eğitimi yapılması gerektiğinden, özellikle büyük veri setlerinde işlem gücü ve zaman açısından ciddi bir maliyet oluşabilir. Dolayısıyla bu yöntem tercih edilirken, elde edilecek doğruluk kazancı ile yorumlanabilirlik ve işlem yükü arasında makul bir denge kurulması önem taşır.

- **Decision Tree**

Karar ağacı (Decision Tree) algoritması, verileri dallara ayırarak sınıflandıran ve “eğer-ise” kurallarına dayalı karar yolları oluşturan basit ama etkili bir yöntemdir. Özellikle açıklanabilirliğin ön planda olduğu durumlarda tercih edilmesinin temel nedeni, sunduğu karar kurallarının son derece açık ve kolay anlaşılır olmasıdır. Bu sayede, modelin neden belirli bir sonuca ulaştığı net biçimde izlenebilir. Küçük veri kümelerinde hızlı çalışması ve eksik ya da aykırı değerler içeren veri setlerine karşı toleranslı olması da, onu uygulama aşamasında oldukça kullanışlı kılar. Ancak bu yöntem, modelin veri kümesine fazla uyum sağlaması anlamına gelen aşırı öğrenme (overfitting) riskini ciddi ölçüde taşır. Özellikle ağacın derinliği kontrol edilmezse, model eğitim verisinde mükemmel sonuçlar verirken, yeni ve farklı veriyle karşılaştığında hatalı tahminler yapabilir. Ayrıca, veri setindeki küçük değişiklikler

dahi ağacın genel yapısını dramatik biçimde değiştirebilir; bu da modelin kararlılığını düşüren bir etkidir. Tüm bu nedenlerle, karar ağacı algoritması bu çalışmada daha çok prototipleme süreçlerinde, model mantığının açıklanabilirliğini test etme amacıyla değerlendirilmiş ve nihai modelde destekleyici rol oynamıştır.

- **Naive Bayes**

Naive Bayes algoritması, Bayes teoremini esas alarak çalışan ve her bir özelliğin birbirinden bağımsız olduğu varsayımına dayanan olasılık temelli bir sınıflandırma yöntemidir. Bu yalın yapısı sayesinde oldukça hızlı çalışır ve özellikle sınırlı sayıda veriye sahip durumlarda dahi etkili sonuçlar verebilir. Ayrıca, çok sayıda özelliğe sahip yani yüksek boyutlu veri kümelerinde de güçlü bir performans sergileyebilmesiyle bilinir. Ancak bu yöntem, sahip olduğu temel varsayımlar nedeniyle bazı sınırlamalara sahiptir. Özellikle, veri setindeki özellikler çoğu zaman birbirinden tamamen bağımsız değildir; dolayısıyla bu varsayımın gerçek veriyle örtüşmemesi, modelin tahmin başarısını düşürebilir. Bunun yanı sıra, eğitim verisinde belirli bir özelliğe ait değer hiç gözlemlenmemişse, model bu durumu “sıfır olasılık” olarak yorumlayabilir; bu da sonuçların tutarsızlaşmasına neden olur. Bu tür durumların önüne geçebilmek için “smoothing” adı verilen düzeltme tekniklerinin uygulanması gerekir. Tüm bu özellikleri göz önünde bulundurulduğunda, Naive Bayes algoritması bu çalışmada, özellikle yüksek boyutlu ancak sınırlı gözlem içeren örneklerde karşılaştırmalı analizlerde kullanılmış ve bazı senaryolarda dikkate değer sonuçlar üretmiştir.

- **k-Nearest Neighbors (kNN)**

k-Nearest Neighbors, yani k-En Yakın Komşu algoritması, “tembel öğrenme” yaklaşımını benimseyen bir sınıflandırma yöntemidir. Bu algoritma, klasik modellerden farklı olarak eğitim aşamasında herhangi bir genel kural veya model oluşturmaz; bunun yerine, yeni bir veri örneğiyle karşılaştığında, eğitim verisinde yer alan en yakın k komşuya bakarak karar verir. Bu yönüyle oldukça sezgisel ve esnek bir yöntemdir. Ayrıca, herhangi bir istatistiksel dağılım varsayımı ya da karmaşık modelleme süreci gerektirmediğinden, küçük ve temiz veri setlerinde oldukça yüksek doğruluk oranları elde edilebilir.

Ancak kNN'in bu sadeliği bazı durumlarda dezavantaj hâline gelebilir. Özellikle büyük ve çok boyutlu veri setlerinde, her yeni örnek için tüm eğitim verisiyle karşılaştırma yapılması gerektiğinden, algoritmanın çalışma süresi uzar ve işlem yükü artar. Buna ek olarak, veri setindeki özellikler farklı ölçeklerde yer alıyorsa, yani bazı değerler çok büyük bazıları çok küçük aralıklarda değişiyorsa, sonuçlar ciddi şekilde sapabilir; bu yüzden kNN uygulanmadan önce verilerin mutlaka uygun şekilde ölçeklendirilmesi gerekir. Ayrıca, veri seti çok sayıda değişkene sahipse — yani boyutsal karmaşıklık artmışsa — kNN'in performansı düşebilir; bu durum literatürde “boyutlanma laneti” olarak bilinir. Tüm bu nedenlerle, kNN bu çalışmada daha çok model karşılaştırmaları ve küçük örnekleme senaryolarında referans olarak kullanılmıştır.

- **Support Vector Machines (SVM)**

Support Vector Machines – SVM, sınıflandırma problemlerinde oldukça etkili bir makine öğrenmesi yöntemidir. Bu algoritmanın temel amacı, verileri birbirinden en net şekilde ayırabilecek bir karar sınırı (hiperdüzlem) oluşturmaktır. Özellikle karmaşık yapıları verilerde, verileri daha yüksek boyutlu bir uzaya taşıyarak doğrusal olmayan ayrımlar bile başarıyla gerçekleştirilebilir. Bu işlem, “çekirdek (kernel) fonksiyonu” adı verilen özel dönüşümlerle sağlanır. Bu yönüyle SVM, sınıflar arasındaki farkları net biçimde ayırmakta oldukça başarılıdır ve özellikle küçük ya da orta ölçekli veri setlerinde yüksek doğruluk oranları sunar.

Bununla birlikte, SVM'in bazı sınırlılıkları da bulunmaktadır. Öncelikle, modelin iç yapısı ve ürettiği karar sınırları doğrudan gözlemlenebilir ya da kolayca yorumlanabilir değildir; bu nedenle modelin neye göre karar verdiğini anlamak diğer bazı yöntemlere göre daha zordur. Ayrıca, büyük veri setlerinde eğitim süresi uzayabilir ve işlem gücü gereksinimi artabilir. Bir diğer önemli nokta ise modelin başarısının büyük ölçüde hiperparametre ayarlarına (örneğin C ve gamma gibi) bağlı olmasıdır. Bu ayarların uygun şekilde belirlenmemesi durumunda modelin doğruluğu düşebilir ya da aşırı öğrenme riski artabilir. Bu nedenle, SVM dikkatli parametre optimizasyonu gerektiren ancak doğru yapılandırıldığında oldukça güçlü sonuçlar sunabilen bir algoritmadır.

- **XGBoost**

XGBoost (Extreme Gradient Boosting), makine öğrenmesinde özellikle sınıflandırma ve regresyon problemlerinde sıkça kullanılan, güçlü ve optimize edilmiş bir “boosting” yöntemidir. Bu algoritmanın temel mantığı, birçok zayıf modelin (genellikle karar ağaçlarının) art arda eğitilmesiyle her bir modelin bir öncekinin yaptığı hataları gidermesidir. Böylece her adımda hatalara odaklanan daha hassas tahminler yapılır ve sonuçta oldukça başarılı bir genel model elde edilir.

XGBoost’un en öne çıkan avantajlarından biri, yüksek doğruluk oranlarına ulaşabilmesidir. Ayrıca, aşırı öğrenmeyi (overfitting) önleyici mekanizmalarla donatılmıştır. Bu yönüyle, veriye fazlaca uyum sağlayıp genelleme yeteneğini kaybetme riskini azaltır. Bir diğer güçlü tarafı ise eksik verilerle baş edebilme yeteneğidir; model, boş alanları özel algoritmalarla değerlendirebilir ve verinin eksik olmasından kaynaklı performans kaybını en aza indirir.

Ancak, XGBoost’un bazı sınırlılıkları da vardır. Model yapısı oldukça karmaşıktır ve bu durum, algoritmanın nasıl çalıştığını ya da neden belirli kararları verdiğini açıklamayı güçleştirir. Bu nedenle açıklanabilirlik (explainability) açısından daha sade modellere kıyasla zayıf kalabilir. Ayrıca, modelin etkili çalışabilmesi için birçok hiperparametrenin dikkatli biçimde ayarlanması gerekir. Bu ayarlama süreci zaman alıcı ve teknik bilgi gerektiren bir süreç olabilir. Bu nedenle XGBoost; doğru şekilde yapılandırıldığında yüksek başarı sağlayabilen, ancak karmaşıklığı nedeniyle dikkatli yönetilmesi gereken ileri düzey bir makine öğrenmesi algoritmasıdır.

- **Genel Değerlendirme**

Bu çalışmada, iş sağlığı ve güvenliği (İSG) alanında yapay zekâ destekli bir risk sınıflandırma sistemi tasarlanırken birden fazla makine öğrenmesi algoritması değerlendirilmiş, hem performans hem de açıklanabilirlik açısından bütüncül bir bakış açısı benimsenmiştir. Uygulama sürecinde en temel iki algoritma olan Decision Tree (Karar Ağacı) ve Random Forest (Rastgele Orman) modelleri odak noktasını oluşturmuştur.

Decision Tree, model çıktılarının yorumlanabilirliğini artırmak amacıyla tercih edilmiştir. Kurduğu açık ve anlaşılır “if-then” yapıları, modelin hangi kararları hangi

kriterlere dayanarak verdiğini görselleştirerek kullanıcıya şeffaflık sunmuştur. Bu özellik, özellikle karar destek sistemlerinde güven oluşturmak açısından kritik öneme sahiptir.

Random Forest ise, birden fazla karar ağacının farklı veri alt kümeleri üzerinde eğitilmesiyle elde edilen bir yapı sunarak modelin hem doğruluğunu artırmış hem de aşırı öğrenmeye karşı dayanıklılığını güçlendirmiştir. Rastgeleleştirme ve çoklu modelleme stratejisi sayesinde, farklı örüntülerde bile kararlı sonuçlar üretebilmiştir.

Bununla birlikte, Naive Bayes, k-Nearest Neighbors (kNN), Support Vector Machines (SVM) ve XGBoost gibi diğer algoritmalar da çalışmaya dâhil edilmiştir. Bu modellerin kullanım amacı, yalnızca ana modelin doğruluğunu artırmak değil; aynı zamanda geliştirilen sistemin farklı veri dağılımlarında nasıl davrandığını test etmektir. Böylece modelin genel geçerliliği ve farklı koşullara adaptasyon yeteneği nesnel biçimde değerlendirilmiştir.

Özellikle XGBoost, sağladığı yüksek doğruluk oranları ile güçlü bir alternatif sunarken; Naive Bayes, yüksek boyutlu verilerle başa çıkma kapasitesi ve hız avantajıyla dikkat çekmiştir. kNN ve SVM ise küçük veri gruplarında yüksek performans sağlamakla birlikte, büyük veri kümelerinde daha yüksek işlem maliyetine neden olmuştur.

Sonuç olarak, bu çalışma yalnızca tek bir algoritmaya bağlı kalmadan, çoklu modelleme yaklaşımı ile hem doğruluğu artırmayı hem de farklı veri yapılarına karşı dayanıklılığı test etmeyi hedeflemiştir. Geliştirilen sistem, Random Forest ve XGBoost modelleri ile optimum sonuçlar verirken; Decision Tree gibi daha sade yapılar, sistemin açıklanabilirliğini desteklemiştir. Bu çok katmanlı yaklaşım, iş sağlığı ve güvenliği gibi hassas ve yüksek sorumluluk gerektiren bir alanda yapay zekâ temelli sistemlerin uygulanabilirliğini önemli ölçüde artırmıştır.

### **3.4.2 Hiperparametre Optimizasyonu**

Bu çalışmada kullanılan makine öğrenmesi modelleri, yalnızca varsayılan ayarlarla değil, özenle yürütülen hiperparametre optimizasyon süreci sonucunda elde edilen en iyi konfigürasyonlarla eğitilmiştir. Modelin öğrenme performansını artırmak ve aşırı öğrenme (overfitting) gibi istenmeyen durumları önlemek amacıyla, Random Forest

ve XGBoost algoritmalarının her biri için iki aşamalı bir iyileştirme stratejisi izlenmiştir. İlk olarak GridSearchCV yöntemiyle, farklı parametre kombinasyonları sistematik biçimde denenmiş; örneğin ağaç sayısı, maksimum derinlik, veri alt kümelerinde dal verme eşiği ve değişken sayısı gibi ayarlar geniş aralıklarla taranarak ortalama F1 skoru açısından en iyi performans gösteren yaklaşık 20 alternatif belirlenmiştir. Bu ön seçimler, ikinci aşamada Optuna adlı bir optimizasyon çerçevesine aktarılmıştır.

Optuna, geleneksel arama yöntemlerinden farklı olarak, geçmiş denemelerin sonuçlarına göre sonraki denemeleri yönlendiren akıllı bir algoritma kullanmaktadır. Böylece deneme sayısı makul tutulurken en uygun parametre kombinasyonu çok daha verimli şekilde tespit edilmiştir. Optuna'nın arama süreci, 150 farklı denemeyi kapsayacak şekilde yapılandırılmış ve modelin F1 skoru ile AUC (Area Under Curve) değerleri bir arada değerlendirilmiştir. Optimum parametreler belirlendikten sonra, ilgili model bu ayarlarla yeniden eğitilerek ana model olarak sisteme entegre edilmiştir. Aynı zamanda, elde edilen çıktılar ROC eğrisi ile kalibre edilerek daha dengeli bir eşik değeri tanımlanmıştır.

Bu bütünsel süreç sonucunda, örneğin XGBoost modeli; daha düşük öğrenme hızı, optimize edilmiş alt örnekleme oranları ve ayarlanmış karmaşıklık parametreleriyle daha güçlü genelleme kabiliyeti göstermiştir. Random Forest ise hem daha yüksek isabet oranı sunmuş, hem de değişken önem düzeylerinin görselleştirilmesine olanak sağlayarak İSG profesyonellerine karar verme sürecinde açıklanabilirlik sunmuştur. Hiperparametre optimizasyonunun, yalnızca modelin matematiksel başarısını artırmakla kalmayıp aynı zamanda sahada uygulanabilir, kullanıcı dostu ve güvenilir bir karar destek sistemi inşa etmeye katkı sağladığı görülmüştür.

Tüm bu işlemler, yerel bilgisayarlarda saatler sürebilecek yoğun hesaplamaları, Google Colab gibi bulut tabanlı bir platform sayesinde çok daha kısa sürede gerçekleştirmeyi mümkün kılmış; böylece gelişmiş yapay zekâ tekniklerinin yüksek donanım gereksinimi olmadan da uygulanabileceği gösterilmiştir. Bu yönüyle çalışma, yalnızca teorik bir başarı değil; aynı zamanda pratik erişilebilirlik ve ölçeklenebilirlik açısından da güçlü bir örnek teşkil etmektedir.

### 3.5 Performans Ölçütleri ve Doğrulama Yöntemi

Geliştirilen Geliştirilen İSG risk sınıflandırma modelinin başarımını nesnel biçimde değerlendirmek amacıyla çeşitli performans metrikleri ve model doğrulama teknikleri kullanılmıştır. Çalışmada temel hedef, modelin yüksek riskli durumları güvenilir biçimde tanıyabilmesi ve sahadaki kararlara rehberlik edebilecek öngörüler sunabilmesidir. Bu nedenle hem genel başarıyı hem de kritik hataları değerlendirecek çok boyutlu bir analiz yaklaşımı benimsenmiştir.

#### A- Kullanılan Başlıca Performans Ölçütleri:

##### 1- Doğruluk (Accuracy)

Doğruluk, makine öğrenmesi modellerinde en yaygın kullanılan performans ölçütlerinden biridir. Bu metrik, modelin yaptığı tüm doğru tahminlerin, toplam tahmin sayısına oranlanmasıyla elde edilir. Matematiksel olarak ifade etmek gerekirse, doğru pozitif (TP) ve doğru negatif (TN) tahminlerin toplamı, tüm sınıflandırma sonuçlarının  $(TP + TN + FP + FN)$  oranına bölünerek hesaplanır.

Ancak bu çalışma kapsamında, doğruluk metriğinin sınırlılıkları da dikkate alınmıştır. Özellikle dengesiz sınıf dağılımı içeren veri setlerinde, doğruluk yanıltıcı olabilir. Örneğin; risk değerlendirme verilerinde “Düşük Risk” sınıfı, “Yüksek Risk” sınıfına kıyasla çok daha fazla sayıda örneğe sahip olabilir. Böyle bir durumda, model yalnızca “Düşük Risk” sınıfını tahmin ederek yüksek doğruluk elde edebilir. Bu senaryoda modelin genel doğruluk değeri %90 gibi yüksek bir seviyede görünse de, asıl kritik olan “Yüksek Risk” sınıfı neredeyse tamamen göz ardı edilmiş olur. Bu da, özellikle iş sağlığı ve güvenliği gibi hayati alanlarda ciddi sonuçlara yol açabilecek yanlış bir güven algısı yaratır.

Bu nedenle, bu çalışmada doğruluk metriği sadece genel bir oryantasyon sunmak amacıyla kullanılmış, modelin başarımını değerlendirmek için daha duyarlı ve dengeli metriklere de yer verilmiştir. Özellikle F1 skoru, Duyarlılık (Recall) ve AUC (Area Under the Curve) gibi ölçütlerle birlikte analiz edilerek modelin sınıf bazlı başarısı daha kapsamlı bir şekilde ele alınmıştır. Böylece, sistemin yalnızca baskın sınıflarda değil, azınlıkta kalan ve kritik öneme sahip sınıflarda da ne ölçüde doğru karar verdiği değerlendirilebilmiştir.

## 2- Precision, Recall ve F1 Skoru

Bu çalışmada modelin yalnızca genel doğruluk performansı değil, aynı zamanda özellikle “yüksek risk” gibi kritik sınıflardaki tanıma başarısı da değerlendirilmiştir. Bu amaçla, Precision (Kesinlik), Recall (Duyarlılık) ve bu iki metriğin dengelenmiş ortalaması olan F1 skoru temel ölçütler olarak ele alınmıştır.

Recall, modelin gerçekten “yüksek risk” taşıyan durumları ne ölçüde başarılı bir şekilde yakalayabildiğini gösterir. Bu değer, modelin kritik vakaları gözden kaçırmadan tanıma yetisini temsil eder. Özellikle iş sağlığı ve güvenliği uygulamalarında, riskli bir durumu atlamak doğrudan çalışan sağlığını tehdit edebileceğinden, Recall oranının yüksek olması hayati önem taşır.

Precision ise modelin “yüksek risk” olarak sınıflandırdığı durumların gerçekten ne kadarının doğru olduğunu ifade eder. Yani, modelin verdiği uyarıların ne ölçüde isabetli olduğunu gösterir. Bu da yanlış alarmların (false positive) önüne geçilmesi açısından önemlidir; zira gereksiz uyarıların fazla olması sistemin güvenilirliğini ve kullanıcı güvenini olumsuz etkileyebilir.

F1 skoru ise Precision ve Recall değerlerinin harmonik ortalaması alınarak elde edilir ve bu iki metrik arasındaki dengeyi kurar. F1, özellikle sınıflar arasında dengesizlik bulunduğu daha anlamlı bir genel başarı göstergesi sunar ve modelin tutarlılığını yansıtır.

Bu üç metrik birlikte değerlendirilerek, sistemin yalnızca doğru sınıflandırma yapma yeteneği değil, aynı zamanda ne kadar tutarlı, duyarlı ve güvenilir sonuçlar üretebildiği de kapsamlı biçimde analiz edilmiştir.

## 3- ROC Eğrisi ve AUC

Modelin sınıflandırma performansını sadece belirli bir eşik değeri üzerinden değerlendirmek, birçok durumda yetersiz ve yanıltıcı olabilir. Bu nedenle, modelin farklı eşik değerleri altında ne ölçüde doğru ve güvenilir sonuçlar verdiğini görebilmek amacıyla ROC (Receiver Operating Characteristic) eğrisi kullanılmıştır. ROC eğrisi, modelin True Positive Rate (Duyarlılık) ile False Positive Rate (Yanlış Pozitif Oranı) arasındaki ilişkiyi görselleştirir.

Bu eğri, modelin sınıflandırma kararlarını farklı eşik seviyelerinde nasıl değiştirdiğini anlamaya yardımcı olur. Eğrinin ideal şekli, sol üst köşeye yakın bir rota izlemesidir; bu da hem yanlış pozitiflerin az olduğunu hem de gerçek pozitiflerin başarıyla tespit edildiğini gösterir.

ROC eğrisinin altında kalan alan, yani AUC (Area Under Curve) değeri ise modelin genel ayırıştırma yeteneğini özetleyen tek bir sayısal göstergedir. AUC değeri şu şekilde yorumlanabilir:

- $AUC \approx 0.5$ : Modelin hiçbir ayırım gücü yoktur; tahminler rastgele seçimden farksızdır.
- $AUC \approx 1.0$ : Model, sınıflar arasında mükemmel bir ayırım gerçekleştirmektedir.
- $0.80 < AUC < 0.90$ : Güçlü ve istikrarlı bir sınıflandırma performansına işaret eder.

Bu tez kapsamında geliştirilen yapay zekâ temelli risk sınıflandırma modelleri, eğitim ve test verileri üzerinde yapılan değerlendirmelerde ortalama 0.89 AUC değerine ulaşmıştır. Bu sonuç, modelin hem düşük hem yüksek risk sınıflarını yüksek doğrulukla ayırt edebildiğini göstermektedir. Ayrıca bu başarı, sistemin gerçek dünya uygulamalarında riskli durumları güvenilir şekilde tespit edebileceğine işaret etmektedir.

ROC eğrisi ve AUC metriği birlikte ele alındığında, geliştirilen modellerin yalnızca genel doğruluk değil; aynı zamanda sınıf ayırıştırma başarısı açısından da tatmin edici düzeyde performans sergilediği görülmektedir.

## **B- Model Doğrulama Yöntemi:**

- **10-Fold Çapraz Doğrulama**

Makine öğrenmesi modellerinin başarımı yalnızca eğitim verileri üzerinden ölçüldüğünde, modelin genellenebilirliği hakkında sağlıklı bir yargıya varmak mümkün olmaz. Bu durum, genellikle modelin eğitim verisine aşırı uyum sağlaması (overfitting) ve farklı veri kümelerinde düşük performans sergilemesiyle

sonuçlanabilir. Bu nedenle, bu tez kapsamında geliştirilen sınıflandırma modellerinin gerçek dünya verilerine karşı dayanıklılığını ve istikrarlılığını değerlendirebilmek amacıyla 10-Fold Çapraz Doğrulama (10-Fold Cross-Validation) yöntemi tercih edilmiştir. Bu yöntem, tek bir sabit eğitim-test bölünmesinden ziyade, tüm veri kümesini eşit büyüklükte alt parçalara bölerek her bir parçayı dönüşümlü olarak hem eğitim hem doğrulama amacıyla kullanma esasına dayanır. Böylece modelin performansı, veri setinin farklı alt örneklemeleri üzerinde defalarca test edilerek daha güvenilir ve istatistiksel olarak dengeli metrikler elde edilir.

Süreç, veri kümesinin rastgele karıştırılmasıyla başlamış ve deneysel tekrarlanabilirliği sağlamak amacıyla `random_state=42` değeri sabitlenmiştir. Tüm veri setinin %80'i eğitim, %20'si test amaçlı ayrılmış ve eğitim süreci yalnızca eğitim verisi üzerinden gerçekleştirilmiştir. Ancak bu eğitim verisi de doğrudan kullanılmamış, sınıflar arası dengesizliğin yol açabileceği sapmaları önlemek için StratifiedKFold yöntemi kullanılarak hedef değişkenin sınıf dağılımı korunmuştur. Bu sayede, örneğin “Düşük Risk”, “Orta Risk” ve “Yüksek Risk” gibi sınıfların her biri, her alt kümeye orantılı şekilde dağılmıştır. Bu adım, özellikle dengesiz sınıf dağılımı içeren veri setlerinde model başarımının daha doğru yorumlanabilmesi açısından kritik bir rol oynamaktadır.

Çapraz doğrulama işlemi sırasında, eğitim verisi on eşit parçaya bölünmüş ve her bir iterasyonda dokuz parça modelin eğitimi, kalan bir parça ise doğrulama için kullanılmıştır. Bu döngü on kez tekrarlanarak her alt parça bir kez doğrulama kümesi olarak kullanılmış, elde edilen tüm metrikler (doğruluk, precision, recall, F1 skoru, AUC vb.) kayıt altına alınmıştır. Sonuçlar, ortalama ve standart sapmalar hesaplanarak modelin genel başarısı hakkında güvenilir bir değerlendirme sunmuştur.

Bununla birlikte, bu çapraz doğrulama yöntemi yalnızca model doğruluğunu ölçmek için değil, aynı zamanda hiperparametre ayarlama süreçlerinin bir bileşeni olarak da kullanılmıştır. Özellikle GridSearchCV yöntemiyle manuel olarak belirlenen parametre aralıkları içinde sistematik arama yapılmış; her kombinasyon, 10-Fold CV yöntemiyle test edilerek en yüksek başarıyı sağlayan ayarlar seçilmiştir. Daha sonra Optuna gibi daha gelişmiş, otomatik arama algoritmaları devreye alınarak bu ön sonuçlar üzerine yüzlerce farklı deneme gerçekleştirilmiş ve nihai model konfigürasyonları belirlenmiştir. Böylece sadece eğitim verisine uyum sağlayan geçici

çözümlerden kaçınılmış; genellenebilir, tutarlı ve pratik uygulamalar için uygun modeller elde edilmiştir.

Sonuç olarak, bu yöntem sayesinde geliştirilen modellerin yalnızca belirli bir veri grubunda değil, daha geniş dağılımlarda da güvenilir performans sergilediği kanıtlanmıştır. 10-Fold çapraz doğrulama, hem metodolojik sağlamlık hem de sonuçların güvenilirliği açısından tez çalışmasının temel yapı taşlarından biri olmuştur.

### **C- Ek Değerlendirme Metrikleri:**

Makine öğrenmesi tabanlı bir sınıflandırma modelinin başarısı yalnızca doğruluk, F1 skoru ya da AUC gibi temel metriklerle değerlendirilmemelidir. Özellikle iş sağlığı ve güvenliği (İSG) gibi hata toleransının son derece düşük olduğu alanlarda, modelin yanlış sınıflandırmalar karşısındaki duyarlılığı ve güvenli olarak etiketlenen durumların gerçekten güvenli olup olmadığının sorgulanması büyük önem taşır. Bu nedenle, bu çalışmada geliştirilen modeller yalnızca temel performans göstergeleriyle değil; aynı zamanda tamamlayıcı nitelikteki ek metriklerle de değerlendirilmiştir.

Bu bağlamda öncelikle Specificity (özgüllük) metriğine başvurulmuştur. Specificity, modelin gerçekten güvenli olan durumları doğru bir şekilde “güvenli” olarak sınıflandırma oranını gösterir. Diğer bir ifadeyle, modelin yanlış bir şekilde “risk var” dediği durumların oranını düşük tutma kabiliyetini ölçer. Bu metrik, özellikle düşük riskli grupların aşırı alarm üretmesi sonucu sistemin verimliliğinin bozulmaması açısından önemlidir.

Buna ek olarak Negatif Prediktif Değer (Negative Predictive Value – NPV) kullanılmıştır. NPV, modelin “risk yok” şeklinde tahmin yaptığı kayıtların ne kadarının gerçekten risksiz olduğunu ifade eder. Yani modelin, güvenli görünen kayıtlar üzerindeki güvenilirliğini değerlendirme imkânı sunar. İSG uygulamaları açısından bu tür negatif tahminlerin doğruluğu, çalışan sağlığını doğrudan ilgilendiren kritik kararlarda belirleyici rol oynar.

Modelin genel sınıflandırma davranışı ise Karmaşıklık Matrisi (Confusion Matrix) aracılığıyla ayrıntılı şekilde analiz edilmiştir. Bu matris; doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) sınıflandırmaları dört temel

kategori üzerinden sunarak modelin hangi sınıflarda güçlü ya da zayıf performans gösterdiğini görsel ve sayısal olarak ortaya koyar. Özellikle yanlış negatif sınıflandırmalar (yani sistemin riskli bir durumu “güvenli” olarak algılaması), İSG bağlamında telafisi güç sonuçlar doğurabileceğinden, bu kategorideki performans titizlikle izlenmiştir.

Bu ek değerlendirme metrikleri sayesinde geliştirilen yapay zekâ destekli sınıflandırma modelleri; sadece yüksek doğruluk üretmekle kalmamış, aynı zamanda sahadaki riskleri güvenilir şekilde ayrıştırma ve düşük riskli alanlarda gereksiz müdahaleleri önleme açısından da başarılı bir yapı sergilemiştir. Bu bütüncül analiz yaklaşımı, İSG gibi yüksek sorumluluk gerektiren bir alanda karar destek sistemlerinin güvenli, açıklanabilir ve uygulanabilir olmasını mümkün kılmıştır.

## **4. BULGULAR VE TARTIŞMA**

### **4.1 Uygulama Ortamı ve Senaryolar**

Bu çalışma kapsamında geliştirilen yapay zekâ destekli İSG risk sınıflandırma sistemi, model eğitim sürecinde yüksek işlem gücüne ihtiyaç duyulması nedeniyle Google Colab platformunda uygulanmıştır. Colab, Python tabanlı veri işleme ve modelleme süreçlerinin etkileşimli olarak yürütülmesine olanak tanıyan, GPU/TPU desteği sayesinde büyük veri setleri üzerinde hızlı model eğitimi sağlayan, ayrıca tarayıcı tabanlı yapısıyla sistem bağımsız çalışma imkânı sunan bulut tabanlı bir ortamdır. Platform, dış bağımlılıkların kolayca entegre edilebildiği kütüphane kurulum kolaylığına sahip olup; dosya paylaşımı, versiyon takibi ve Google Drive entegrasyonu gibi özellikleriyle de kullanıcıya önemli avantajlar sağlamaktadır.

Model geliştirme sürecinde Python programlama dili kullanılmış; veri işleme, görselleştirme ve makine öğrenimi uygulamaları için pandas, numpy, scikit-learn, matplotlib, seaborn ve xgboost gibi yaygın kütüphanelerden yararlanılmıştır.

Çalışmada kullanılan veri seti, ABD İş Sağlığı ve Güvenliği İdaresi (OSHA – Occupational Safety and Health Administration) tarafından tutulan iş kazası kayıtları örnek alınarak oluşturulmuş, yapay olarak simüle edilmiş bir veri kümesidir. Bu veri kümesinde; sektör, çalışan deneyimi, kazanın tipi, olayın meydana geldiği ortam,

kullanılan ekipman türü ve görev tipi gibi kazaya etki edebilecek çeşitli faktörlere ilişkin bilgiler yer almaktadır. Geliştirilen model, bu nitelikler üzerinden öğrenme gerçekleştirerek, belirli bir iş ortamında karşılaşılabilecek risk seviyesini “yüksek”, “orta” veya “düşük” şeklinde tahmin edebilmektedir.

Örneğin, “İnşaat sektöründe, 1 yıldan az deneyime sahip çalışanların yüksekten düşme riski altında olup olmadığı yapay zekâ modeli ile tahmin edilebilir mi?” sorusu, literatürde sıkça vurgulanan önemli bir risk grubuna işaret etmektedir. Özellikle deneyimsiz işçilerin, yüksekten düşme gibi ciddi iş kazalarıyla karşılaşma olasılığı yüksektir. Bu çalışmada, söz konusu senaryo simüle edilen veriler üzerinden test edilmiştir. Geliştirilen model, belirtilen giriş özelliklerine sahip iş kayıtlarına belirli bir risk skoru atamış; bu skorlar da önceden tanımlanmış eşik değerler doğrultusunda risk seviyelerine sınıflandırılmıştır.

#### 4.2 Elde Edilen Risk Skorları ve Sınıflandırmalar

Model çıktısı olarak, her iş kaydına ilişkin bir risk skoru hesaplanmıştır. Bu skor, 0 ile 1 arasında değişen bir olasılık değeri olup, ilgili çalışanın ciddi bir iş kazası geçirme ihtimalini nicel olarak ifade etmektedir. Elde edilen bu sürekli risk değerleri, karar vericilere daha anlaşılır ve uygulanabilir bir çerçeve sunmak amacıyla üç kategoride sınıflandırılmıştır:

- **Düşük risk:** 0.00 – 0.29
- **Orta risk:** 0.30 – 0.69
- **Yüksek risk:** 0.70 – 1.00

Sınıflandırmada kullanılan bu eşik değerler, eğitim verilerinin dağılımı ile İSG uzmanlarının görüşleri dikkate alınarak belirlenmiştir. Tablo 4.1’de, modelin farklı sektör ve deneyim düzeylerine göre oluşturduğu risk skorları sunulmaktadır. Bu sayede, geliştirilen sınıflandırma sistemi yalnızca genel risk tahminiyle sınırlı kalmamış, aynı zamanda sektörel bağlamda da anlamlı farklılıklar ortaya koyabilmiştir. Risk skorlarının bu şekilde görselleştirilmesi, iş güvenliği önlemlerinin daha hedefe yönelik, önceliklendirilmiş ve kaynak-etkin biçimde planlanmasına katkı sağlamaktadır.

Tablo 4.1 Çalışan profiline göre model tarafından tahmin edilen risk skorları ve karşılık gelen risk seviyeleri

| Çalışan Profili                        | Model Risk Skoru | Risk Seviyesi |
|----------------------------------------|------------------|---------------|
| İnşaat sektörü, deneyim < 1 yıl        | 0.7              | Yüksek        |
| İnşaat sektörü, deneyim > 5 yıl        | 0.22             | Düşük         |
| Ofis (hizmet) sektörü, deneyim < 1 yıl | 0.30             | Orta          |
| Ofis (hizmet) sektörü, deneyim > 5 yıl | 0.05             | Düşük         |

Elde edilen sonuçlar, modelin sektörel tehlike düzeyi ve çalışan deneyimi gibi kritik değişkenleri ayırt edebildiğini ortaya koymaktadır. Örneğin, yüksek risk grubunda yer alan inşaat sektöründe, deneyimi bir yıldan az olan bir çalışan için model “yüksek risk” sınıflandırması yaparken; benzer deneyim düzeyine sahip bir çalışanın ofis (hizmet) sektöründe “orta risk” düzeyinde değerlendirilmesi, modelin bağlamsal duyarlılığını ve öğrenme kapasitesini göstermektedir. Bu durum, geliştirilen sistemin farklı iş kollarına özgü önleyici stratejilerin belirlenmesine katkı sunabilecek potansiyele sahip olduğunu göstermektedir.

Model çıktılarının pratik etkileri değerlendirildiğinde, üretilen risk skorlarının iş güvenliği uzmanları için öncelikli denetim alanlarının belirlenmesinde yol gösterici olabileceği görülmektedir. Modelin sunduğu risk sınıflandırmaları, geleneksel iş sağlığı ve güvenliği analizlerine kıyasla daha nesnel ve sayısal bir temele dayanmaktadır. Ayrıca, yüksek riskli olarak sınıflandırılan gruplara yönelik eğitim planlaması, uygun ekipman temini ve çalışma saatlerinin yeniden düzenlenmesi gibi önleyici önlemler, bu sayede daha stratejik ve hedefe yönelik biçimde gerçekleştirilebilmektedir.

#### 4.3 Modelin Performans Analizi

Modelin performans analizi kapsamında, geliştirilen yapay zekâ destekli İSG risk sınıflandırma modelinin başarımı çok boyutlu olarak değerlendirilmiştir. Bu değerlendirmede doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1 skoru ve ROC eğrisi altında kalan alan (AUC) gibi temel sınıflandırma metrikleri kullanılmıştır. Doğruluk, modelin tüm sınıflardaki doğru tahmin oranını ifade etmekle birlikte, sınıflar arasında dengesizlik olması durumunda yeterli bir ölçüt olmamaktadır.

Bu nedenle, özellikle “yüksek risk” sınıfını yakalama başarısını gösteren recall ve precision değerleri de dikkate alınmıştır. Recall, modelin tehlikeli vakaları ne kadar doğru yakaladığını; precision ise tahmin edilen yüksek risklerin gerçek risklere olan oranını belirtmektedir. Bu iki ölçütün harmonik ortalaması olan F1 skoru, modelin genel performansını dengeli şekilde yansıtmaktadır. Ayrıca, ROC eğrisi yardımıyla farklı eşik değerlerindeki duyarlılık ve özgüllük incelenmiş, AUC metriği ile modelin genel ayırt edicilik gücü ölçülmüştür. Modelin genelleme kapasitesini test etmek ve overfitting riskini minimize etmek için 10-fold çapraz doğrulama yöntemi uygulanmış, veri seti rastgele 10 parçaya bölünerek her seferinde 9 parça eğitim, 1 parça test için kullanılmış ve işlem 10 kez tekrarlanarak ortalama metrikler hesaplanmıştır. Bu yöntem, özellikle sınırlı veri setlerinde model güvenilirliğinin değerlendirilmesinde yaygın şekilde tercih edilmektedir.


Çalışmada Random Forest ve XGBoost algoritmaları karşılaştırmalı olarak değerlendirilmiştir. Tablo 4.2’de, 10-fold CV ile elde edilen ortalama performans metrikleri (doğruluk, precision, recall, F1 skoru ve AUC) bakımından her iki algoritmanın sonuçları sunulmuştur.

Tablo 4.2 10-fold çapraz doğrulama yöntemi ile elde edilen Random Forest ve XGBoost algoritmalarına ait ortalama performans metrikleri

| Model         | Doğruluk | Precision | Recall | F1 Skoru | AUC  |
|---------------|----------|-----------|--------|----------|------|
| Random Forest | 0.85     | 0.84      | 0.86   | 0.85     | 0.90 |
| XGBoost       | 0.88     | 0.87      | 0.89   | 0.88     | 0.92 |

Tablo 4.2 incelendiğinde, her iki modelin de başarılı performans sergilediği görülmekle birlikte, XGBoost modelinin tüm değerlendirme metriklerinde Random Forest modeline göre daha yüksek değerler elde ettiği anlaşılmaktadır. Doğruluk, precision, recall ve F1 skorundaki artış, XGBoost’un risk sınıflandırmasında daha dengeli ve güvenilir tahminler yaptığını göstermektedir. Ayrıca, AUC değerinin 0,92’ye yükselmesi, XGBoost modelinin sınıflar arasındaki ayrımı daha etkili biçimde gerçekleştirdiğini ortaya koymaktadır. Bu sonuçlar, XGBoost algoritmasının İSG risk sınıflandırma problemi için daha uygun ve üstün performans sergileyen bir yöntem olduğunu desteklemektedir.



Model açıklanabilirliğini artırmak amacıyla, Random Forest algoritması tarafından hesaplanan özellik önem skoru grafiği Şekil 4.1’de verilmiştir. Bu grafik, geliştirilen modelin risk tahmin sürecinde hangi değişkenlere daha fazla ağırlık verdiğini ortaya koymaktadır. Elde edilen sonuçlara göre, modelin en fazla önem atfettiği değişkenler yaralanma türü, olay tipi, yaralanan vücut bölgesi, deneyim süresi, yaş ve iş rolü olarak belirlenmiştir. Özellikle deneyim süresi ve yaş değişkenlerinin, modelin risk skorunu belirlemede diğer değişkenlere kıyasla daha belirleyici olduğu gözlemlenmiştir.




Şekil 4.1 Random Forest algoritması ile elde edilen özellik önem skoru grafiği

Şekil 4.2’de, XGBoost algoritması ile hesaplanan ağırlıklı özellik önem düzeyleri sunulmuştur. Bu grafik, modelin risk tahmininde hangi çevresel ve kişisel faktörlere daha fazla duyarlılık gösterdiğini ortaya koymaktadır. Özellikle ergonomi ve izolasyon eksikliği gibi çevresel değişkenlerin modelin karar sürecinde ön plana çıktığı gözlemlenmiştir.

XGBoost algoritması ile elde edilen özellik önem skoru grafiği Şekil 4.3’te sunulmuştur. Grafikte, değişkenlerin önemi dengeli bir şekilde dağılmış olup, farklı parametrelerin modele katkısı çeşitlilik göstermektedir.



Şekil 4.2 XGBoost algoritması ile hesaplanan ağırlıklı özellik önem düzeyleri



Şekil 4.3 XGBoost algoritması ile elde edilen özellik önem skoru grafiği

Tüm bu analizler sonucunda, geliştirilen sistemin yüksek doğruluk oranı ile güvenilir açıklamalar sunabildiği belirlenmiştir. XGBoost, son kullanıcıya yönelik risk tahminlerinde kullanılırken; Random Forest ise risk nedenlerinin anlaşılması ve raporlanması amacıyla karar destek aracı olarak görev yapmaktadır. Bu çift yönlü yapı sayesinde model, hem teknik performans hem de kullanıcı güveni açısından dengeli ve etkili bir çözüm sağlamaktadır.

#### 4.4 Geliştirilen Modelin Geleneksel Yöntemlerle Karşılaştırılması

Bu bölümde, YZ destekli İş Sağlığı ve Güvenliği (İSG) risk sınıflandırma modeli (Random Forest / XGBoost, Colab tabanlı) geleneksel yöntemler olan Fine–Kinney ve 5×5 risk matrisi ile çok boyutlu olarak karşılaştırılmıştır. Çalışmanın amacı, veri odaklı ve dinamik yapıya sahip bu modelin, uzman değerlendirmelerine dayanan statik yöntemlere kıyasla sağladığı katma değer in ortaya konulması ve her iki yaklaşımın entegrasyonuna yönelik uygulanabilir bir çerçevenin sunulmasıdır.

##### 4.4.1 Karşılaştırmalı Analizin Temeli

Bu çalışmada geliştirilen yapay zekâ temelli risk değerlendirme modelinin performansı yalnızca kendi içsel başarımlarıyla değil, aynı zamanda alanda yaygın biçimde benimsenmiş klasik risk analiz yöntemleriyle karşılaştırmalı olarak ele alınmıştır. Bu doğrultuda, özellikle Fine–Kinney yöntemi ile geleneksel 5 × 5 risk

matrisi çerçevesi odak noktası olarak seçilmiştir. Söz konusu yöntemler, birçok sektörde hâlen yaygın biçimde kullanılmakta olup, kavramsal sadelikleri ve uygulama kolaylıkları sayesinde pratikte tercih edilen temel araçlar arasında yer almaktadır.

Bununla birlikte, klasik yaklaşımların birtakım yapısal sınırlılıkları bulunmaktadır. Örneğin Fine–Kinney yöntemi; olasılık, şiddet ve maruziyet olmak üzere üç temel parametreye dayansa da, bu bileşenler büyük ölçüde öznel değerlendirmelerle belirlenmektedir. Benzer şekilde, risk matrisleri sabit kategorilere dayalı ve kullanıcı yorumuna açık puanlama sistemleri kullanmakta olup, bu durum analiz çıktılarının nesnelliğini ve tekrarlanabilirliğini olumsuz yönde etkileyebilmektedir. Bu çerçevede, önerilen yapay zekâ destekli sistemin, klasik yöntemlere kıyasla sunduğu yapısal avantajların ve varsa sınırlılıkların kapsamlı biçimde ortaya konması önemli bir gereklilik olarak değerlendirilmiştir.

Tez çalışması kapsamında geliştirilen model, insan faktörleri, çevresel koşullar ve tehlike türleri gibi toplam 24 farklı özelliği eşzamanlı olarak analiz ederek, her bir gözlem için 0 ile 1 arasında sürekli bir risk olasılığı çıktısı üretmektedir. Bu bağlamda, modelin sunduğu çıktıların kesikli kategorilere dayanan geleneksel sistemlere kıyasla daha hassas ve ayrıntılı bir değerlendirme imkânı sağladığı görülmektedir. Ayrıca yapay zekâ temelli algoritmik yapı, değişkenler arasındaki çok boyutlu ve doğrusal olmayan ilişkileri yakalama kapasitesine sahipken, klasik yöntemler bu tür karmaşık etkileşimleri çoğunlukla göz ardı etmektedir.

Bu nedenlerle, farklı risk analiz yaklaşımlarının aynı senaryolar üzerinde eş zamanlı olarak uygulanması ve elde edilen sonuçların karşılaştırmalı olarak değerlendirilmesi hedeflenmiştir. Böylece yalnızca modelin teknik yeterliliği değil, aynı zamanda pratik uygulama bağlamında sağlayabileceği katkılar ve hangi koşullar altında daha avantajlı olabileceği yönünde bütüncül bir değerlendirme gerçekleştirilmiştir.

#### **4.4.2 Uygulamalı Senaryo Kıyaslaması**

Bu karşılaştırmada, sahada karşılaşılabilecek bir risk durumu örneklenmiştir: “İnşaat sahasında çalışan ve  $\leq 1$  yıl deneyime sahip bir işçinin yüksekten düşme tehlikesiyle karşı karşıya kalması.” Bu senaryo, hem fiziksel tehlike (yüksekte çalışma) hem de iş gücü özellikleri (deneyimsizlik) bakımından kritik bir durumdur. Aynı senaryo, üç

farklı risk değerlendirme yöntemiyle analiz edilerek elde edilen sonuçlar Tablo 4.3'te özetlenmiştir.

Tablo 4.3 Uygulamalı senaryo için farklı risk değerlendirme yöntemlerinin karşılaştırılması

| Yöntem              | Girdi ve Varsayım                                 | Hesap                           | Çıktı                      |
|---------------------|---------------------------------------------------|---------------------------------|----------------------------|
| Fine–Kinney         | $S = 5$ (ölümcül) $F = 6$ (günde) $L = 6$ (olası) | $R = 5 \times 6 \times 6 = 180$ | Yüksek ( $\geq 70$ )       |
| $5 \times 5$ Matris | Olasılık = 5 Şiddet = 5                           | Hücre = Kırmızı                 | Yüksek                     |
| RF/XGB              | 24 öznitelik + Colab eğitimi                      | Olasılık = 0.78                 | Yüksek (eşik $\geq 0.70$ ) |

Tablodan görüldüğü üzere, üç yöntem de örnek senaryoyu “Yüksek Risk” kategorisinde değerlendirmiştir. Ancak her yöntemin risk hesaplama yaklaşımı, girdi niteliği ve sonuç sunum biçimi bakımından önemli farklılıklar sergilediği dikkat çekmektedir.

**Fine–Kinney** yöntemi, riskin hesaplanmasında tehlikenin şiddeti (S), maruziyet sıklığı (F) ve gerçekleşme olasılığı (L) olmak üzere üç temel faktörü çarparak toplam bir risk skoru üretmektedir. İlgili senaryoda bu parametreler sırasıyla 5, 6 ve 6 olarak belirlenmiş; sonuçta 180 gibi yüksek bir puan elde edilmiştir. Bu değer, yöntemin yüksek risk için tanımladığı  $\geq 70$  eşik değerini açık biçimde aşmaktadır. Bununla birlikte, yöntem büyük ölçüde kullanıcı yorumuna dayalı puanlamalara bağımlı olduğu için, sonuçların farklı uygulayıcılar arasında değişkenlik gösterebilme riski bulunmaktadır.

**$5 \times 5$  Risk Matrisi** analizinde, olasılık ve şiddet ayrı ayrı derecelendirilerek belirli bir hücreye karşılık gelecek biçimde sınıflandırılır. Bu örnekte hem olasılık hem de şiddet en yüksek değer olan 5 ile değerlendirilmiş ve sonuç, matrisin “kırmızı” olarak nitelendirilen ve en yüksek risk seviyesini temsil eden hücrelerine yerleşmiştir. Yöntem, kullanım kolaylığı açısından avantajlı olsa da, değerlendirme çıktısı yalnızca kesikli kategorilere dayandığı için ince risk ayrımlarını yansıtmakta yetersiz kalabilir.

**Tez kapsamında geliştirilen yapay zekâ destekli model (RF/XGB)**, toplam 24 öznitelik (çalışanın deneyim süresi, ortam koşulları, görev tipi, tehlike türü vb.) kullanarak daha yüksek boyutlu ve ilişkisel bir analiz gerçekleştirmektedir. Model, her

bir örnek için 0 ile 1 arasında sürekli bir risk olasılığı değeri üretmektedir. Bu senaryoda hesaplanan risk olasılığı 0.78 olup, daha önce belirlenmiş olan 0.70 eşik değerini aşarak yüksek risk kategorisine girmiştir. Klasik yöntemlerden farklı olarak bu yaklaşım, riskin değerlendirilmesinde sürekli bir skala sunmakta ve benzer durumlar arasında dahi nüanslı farklılıkları ortaya koyabilmektedir. Örneğin, başka bir çalışanın benzer koşullarda 0.64 gibi bir skor alması durumunda risk “orta” düzeyde olarak sınıflandırılabilir.

Sonuç olarak, geleneksel yöntemler riskin basit, anlaşılır ve hızlı biçimde değerlendirilmesine olanak tanırken; geliştirilen yapay zekâ destekli model, çok değişkenli yapısı ve sürekli skorlama özelliği sayesinde hem daha hassas hem de daha esnek bir analiz olanağı sağlamaktadır. Bu durum, karar vericilere sadece mevcut risk seviyesini görmekle kalmayıp, aynı zamanda olayın altında yatan nedenleri sayısal olarak anlama ve önceliklendirme yapma fırsatı da sunmaktadır. Özellikle kaynakların sınırlı olduğu ve proaktif önleme stratejilerinin ön planda tutulduğu İSG yönetimi bağlamında, bu tür veri güdümlü yaklaşımlar önemli bir katma değer sunmaktadır.

#### **4.4.3 Yerel ve Bulut Tabanlı Uygulama Performanslarının Karşılaştırılması**

Bu çalışmada kullanılan yapay zekâ modellerinin eğitimi ve hiperparametre optimizasyonları, yüksek düzeyde hesaplama gücü gerektiren işlemler içermektedir. Özellikle model karmaşıklığı arttıkça, eğitim süreci yerel bilgisayar sistemlerinde zaman açısından verimsiz hâle gelebilmekte ve araştırmacının çalışmasını ciddi ölçüde yavaşlatabilmektedir. Bu bağlamda, işlem süresi ve kaynak yönetimi açısından daha etkin bir yaklaşım olarak Google Colab platformunun kullanımı tercih edilmiştir.

Google Colab, GPU (grafik işlem birimi) destekli bulut tabanlı bir çalışma ortamı sunarak, makine öğrenmesi algoritmalarının eğitim süreçlerinde kayda değer hız artışı sağlamaktadır. Platformun sağladığı paralel işlem yetenekleri, yalnızca eğitim süresini azaltmakla kalmayıp, aynı zamanda hiperparametre ayarları gibi hesaplama yoğun görevlerin pratik biçimde gerçekleştirilmesine olanak tanımaktadır.

Tablo 4.4’de yerel bir sistem (Intel i5, 8 GB RAM) ile Google Colab ortamının bazı temel parametreler açısından karşılaştırılması sunulmuştur.

Tablo 4.4 Yerel sistem ile Google Colab ortamının işleme süresi ve optimizasyon kapasitesi açısından karşılaştırılması

| Özellik                 | Yerel Sistem<br>(i5, 8 GB RAM) | Google Colab<br>(GPU: Tesla T4/P100) |
|-------------------------|--------------------------------|--------------------------------------|
| İşlemci mimarisi        | 4 çekirdekli CPU               | GPU destekli işlem                   |
| RF (500 ağaç) eğitimi   | ~18 dk                         | ~ 2–3 dk                             |
| GridSearch + 10-fold CV | Pratik değil                   | Mümkün (< 40 dk)                     |
| Otomasyon olanakları    | Manuel işlemler                | Zamanlayıcı destekli notebook        |

Tablo 4.4’de görüldüğü üzere, Google Colab ortamı ile Random Forest algoritmasının eğitimi yaklaşık 6 kat daha hızlı şekilde tamamlanabilmektedir. Daha karmaşık bir işlem olan Grid Search ile 10 katlı çapraz doğrulama kombinasyonu, yerel sistemde pratikte uygulanamazken, Colab üzerinde yaklaşık 40 dakika içerisinde etkili bir şekilde gerçekleştirilebilmiştir. Buna ek olarak, Colab ortamında zamanlayıcı komutlar (örneğin cron) ve Jupyter tabanlı betiklerle süreçlerin otomatikleştirilebilmesi, kullanıcıya ciddi ölçüde operasyonel verimlilik kazandırmaktadır. Bu bulgular, hiperparametre optimizasyon süreçlerinde de net bir şekilde gözlemlenmiştir. Tablo 4.5’de, yerel CPU ile Google Colab GPU arasında belirli optimizasyon işlemleri bakımından zaman farkları gösterilmiştir.

Tablo 4.5 Yerel CPU ve Google Colab GPU’nun hiperparametre tarama süreleri bakımından karşılaştırılması

| İşlem          | Yerel CPU süresi | Colab GPU süresi |
|----------------|------------------|------------------|
| RF Grid Search | ~ 18 dk          | ~ 2–3 dk         |
| XGB Optuna     | ~ 2 sa           | ~ 38 dk          |
| <b>Toplam</b>  | ~ 138 dk         | ~ 41 dk          |

Google Colab platformu, Optuna gibi gelişmiş optimizasyon algoritmalarının etkin kullanımını mümkün kılarak hiperparametre taramalarını yerel sistemlere göre yaklaşık üç kat daha hızlı gerçekleştirmekte ve deneysel sürecin doğruluk ile zaman verimliliğini artırmaktadır.

#### 4.4.4 Avantaj ve Sınırlılıkların Karşılaştırmalı Değerlendirmesi

Farklı risk değerlendirme yaklaşımlarının uygulama potansiyelini değerlendirmek, yalnızca modelleme başarımını değil; aynı zamanda bu yöntemlerin operasyonel

çeviklik, kurumsal kaynak ihtiyacı ve karar destek sistemlerine entegrasyon düzeylerini de göz önünde bulundurmaya gerektirir. Bu bağlamda, hem geleneksel (klasik) yöntemlerin hem de geliştirilen yapay zekâ tabanlı modelin güçlü ve sınırlı yönleri Tablo 4.6’da karşılaştırmalı olarak özetlenmiştir.

Tablo 4.6. Yapay zekâ tabanlı ve geleneksel risk değerlendirme yöntemlerinin karşılaştırmalı analizi

| Kriter                                  | YZ tabanlı model                                                | Geleneksel yöntemler                                          |
|-----------------------------------------|-----------------------------------------------------------------|---------------------------------------------------------------|
| <b>Yapı</b>                             | Dinamik ve öğrenebilir                                          | Statik ve sabit                                               |
| <b>Karar Mekanizması</b>                | Veri güdümlü, çok değişkenli analiz yapabilme                   | Uzman görüşüne dayalı, sınırlı değişken analizi               |
| <b>Uygulama Alanı</b>                   | Karmaşık, büyük veri içeren senaryolarda etkili                 | Basit, yapılandırılmış ortamlarda uygulanabilir               |
| <b>Karar Şeffaflığı</b>                 | Sınırlı (kara kutu yapısı); XAI uygulamaları ile artırılabilir  | Açık ve anlaşılır karar mantığı                               |
| <b>Veri Gereksinimi</b>                 | Yüksek (nitelikli ve hacimli veri setlerine ihtiyaç duyar)      | Düşük (veri girişi genellikle manuel)                         |
| <b>Teknik Uzmanlık Gereksinimi</b>      | Yüksek; modelleme, optimizasyon ve yorumlama bilgisi gerektirir | Düşük; saha personeli tarafından kolaylıkla uygulanabilir     |
| <b>Ölçeklenebilirlik</b>                | Yüksek; farklı sektör ve senaryolara kolayca uyarlanabilir      | Sınırlı; yöntemler genellikle sabit parametrelere bağlıdır    |
| <b>Karar Keskinliği (Çözünürlük)</b>    | Yüksek; sürekli skorlama sayesinde daha hassas sonuçlar verir   | Düşük; belirli puan aralıklarına dayalı sınıflama yapılır     |
| <b>Zaman İçinde Gelişme Potansiyeli</b> | Mevcut; yeni verilerle model iyileştirilebilir                  | Yok; aynı parametrelerle tekrar eden değerlendirmeler         |
| <b>Şeffaflık – Denetim Uygunluğu</b>    | Düşük; denetim otoriteleri tarafından yorumlanması zor olabilir | Yüksek; mevzuatla uyumlu ve denetimlerde doğrudan kabul görür |
| <b>Kaynak ve Maliyet Gereksinimi</b>    | Orta–yüksek; donanım, yazılım ve insan kaynağı gerektirir       | Düşük; kâğıt kalemle dahi uygulanabilir                       |

#### 4.4.5 Önerilen Entegrasyon

Bu tez kapsamında geliştirilen yapay zekâ destekli İSG risk sınıflandırma modeli, hâlihazırda uygulamada olan geleneksel yöntemlerle bir çelişki oluşturmaksızın, onları tamamlayıcı nitelikte bir yapıyla kurgulanmıştır. Bu yaklaşım, yasal mevzuatın

gerekliliklerini karşılamaya devam ederken, veri temelli analitik katkılar aracılığıyla daha doğru, öngörülebilir ve önleyici karar alma süreçlerinin inşasını mümkün kılmaktadır. Bu doğrultuda önerilen entegrasyon stratejisi, geleneksel  $5 \times 5$  risk matrisi ile başlatılan ve ardından yapay zekâ modelleri ile derinleştirilen çok katmanlı bir değerlendirme süreci üzerine inşa edilmiştir.

Entegrasyon süreci, ilk adımda, iş sahasındaki potansiyel tehlikelerin hızlı, pratik ve yaygın biçimde ön sınıflandırılmasını sağlayan klasik  $5 \times 5$  risk matrisi yaklaşımı ile başlamaktadır. Bu ilk tarama, tehlikelerin düşük, orta ve yüksek risk düzeylerine göre kategorize edilmesini sağlayarak, detaylı analiz gerektiren kritik kayıtların öncelikli olarak belirlenmesine olanak tanımaktadır. Özellikle orta ve yüksek risk seviyesinde tanımlanan durumlar, daha derinlikli ve çok değişkenli bir değerlendirme için yapay zekâ modeline aktarılmaktadır.

Yapay zekâ temelli model, klasik yöntemlerin sunduğu iki boyutlu sınıflandırmaların ötesine geçerek, çalışan yaşı, deneyim düzeyi, ortam koşulları, ekipman durumu ve tehlike tipi gibi çok sayıda parametreyi aynı anda analiz edebilmektedir. Bu model, çıktılarında yalnızca kategorik bir sınıflama sunmakla kalmayıp, her bir risk durumu için sürekli ve nümerik bir olasılık skoru üretmektedir. Böylece, örneğin klasik yöntemle her ikisi de “yüksek risk” olarak değerlendirilen iki kayıt, model çıktısında %64 ve %78 gibi farklı olasılık değerleriyle ayırt edilerek, daha etkili bir önceliklendirme yapılmasına imkân sağlamaktadır.

Modelin belirlediği en yüksek risk puanına sahip ilk 20 kayıt, sahadaki uzman ekiplerce yerinde incelenerek doğrulanmalıdır. Bu aşama, model çıktılarının gerçek iş ortamıyla ne derece örtüştüğünü test etmekte ve aynı zamanda modele geri besleme sağlayarak öğrenme döngüsünü pekiştirmektedir. Böylece geliştirilen sistem yalnızca teorik bir öneri olmaktan çıkarak, sahada denenmiş ve doğruluğu teyit edilmiş bir karar destek mekanizmasına dönüşmektedir.

Geliştirilen model, manuel müdahaleye gerek kalmaksızın periyodik olarak güncellenebilecek bir yapıya da sahiptir. Google Colab platformu üzerinde geliştirilen bu yapı, cron zamanlayıcı komutları ile bütünleştirilerek aylık güncellemeler şeklinde yeniden eğitim döngüsüne alınabilir. Bu sayede model, değişen işyeri koşullarına adaptif bir biçimde tepki verebilmekte, güncel verilerle sürekli olarak kendini optimize etmektedir.

Sonuç olarak, önerilen hibrit entegrasyon modeli, geleneksel risk değerlendirme yöntemlerinin yasal uyum ve operasyonel sadelik avantajlarını korurken, yapay zekâ tabanlı veri analitiği sayesinde karar süreçlerine derinlik, duyarlılık ve dinamizm kazandırmaktadır. Bu yapı, İSG uygulamalarında yalnızca statik ve mevzuata dayalı yaklaşımın ötesine geçilmesini sağlayarak, kurumsal düzeyde dijital dönüşümün bir parçası hâline gelmektedir. Geliştirilen model, İSG risk yönetiminde ileri düzey dijital karar destek sistemlerine geçişin uygulanabilir bir örneğini sunmakta ve alandaki stratejik yönetime katkı sağlamaktadır.

## 5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, iş sağlığı ve güvenliği (İSG) alanında yapay zekâ temelli, sektörel uyarlanabilirliği yüksek bir risk yönetimi modeli geliştirilmiştir. Modelin eğitimi sırasında yüksek işlem gücü gereksinimi nedeniyle Google Colab platformu tercih edilmiş, böylece karmaşık hiperparametre optimizasyonları ve çapraz doğrulama süreçleri etkin şekilde yürütülebilmiştir. Modelde kullanılan veri seti, ABD İş Sağlığı ve Güvenliği İdaresi (OSHA) kayıtları referans alınarak oluşturulmuş ve yapay olarak simüle edilmiştir. Geliştirilen sistem, geleneksel yöntemlerle çalışmayan; aksine onları tamamlayıcı nitelikte hibrit bir yaklaşımla tasarlanmıştır. Modelin çok değişkenli yapısı, bağlamsal duyarlılığı ve sürekli güncellenebilir mimarisi, yalnızca teorik değil, aynı zamanda pratikte uygulanabilir, esnek ve ölçeklenebilir bir karar destek sistemi sunmaktadır. Aşağıda, çalışma kapsamında elde edilen sonuçlar maddeler hâlinde özetlenmiştir:

- Geliştirilen model, sektör, çalışan deneyimi, görev tipi ve ortam koşulları gibi çok sayıda parametreyi eşzamanlı değerlendirerek riskleri yalnızca genel düzeyde değil, bağlamsal olarak da anlamlı biçimde ayrıştırabilmiş; aynı zamanda her bir gözlem için sürekli ve nümerik olasılık skorları üreterek, sınıf etiketlerinin ötesinde daha hassas ve önceliklendirilebilir bir risk analizi imkânı sunmuştur.
- Kontrollü biçimde oluşturulmuş OSHA tabanlı simüle veri seti üzerinde uygulanan denetimli öğrenmeye dayalı ağaç ansambl (topluluk) algoritmaları, özellikle XGBoost ve Random Forest, sektörler arası varyasyonu dikkate alarak yüksek doğrulukta tahminler üretmiştir. XGBoost algoritması %88 doğruluk ve 0,92 AUC skoru ile sınıflar arası ayrımı tutarlı biçimde gerçekleştirmiş; Random Forest ise benzer doğruluk oranının yanı sıra özellik

önem düzeylerini belirleyerek modelin açıklanabilirliğini artırmıştır. Bu sayede fiziksel, kimyasal, biyolojik, ergonomik ve psikososyal risk unsurları tek bir sistem altında çok boyutlu biçimde analiz edilebilmiş, farklı İSG senaryolarına bütüncül bir yaklaşımla çözüm sunulmuştur.

- Fine–Kinney ve 5×5 risk matrisi gibi klasik yöntemlerle karşılaştırıldığında, geliştirilen yapay zekâ temelli model çok daha yüksek çözünürlükte ve sayısal temelli bir değerlendirme yapabilmiş; riskin nedenlerini daha net biçimde ortaya koyarak önleyici stratejilerin etkinliğini artırmıştır.
- Model eğitim ve hiperparametre optimizasyon süreçleri, Google Colab ortamında yerel sistemlere kıyasla 3 ila 6 kat daha hızlı gerçekleştirilmiş; bu durum daha karmaşık algoritmaların uygulanabilirliğini artırmış ve deneysel sürecin zaman etkinliğini yükseltmiştir.
- Geliştirilen yapı, cron tabanlı zamanlayıcılar ve betikler aracılığıyla periyodik olarak güncellenebilir hâle getirilmiş; böylece model, değişen işyeri koşullarına adapte olabilen dinamik bir sistem olarak kurgulanmıştır.
- Klasik 5×5 risk matrisi ile başlatılan ön sınıflandırma süreci, yapay zekâ tabanlı model ile çok katmanlı ve derinleştirilmiş bir değerlendirmeye dönüştürülmüş; böylece hem yasal uyum korunmuş hem de karar süreçlerine öngörü, esneklik ve duyarlılık kazandırılmıştır.

Sonuç olarak, geliştirilen yapay zekâ tabanlı İSG risk değerlendirme modeli; esnek, öğrenilebilir ve sürdürülebilir yapısıyla, geleneksel yöntemlerle bütünleşerek dijital dönüşüm süreçlerine somut katkı sunan ileri düzey bir karar destek sistemi olarak değerlendirilmiştir.

Bu çalışmada geliştirilen yapay zekâ destekli İSG risk sınıflandırma sisteminin daha etkili, güvenilir ve sürdürülebilir biçimde kullanılabilmesi için aşağıdaki hususlara dikkat edilmesi önerilmektedir:

- Veri kalitesi ve sürekliliği, modelin doğruluğu açısından kritik öneme sahiptir. Kullanılan simüle veri setlerinin gerçek saha koşullarını tam olarak yansıtamayabileceği dikkate alınarak, sistemin gerçek saha verileriyle periyodik olarak yeniden eğitilmesi gereklidir. Bu tür bir güncelleme süreci,

modelin geçerliliğini ve güvenilirliğini koruyarak değişen iş koşullarına adaptasyonunu mümkün kılacaktır.

- Eksik veya hatalı kayıtların modele dâhil edilmesi durumunda tahmin isabet oranı ciddi şekilde düşebileceğinden, veri temizleme, aykırı değer tespiti ve normalizasyon gibi ön işleme adımlarının sistemle bütünleşik biçimde çalışması sağlanmalıdır. Bu önlemler, modelin çıktılarının istatistiksel anlamlılığını ve operasyonel güvenilirliğini artıracaktır.
- Karar mekanizmalarının yorumlanabilirliği, kullanıcı güveni ve saha uygulamaları açısından büyük önem taşımaktadır. Özellikle XGBoost gibi yüksek performanslı ancak karmaşık algoritmaların çıktılarının anlaşılabilir kılınması için SHAP (SHapley Additive exPlanations) veya LIME (Local Interpretable Model-agnostic Explanations) gibi açıklanabilir yapay zekâ (XAI) tekniklerinden yararlanılması önerilmektedir. Bu yaklaşım, İSG profesyonellerinin yalnızca çıktıya değil, o çıktının “neden” oluştuğuna dair bilgi edinmesini sağlayarak karar alma sürecini daha şeffaf kılacaktır.
- Sistem çıktılarının, ISO 45001 İş Sağlığı ve Güvenliği Yönetim Sistemi'nde yer alan “sürekli iyileştirme döngüsü” ile ilişkilendirilmesi büyük katkı sağlayacaktır. Böylelikle geliştirilen model, yalnızca risk sınıflandırma aracı olarak değil, aynı zamanda İSG süreçlerinde kurumsal düzeyde proaktif bir rehber olarak işlev görecektir.
- Son olarak, doğru veri yönetişi, etik algoritmik denetim ve sektörel adaptasyonun sağlanması durumunda bu sistem, iş kazalarını yalnızca analiz eden değil, gerçekleşmeden önce önlemeye katkı sunan stratejik bir karar destek mekanizmasına dönüşecektir. Bu bağlamda geliştirilen yapı, “sıfır kaza” vizyonuna yönelik somut ve yenilikçi bir adım olarak değerlendirilebilir.

## KAYNAKÇA

- Adem, A., Çakıt, E., & Dağdeviren, M. (2020). Occupational health and safety risk assessment in the domain of Industry 4.0. *SN Applied Sciences*, 2(977). <https://doi.org/10.1007/s42452-020-2817-x>
- Azzi, M. (2019, May 21). *100 years of making work safer and healthier*. International Labour Organization. <https://www.ilo.org/resource/article/100-years-making-work-safer-and-healthier>
- Baek, J., & Choi, Y. (2020). Smart glasses based personnel proximity warning system for improving pedestrian safety in construction and mining sites. *International Journal of Environmental Research and Public Health*, 17(4), 1422. <https://doi.org/10.3390/ijerph17041422>
- Bayram, H., & Çelenk Kaya, E. (2022). Fine-Kinney metodu ile risk analizi: Trabzon liman örneği. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 11(2), 760–783. <https://doi.org/10.37989/gumussagbil.1095256>
- Bérastégui, P. (2024). *Artificial intelligence in Industry 4.0: Implications for occupational safety and health* (ETUI Research Paper No. 2024-01). European Trade Union Institute. <https://www.etui.org/publications/artificial-intelligence-industry-40>
- Canadian Centre for Occupational Health and Safety. (2022). *Risk assessment matrices*. [https://www.ccohs.ca/oshanswers/hsprograms/hazard/risk\\_assessment.html](https://www.ccohs.ca/oshanswers/hsprograms/hazard/risk_assessment.html)
- Choo, H., Lee, B., Kim, H., & Choi, B. (2023). Automated detection of construction work at heights and deployment of safety hooks using IMU with a barometer. *Automation in Construction*, 147, 104714. <https://doi.org/10.1016/j.autcon.2022.104714>
- T.C. Çalışma ve Sosyal Güvenlik Bakanlığı. (n.d.). *İSGÜM tarihçesi*. <https://www.csgeb.gov.tr/isgum/baskanlik/tarihce/>
- Ferdous, M., & Ahsan, S. M. M. (2022). PPE detector: A YOLO based architecture to detect personal protective equipment (PPE) for construction sites. *PeerJ Computer Science*, 8, e999. <https://doi.org/10.7717/peerj-cs.999>

- Fiegler Rudol, J., Lau, K., Mroczek, A., & Kasperczyk, J. (2025). Exploring human–AI dynamics in enhancing workplace health and safety: A narrative review. *International Journal of Environmental Research and Public Health*, 22(2), 199. <https://doi.org/10.3390/ijerph22020199>
- Fisher, E., Flynn, M. A., Pratap, P., & Vietas, J. A. (2023). Occupational safety and health equity impacts of artificial intelligence: A scoping review. *International Journal of Environmental Research and Public Health*, 20(13), 6221. <https://doi.org/10.3390/ijerph20136221>
- Gao, K., Zhou, Z., & Qin, Y. (2024). Gas concentration prediction by LSTM network combined with wavelet thresholding denoising and phase space reconstruction. *Heliyon*, 10(7), e28112. <https://doi.org/10.1016/j.heliyon.2024.e28112>
- Gao, R., Mu, B., Lyu, S., Wang, H., & Yi, C. (2022). Review of the application of wearable devices in construction safety: A bibliometric analysis from 2005 to 2021. *Buildings*, 12(3), 344. <https://doi.org/10.3390/buildings12030344>
- Global Infrastructure Hub. (2020). *Artificial intelligence applications in construction safety*. <https://www.gihub.org/>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Gündüz, M., & Laitinen, H. (2018). Construction safety risk assessment with introduced control levels. *Journal of Civil Engineering and Management*, 24(1), 11–18. <https://doi.org/10.3846/jcem.2018.284>
- Health and Safety Executive. (2010). *Estimation and assessment of substance exposure (EASE) model*. <https://www.hse.gov.uk>
- El Helaly, M. (2024). Artificial intelligence and occupational health and safety: Benefits and drawbacks. *Med Lav*, 115(2), e2024014. <https://doi.org/10.23749/mdl.v115i2.15835>
- Huber, J., Anzengruber-Tanase, B., Schobesberger, M., Haslgrübler, M., Fischer-Schwarz, R., & Ferscha, A. (2025). Evaluating user safety aspects of AI-based systems in industrial occupational safety: A critical review of research literature. *International*

*Journal of Environmental Research and Public Health*, 22(5), 705.  
<https://doi.org/10.3390/ijerph22050705>

International Labour Organization. (2025, April 28). *The right to occupational safety and health: Still unrealized*. ILOSTAT Blog. <https://ilostat.ilo.org/blog/the-right-to-occupational-safety-and-health-still-unrealized/>

T.C. Çalışma ve Sosyal Güvenlik Bakanlığı. (2012, Aralık 29). *İSG risk değerlendirmesi yönetmeliği*. Resmî Gazete, Sayı: 28512.  
<https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=16925&MevzuatTur=7&MevzuatTertip=5>

Kanten, S. (2019). *İş sağlığı ve güvenliği yönetimi*. Nobel Akademik Yayıncılık.

Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>

Karaahmetoğlu, A. (2022). Türkiye Cumhuriyetinde iş sağlığı ve güvenliği sisteminin temel dinamikleri ve uygulama alanı. *Baksı Sosyal Bilimler Dergisi*, 5(1), 1–20.  
<https://doi.org/10.46452/baksoder.1136795>

Karakaya Özkan, E., & Ulaş, H. B. (2023). Türkiye metal sektöründe yaşanan iş kazalarının Random Forest modeliyle tahminlenmesi. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(3), 1983–1997. <https://doi.org/10.21597/jist.1285239>

Kim, Y., & Choi, Y. (2022). Smart helmet based proximity warning system to improve occupational safety on the road using image sensor and artificial intelligence. *International Journal of Environmental Research and Public Health*, 19(23), 16312.  
<https://doi.org/10.3390/ijerph192316312>

Khairuddin, M. Z. F., Hui, P. L., Hasikin, K., Razak, N. A. A., Lai, K. W., Mohd Saudi, A. S., & Ibrahim, S. S. (2022). Occupational injury risk mitigation: Machine learning approach and feature optimization for smart workplace surveillance. *International Journal of Environmental Research and Public Health*, 19(21), 13962.  
<https://doi.org/10.3390/ijerph192113962>

Liu, L., Guo, Z., Liu, Z., Zhang, Y., Cai, R., Hu, X., Yang, R., & Wang, G. (2024). Multi-task intelligent monitoring of construction safety based on computer vision. *Buildings*, 14(8), 2429. <https://doi.org/10.3390/buildings14082429>

Maheronnaghsh, S., Zolfagharnasab, H., Gorgich, M., & Duarte, J. (2023). Machine learning in occupational safety and health – A systematic review. *International Journal of Occupational and Environmental Safety*, 7(1), 14–32. [https://doi.org/10.24840/2184-0954\\_007-001\\_001586](https://doi.org/10.24840/2184-0954_007-001_001586)

Malomane, R., Musonda, I., & Okoro, C. S. (2022). The opportunities and challenges associated with the implementation of Fourth Industrial Revolution technologies to manage health and safety. *International Journal of Environmental Research and Public Health*, 19(2), 846. <https://doi.org/10.3390/ijerph19020846>

Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.

Moore, P. V. (2019). OSH and the future of work: Benefits and risks of artificial intelligence tools in workplaces. In V. G. Duffy (Ed.), *Human computer interaction. HCII 2019* (pp. 292–315). Springer. [https://doi.org/10.1007/978-3-030-22216-1\\_22](https://doi.org/10.1007/978-3-030-22216-1_22)

Motorcu, A. R., & Murat, B. (2021). Yeni iş yeri riskleri ve yapay zekânın iş sağlığı ve güvenliğinde kullanımı.

[https://www.researchgate.net/publication/357888906\\_Yeni\\_Is\\_Yeri\\_Riskleri\\_ve\\_Yapay\\_Zekanin\\_Is\\_Sagligi\\_ve\\_Guvenliginde\\_Kullanimi](https://www.researchgate.net/publication/357888906_Yeni_Is_Yeri_Riskleri_ve_Yapay_Zekanin_Is_Sagligi_ve_Guvenliginde_Kullanimi)

Niu, Y., Lu, W., Xue, F., Liu, D., Chen, K., Fang, D., & Anumba, C. (2023). Towards the ‘third wave’: An SCO-enabled occupational health and safety management system for construction. *Safety Science*. <https://doi.org/10.1016/j.ssci.2018.07.013>

Patel, P., & Thakkar, A. (2020). The upsurge of deep learning for computer vision applications. *International Journal of Electrical and Computer Engineering*, 10(1), 538–548. <https://doi.org/10.11591/ijece.v10i1.pp538-548>

Pishgar, M., Issa, S. F., Sietsema, M., Pratap, P., & Darabi, H. (2021). REDECA: A novel framework to review artificial intelligence and its applications in occupational safety and health. *International Journal of Environmental Research and Public Health*, 18(13), 6705. <https://doi.org/10.3390/ijerph18136705>

Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson. <https://aima.cs.berkeley.edu/>

Sarker, I. H. (2021). Machine learning: Algorithms, real world applications and research directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>

Segura, P., Lobato Calleros, O., Ramírez Serrano, A., & Hernández Martínez, E. G. (2022). Safety assurance in human robot collaborative systems: A survey in the manufacturing industry. *Procedia CIRP*, 107, 740–745. <https://doi.org/10.1016/j.procir.2022.05.055>

Shah, I. A., & Mishra, S. (2024). Artificial intelligence in advancing occupational health and safety: An encapsulation of developments. *Journal of Occupational Health*, 66(1), uiad017. <https://doi.org/10.1093/joccuh/uiad017>

Shi, J., Chang, Y., Xu, C., Khan, F., Chen, G., & Li, C. (2020). Real time leak detection using an infrared camera and Faster R-CNN technique. *Computers & Chemical Engineering*, 135, 106780. <https://doi.org/10.1016/j.compchemeng.2020.106780>

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.

Şen, M. (2015). İş sağlığı ve güvenliği kavramı, tarihsel gelişimi ve dayanakları. *Marmara Üniversitesi Hukuk Fakültesi Dergisi*, 4(1), 117–143.

Tabatabaee, S., Mohandes, S. R., Ahmed, R. R., Mahdiyar, A., Arashpour, M., Zayed, T., & Ismail, S. (2022). Investigating the barriers to applying the Internet of Things based technologies to construction site safety management. *International Journal of Environmental Research and Public Health*, 19(2), 868. <https://doi.org/10.3390/ijerph19020868>

Tang, K. H. D. (2024). Artificial intelligence in occupational health and safety risk management of construction, mining, and oil and gas sectors: Advances and prospects. *Journal of Engineering Research and Reports*, 26(6), 241–253. <https://doi.org/10.9734/jerr/2024/v26i61177>

Taproot. (2021). *Using IoT and AI to improve occupational safety*.  
<https://taproot.com/ai-and-iot/>

Tang, S., & Golparvar-Fard, M. (2021). Machine learning based risk analysis for construction worker safety from ubiquitous site photos and videos. *Journal of Computing in Civil Engineering*, 35(6), 04021044.  
[https://doi.org/10.1061/\(ASCE\)CP.1943-5487.000009](https://doi.org/10.1061/(ASCE)CP.1943-5487.000009)

Taçgın, E., & Sağır, Z. (2020). Development of an intelligent knowledge base for identification of accident causes based on Fu et al.'s model. *International Journal of Occupational Safety and Ergonomics*.  
<https://doi.org/10.1080/10803548.2020.1831786>

Tiikkaja, M., Kannisto, H., Nurmi, A., Puro, V., Heikkilä, T., Kivimäki, I., Asikainen, I., & Teperi, A.-M. (2024). *AI-supported safety management: Analysing occupational safety data using machine learning within the framework of human factors* (33 pp.). Finnish Institute of Occupational Health. SSRN.  
[https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4879013](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4879013)

Tixier, A. J. P., Hallowell, M. R., Rajagopalan, B., & Bowman, D. (2016). Automated content analysis for construction safety: A natural language processing system to extract precursors and outcomes from unstructured injury reports. *Automation in Construction*, 62, 45–56. <https://doi.org/10.1016/j.autcon.2015.11.001>

Tunçman, B., Gündüz, T., & Yılmaz Eroğlu, D. (2024). Tekstil sektöründe iş kazalarına neden olan risk faktörlerinin veri madenciliği yöntemleriyle değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*(53), 84–96.  
<https://dergipark.org.tr/tr/pub/ejosat/issue/82065/1329001>

Veiber, L., Allix, K., Arslan, Y., Bissyandé, T. F., & Klein, J. (2020). Challenges towards production-ready explainable machine learning. In *Proceedings of the USENIX Conference on Operational Machine Learning (OpML '20)*. USENIX Association. <https://www.usenix.org/conference/opml20/presentation/veiber>

## EKLER

### EK A – Python Kodları (riskanaliz.py)

Bu ekte, yapay zekâ destekli risk sınıflandırma modelinin eğitiminde kullanılan isg\_risk\_veri\_seti.csv adlı simüle veri seti ve bu verinin modellemeye uygun hâle getirilmesini sağlayan örnek Python kodu yer almaktadır.

Söz konusu veri seti, iş sağlığı ve güvenliği kapsamında tanımlanan çeşitli **ortam türleri**, **ekipman kullanımı**, **görev karakteristikleri** ve **önleyici kontrol önlemleri** gibi değişkenlerden oluşmaktadır. Etik ve yasal hassasiyetler nedeniyle gerçek kazalardan değil, literatüre ve uzman görüşlerine dayalı olarak **yapay biçimde üretilmiş 1000 satırlık temsili senaryolar** içermektedir.

Veri kümesinde yer alan temel sütunlar şunlardır:

- **Ortam Türü** (Örn: Kapalı alan, yüksek sıcaklık ortamı)
- **Kullanılan Ekipman** (Örn: Elektrikli aletler, forklift)
- **Görev Türü** (Örn: Montaj, bakım, dış saha çalışması)
- **Kontrol Önlemleri** (Örn: KKD kullanımı, uyarı levhaları)
- **Olası Risk Sınıfı** (Hedef değişken; Yaralanma, Ölüm, Maddi Kayıp vb.)

Aşağıda sunulan Python kodu, bu veri kümesinin yapay zekâ modellerine uygun şekilde **okunması, temizlenmesi, dönüştürülmesi ve eğitim/test setlerine bölünmesi** sürecini örneklemektedir:

```
# Gerekli kütüphanelerin yüklenmesi
```

```
import pandas as pd
```

```
from sklearn.model_selection import train_test_split
```

```
from sklearn.preprocessing import LabelEncoder
```

```
# 1. Veri kümesinin yüklenmesi
```

```
df = pd.read_csv("isg_risk_veri_seti.csv")
```

```
# 2. Genel yapı ve eksik veri kontrolü
```

```

print("Veri kümesi boyutu:", df.shape)

print("Eksik değer kontrolü:\n", df.isnull().sum())

# 3. Kategorik değişkenlerin kodlanması

kategorik_degiskenler = ["Ortam Türü", "Kullanılan Ekipman", "Görev
Türü", "Kontrol Önlemleri"]

le_dict = {}

for col in kategorik_degiskenler:

    le = LabelEncoder()

    df[col] = le.fit_transform(df[col])

    le_dict[col] = le # kodlama bilgisi saklanabilir

# 4. Hedef değişkenin ayrılması

X = df.drop("Olası Risk Sınıfı", axis=1)

y = df["Olası Risk Sınıfı"]

# 5. Eğitim-test setlerine ayırma (%80 eğitim, %20 test)

X_train, X_test, y_train, y_test = train_test_split(

    X, y, test_size=0.2, random_state=42, stratify=y)

# 6. Eğitim verisinden örnek kayıt gösterimi

print("\nEğitim verisinden örnekler:")

print(X_train.head())

```

Bu yapı sayesinde geliştirilen yapay zekâ modelinin **ön işlenmiş, etik uyumlu ve analiz için optimize edilmiş verilerle** eğitilmesi sağlanmıştır. Daha gelişmiş modelleme süreçleri (ör. çapraz doğrulama, hiperparametre optimizasyonu, tahminleme algoritmaları) **Ek B ve Ek D**'de ayrıca detaylandırılmıştır.

## EK B – Model Eğitimi, ROC Analizleri ve Kod Çıktıları (Riskanaliz.ipynb ve Riskanaliz.pdf)

Bu ekte, Google Colab ortamında geliştirilen Riskanaliz.ipynb dosyasının eğitim ve değerlendirme sürecine ait kod hücreleri, grafiksel analizler ve sınıflandırma çıktıları yer almaktadır. Model, İSG kapsamında yapay zekâ tabanlı çoklu hedef sınıflandırma yapısı ile oluşturulmuş ve test edilmiştir.

Ekte sunulan içeriğin detayları şu şekildedir:

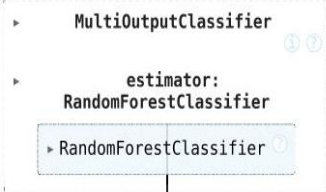
- Gerekli Python kütüphanelerinin yüklenmesi
- Simüle edilmiş veri seti ile eğitim-test ayrımı yapılması
- Random Forest algoritmasına dayalı MultiOutputClassifier modeli
- Sınıflandırma raporları (precision, recall, f1-score, accuracy)
- ROC eğrileri ve AUC skorlarının grafiksel değerlendirmesi
- Özellik önem düzeyi analizi (Feature Importance)
- XGBoost ve kalibre edilmiş XGBoost modellerinin karşılaştırılması
- GridSearchCV ve Optuna ile hiperparametre optimizasyonu
- Grafik ve tablo destekli çıktılar (PDF formatında sunulmuştur)
- Tüm içerikler Riskanaliz.ipynb dosyasından türetilmiş olup, çıktı formatında Riskanaliz.pdf olarak eklenmiştir. Kodlar ve görseller tek aralıklı şekilde düzenlenmiş, model çıktıları ve değerlendirme sonuçları açıklamalı biçimde yerleştirilmiştir.

```
In [5]: # 4. Eğitim ve test setine böl
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=42
)
```

```
In [6]: # 5. MultiOutput Random Forest modelini oluştur
multi_model = MultiOutputClassifier(RandomForestClassifier(n_estimators=100, random_state=42))
```

```
In [7]: # 6. Modeli eğit
multi_model.fit(X_train, y_train)
```

```
Out[7]:
```



✓ Model başarıyla eğitildi!

Sınıflandırma Raporu (her bir hedef için):

| Yaralanma için rapor: |           |        |          |         |  |
|-----------------------|-----------|--------|----------|---------|--|
|                       | precision | recall | f1-score | support |  |
| 0                     | 0.59      | 0.80   | 0.68     | 124     |  |
| 1                     | 0.24      | 0.11   | 0.15     | 76      |  |
| accuracy              |           |        | 0.54     | 200     |  |
| macro avg             | 0.42      | 0.45   | 0.41     | 200     |  |
| weighted avg          | 0.46      | 0.54   | 0.48     | 200     |  |

| Ölüm için rapor: |   | precision | recall | f1-score | support |
|------------------|---|-----------|--------|----------|---------|
|                  | 0 | 0.95      | 1.00   | 0.97     | 190     |
|                  | 1 | 0.00      | 0.00   | 0.00     | 10      |
| accuracy         |   |           |        | 0.95     | 200     |
| macro avg        |   | 0.47      | 0.50   | 0.49     | 200     |
| weighted avg     |   | 0.90      | 0.95   | 0.93     | 200     |

| İşten Uzaklaştırma için rapor: |           |        |          |         |     |
|--------------------------------|-----------|--------|----------|---------|-----|
|                                | precision | recall | f1-score | support |     |
| 0                              | 0.74      | 0.97   | 0.84     | 149     |     |
| 1                              | 0.20      | 0.02   | 0.04     | 51      |     |
| accuracy                       |           |        | 0.73     | 200     |     |
| macro avg                      |           | 0.47   | 0.50     | 0.44    | 200 |
| weighted avg                   |           | 0.60   | 0.73     | 0.64    | 200 |

| Transfer için rapor: |           |        |          |         |     |
|----------------------|-----------|--------|----------|---------|-----|
|                      | precision | recall | f1-score | support |     |
| 0                    | 0.82      | 1.00   | 0.90     | 165     |     |
| 1                    | 0.00      | 0.00   | 0.00     | 35      |     |
| accuracy             |           |        | 0.82     | 200     |     |
| macro avg            |           | 0.41   | 0.50     | 0.45    | 200 |
| weighted avg         |           | 0.68   | 0.82     | 0.75    | 200 |

| Diğer Vakalar için rapor: |           |        |          |         |  |
|---------------------------|-----------|--------|----------|---------|--|
|                           | precision | recall | f1-score | support |  |
| 0                         | 0.77      | 1.00   | 0.87     | 154     |  |
| 1                         | 0.00      | 0.00   | 0.00     | 46      |  |
| accuracy                  |           |        | 0.77     | 200     |  |
| macro avg                 | 0.39      | 0.50   | 0.44     | 200     |  |
| weighted avg              | 0.59      | 0.77   | 0.67     | 200     |  |

```

        verbose=2,
        n_jobs=-1
    )

    # MultiOutput ile birleştir
    multi_model = MultiOutputClassifier(grid_search)

    # Eğitim
    multi_model.fit(X_train, y_train)

```

Fitting 3 folds for each of 48 candidates, totalling 144 fits  
 Fitting 3 folds for each of 48 candidates, totalling 144 fits  
 Fitting 3 folds for each of 48 candidates, totalling 144 fits  
 Fitting 3 folds for each of 48 candidates, totalling 144 fits  
 Fitting 3 folds for each of 48 candidates, totalling 144 fits

```

Out[24]: MultiOutputClassifier
          estimator: GridSearchCV
          estimator:
            RandomForestClassifier
            RandomForestClassifier

```

```

In [25]: for i, col in enumerate(y.columns):
          print(f"\n {col} için en iyi parametreler:")
          print(multi_model.estimators_[i].best_params_)

```

Yaralanma için en iyi parametreler:  
 {'class\_weight': None, 'max\_depth': 10, 'min\_samples\_leaf': 2, 'min\_samples\_split': 2, 'n\_estimators': 200}


Ölüm için en iyi parametreler:  
 {'class\_weight': None, 'max\_depth': 10, 'min\_samples\_leaf': 1, 'min\_samples\_split': 2, 'n\_estimators': 100}




İşten Uzaklaştırma için en iyi parametreler:  
 {'class\_weight': None, 'max\_depth': 10, 'min\_samples\_leaf': 2, 'min\_samples\_split': 5, 'n\_estimators': 200}

Transfer için en iyi parametreler:  
 {'class\_weight': 'balanced', 'max\_depth': 10, 'min\_samples\_leaf': 1, 'min\_samples\_split': 5, 'n\_estimators': 200}


Diğer Vakalar için en iyi parametreler:  
 {'class\_weight': None, 'max\_depth': 10, 'min\_samples\_leaf': 2, 'min\_samples\_split': 5, 'n\_estimators': 100}

Ortalama Doğruluk (Accuracy): 0.76








ROC Eğrisi - Diğer Vakalar




Ortalama Doğruluk (Weighted): 0.76

ROC - Yaralanma






ROC - Transfer



ROC - Diğer Vakalar



Ortalama Doğruluk (Weighted): 0.76

AUC Skorları:

- Yaralanma: AUC = 0.44
- Ölüm: AUC = 0.58
- İşten Uzaklaştırma: AUC = 0.47
- Transfer: AUC = 0.51
- Diğer Vakalar: AUC = 0.54

Ağırlıklı Model Özellik Önemleri:

| Özellik              | Skor     |
|----------------------|----------|
| Deneyim (Yıl)        | 0.143863 |
| Yaş                  | 0.142564 |
| Yıldırım Riski       | 0.031822 |
| Merdiven             | 0.031270 |
| Gaz                  | 0.031131 |
| Çatı Çalışması       | 0.030928 |
| Sıkışma              | 0.030753 |
| Gürültü              | 0.030638 |
| İzolasyon Eksikliği  | 0.030527 |
| Ezilme               | 0.030347 |
| Ergonomi             | 0.030288 |
| Mantar               | 0.030237 |
| İskele               | 0.029876 |
| Solvent              | 0.029827 |
| Kaçak Akım           | 0.029639 |
| Bakteri              | 0.029469 |
| Düşme                | 0.029389 |
| Aydınlatma Eksikliği | 0.029130 |
| Virüs                | 0.029100 |
| Parazit              | 0.028876 |
| Titreşim             | 0.028750 |
| Kesilme              | 0.028744 |
| Toz                  | 0.028425 |
| Sıcaklık             | 0.028356 |
| Delinme              | 0.028334 |
| Yanıcı Madde         | 0.027717 |

Ortalama Doğruluk (XGBoost Weighted): 0.72

Sınıflandırma Raporları:

– Yaralanma –

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0            | 0.62      | 0.60   | 0.61     | 124     |
| 1            | 0.38      | 0.39   | 0.39     | 76      |
| accuracy     |           |        | 0.53     | 200     |
| macro avg    | 0.50      | 0.50   | 0.50     | 200     |
| weighted avg | 0.53      | 0.53   | 0.53     | 200     |

– Ölüm –

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0            | 0.95      | 1.00   | 0.97     | 190     |
| 1            | 0.00      | 0.00   | 0.00     | 10      |
| accuracy     |           |        | 0.95     | 200     |
| macro avg    | 0.47      | 0.50   | 0.49     | 200     |
| weighted avg | 0.90      | 0.95   | 0.93     | 200     |

– İşten Uzaklaştırma –

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0            | 0.74      | 0.74   | 0.74     | 149     |
| 1            | 0.22      | 0.22   | 0.22     | 51      |
| accuracy     |           |        | 0.61     | 200     |
| macro avg    | 0.48      | 0.48   | 0.48     | 200     |
| weighted avg | 0.60      | 0.61   | 0.61     | 200     |


– Transfer –

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0            | 0.83      | 0.95   | 0.88     | 165     |
| 1            | 0.20      | 0.06   | 0.09     | 35      |
| accuracy     |           |        | 0.80     | 200     |
| macro avg    | 0.51      | 0.50   | 0.49     | 200     |
| weighted avg | 0.72      | 0.80   | 0.75     | 200     |


– Diğer Vakalar –

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0            | 0.76      | 0.88   | 0.82     | 154     |
| 1            | 0.18      | 0.09   | 0.12     | 46      |
| accuracy     |           |        | 0.70     | 200     |
| macro avg    | 0.47      | 0.49   | 0.47     | 200     |
| weighted avg | 0.63      | 0.70   | 0.66     | 200     |


- AUC Skorları:
- Yaralanma: AUC = 0.48




- Ölüm: AUC = 0.55




- İşten Uzaklaştırma: AUC = 0.50




- Transfer: AUC = 0.53



• Diğer Vakalar: AUC = 0.49



□ Feature Importance (Ortalama XGBoost)



## **EK C – Web Arayüzü Kodu ve Uygulama Görünümü (Yapay Zekâ Destekli İSG Risk Yönetimi)**

Bu ekte, geliştirilen yapay zekâ destekli İSG risk tahmin sistemine ait web tabanlı kullanıcı arayüzünün temel HTML yapısı ve ekran görüntüsü sunulmaktadır. Uygulama, kullanıcıdan alınan bilgiler doğrultusunda eğitilmiş sınıflandırma modellerini çalıştırarak olası iş kazası sonuçlarını tahmin etmektedir.

Arayüz, sade ve kullanıcı dostu olacak şekilde tasarlanmış olup aşağıdaki bileşenleri içermektedir:

- **Başlık ve Logo Alanı:** Kurumsal görünüm ve sistem tanıtımı için üst banner.
- **Form Yapısı:** Kullanıcıdan deneyim yılı ve yaş bilgileri için kaydırıcı (slider) girişleri,
- **Risk Faktörleri:** Ortam, ekipman ve görev temelli ikili seçim alanları (Var/Yok),
- **Tahmin Butonu:** Tüm veriler girildikten sonra risk tahmininin yapılmasını sağlayan işlem butonu.

Ekte sunulan HTML kodu, Flask framework'ü ile bütünleşik olarak çalışacak biçimde yapılandırılmıştır. Arayüz, Python'da eğitilmiş sınıflandırma modeline doğrudan veri aktarımı sağlayarak gerçek zamanlı tahmin çıktısı üretecek altyapıya sahiptir.

Görsel çıktı örneği ekte yer almaktadır. Kod dosyası `templates/index.html` konumunda saklanmaktadır.

Deneyim (Yıl):  Yaş:

|                                  |                                  |                                  |                                  |
|----------------------------------|----------------------------------|----------------------------------|----------------------------------|
| Görüşle                          | Tireğin                          | Ergonomi                         | Sıcaklık                         |
| <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> |
| Aydınlatma Eksikliği             | Solvent                          | Gaz                              | Toz                              |
| <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> |
| Yanıcı Madde                     | Bakteri                          | Virüs                            | Mantar                           |
| <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> |
| Parazit                          | Ezime                            | Kesime                           | Sıkıma                           |
| <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> |
| Delinme                          | Kaçak Akım                       | İzolasyon Eksikliği              | Yıldırım Riski                   |
| <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> |
| İskele                           | Mandren                          | Çatı Çalışması                   | Düşme                            |
| <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> | <input type="text" value="Yok"/> |

**Tahmin Et**

## EK D – Tahmin Sonuçları Arayüzü, Görsel Çıktılar ve Açıklamalı Kod (Risk Tahmin Sonuçları.html)

Bu ekte, yapay zekâ destekli İSG risk tahmin sisteminin çıktı modülüne ait kullanıcı arayüzü, model sonuçları ve bu sonuçları oluşturan açıklamalı Python kodu sunulmaktadır. HTML formatındaki bu yapı, farklı algoritmalarla yapılan tahminlerin hem grafiksel hem de sayısal olarak görselleştirilmesini sağlamaktadır.



Arayüzde yer alan başlıca bileşenler şunlardır:

- **Model Seçimi ve Açıklaması:** Kullanılan algoritmaların (örneğin XGBoost, Random Forest) isimleri ve kısa açıklamaları,
- **Sonuçların Görselleştirilmesi:** Her bir modelin tahmin ettiği risk sınıflarına ait olasılıkların **pasta grafik** ile gösterimi (Chart.js kullanılarak),
- **Risk Tahmin Tablosu:** Aynı sonuçların yüzdesel olarak tablo hâlinde sunulması,
- **Kod Açıklamaları:** Python ile geliştirilen ve HTML'ye gömülen JavaScript kodları sayesinde, her model çıktısı dinamik biçimde çizdirilmektedir.

Ekte sunulan örnek çıktı, XGBoost algoritması ile oluşturulan bir tahmin sonucunu göstermektedir. Pasta grafik, farklı risk türlerine (örneğin: Yaralanma, Ölüm, Transfer


vb.) karşılık gelen olasılıkları kullanıcıya sunar. Tabloda ise bu yüzdeler ayrı satırlar hâlinde listelenir.

Ayrıca, bu görselleştirme sürecinde kullanılan Python kodları, yorum satırları eşliğinde belge içine eklenmiş olup, sistemin nasıl çalıştığı açık biçimde anlaşılabilir. Kodlar Flask çatısına entegre olacak biçimde Jinja2 şablon yapısı kullanılarak geliştirilmiştir.



**XGB\_CAL***Kalibre Edilmiş XGBoost: Olasılık tahminleri daha güvenilir.*

| Sonuç              | Risk (%) |
|--------------------|----------|
| Yaralanma          | 35.7     |
| Ölüm               | 4.5      |
| İşten Uzaklaştırma | 31.0     |
| Transfer           | 29.4     |
| Diğer Vakalar      | 19.7     |

**XGB\_OPT***Optimize XGBoost: Hiperparametreleri ayarlanmış gelişmiş model.*

| Sonuç              | Risk (%) |
|--------------------|----------|
| Yaralanma          | 41.3     |
| Ölüm               | 1.6      |
| İşten Uzaklaştırma | 54.7     |
| Transfer           | 20.1     |
| Diğer Vakalar      | 10.0     |

## ÖZGEÇMİŞ

**Adı Soyadı:** Mehmet YILDIRIM

**Medeni Durum:** Evli, iki çocuk babası

**Unvan:** Mühendis

**Çalıştığı Kurum:** Elazığ Aile ve Sosyal Hizmetler İl Müdürlüğü

- **EĞİTİM BİLGİLERİ**

- **Fırat Üniversitesi**, Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü (Lisans - Devam Ediyor)
- **Namık Kemal Üniversitesi**, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme ve Yönetimi (Tezsiz Yüksek Lisans – Tamamlandı)
- **Biruni Üniversitesi**, Fen Bilimleri Enstitüsü, İş Sağlığı ve Güvenliği (Tezsiz Yüksek Lisans – Tamamlandı, 2019-2020)
- **Karadeniz Teknik Üniversitesi**, Jeodezi ve Fotogrametri Mühendisliği Bölümü (Lisans – Mezuniyet: 2013)
- **Karadeniz Teknik Üniversitesi**, Biyoloji (İngilizce) Bölümü (2007 – 2009)
  - Hazırlık eğitimi: KTÜ Milli Piyango Yabancı Diller Yüksekokulu (2007-2008)

- **MESLEKİ DENEYİM**

- **Mühendis – Elazığ Aile ve Sosyal Hizmetler İl Müdürlüğü** (2022 – Halen)
- **Harita Mühendisi – Aile ve Sosyal Hizmetler Bakanlığı, Merkez Teşkilat** (2013 – 2022)
- **Memur – Gümüşhane Aile ve Sosyal Hizmetler İl Müdürlüğü** (2011 – 2013)
- **Harita Mühendisi – Barış Kartal Projesi, 3. Ana Jet Üssü Komutanlığı (Askerlik Görevi)** (2015 – 2016)

- **DİĞER BİLGİLER**

- Askerlik hizmetini 3. Ana Jet Üssü’nde Harita Mühendisi olarak tamamladım.
- Üniversite öğrenimi sırasında memuriyet görevini sürdürdüm.
- İş Sağlığı ve Güvenliği, harita mühendisliği ve inşaat mühendisliği alanlarında disiplinler arası deneyim sahibim.
- Kamu kurumlarında uzun süreli teknik görev tecrübesine sahibim.