

T.C.
BİNGÖL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKÂ DESTEKLİ İŞ GÜVENLİĞİ MODELLEMESİ

YÜKSEK LİSANS TEZİ

Fatoş DAVRAN

İŞ SAĞLIĞI VE GÜVENLİĞİ ANABİLİM DALI

TEZ DANIŞMANI

Prof. Dr. Ramazan SOLMAZ

BİNGÖL - 2025

ÖNSÖZ

Yüksek lisans eğitimin süresince yardımlarını ve bilgi birikimini esirgemeyen, çalışmalarımın tamamlanabilmesi için gerekli desteği veren değerli hocam Prof. Dr. Ramazan SOLMAZ'a teşekkür ederim.

Tez çalışmasında yaptıkları yönlendirmeler ve katkılardan dolayı Mehmet BARAÇ'a ve uygulama çalışmalarım esnasında yardımlarını gördüğüm Mehmet YILDIZ'a teşekkürlerimi sunuyorum.

Son olarak bende büyük emekleri olan, benim için hiçbir fedakarlıktan kaçınmayan ve dualarını esirgemeyen annem Sayime DAVRAN, babam Feyzi DAVRAN ve kardeşlerime teşekkürü bir borç bilirim.

Fatoş DAVRAN

Bingöl 2025

İÇİNDEKİLER

ÖNSÖZ	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
ÖZET.....	viii
ABSTRACT.....	ix
1. GİRİŞ.....	1
1.1. İş Sağlığı ve Güvenliği	2
1.1.1. İş Sağlığı ve Güvenliğinin Tanımı ve Önemi.....	2
1.2.2. Risk Değerlendirmesi ve Yönetimi	5
1.2. Yapay Zekâ ve İlgili Teknolojiler	7
1.2.1. Yapay Zekânın Tanımı ve Tarihsel Gelişimi	7
1.2.2. Makine Öğrenmesi ve Derin Öğrenme	9
1.2.3. Bilgisayarlı Görü (Computer Vision).....	12
2. KAYNAK ÖZETLERİ.....	14
3. MATERYAL VE YÖNTEM.....	20
3.1. Araştırmanın Modeli.....	20
3.2. Veri Setinin Oluşturulması ve Hazırlanması	21
3.2.1. Veri Toplama	21
3.2.2. Veri Etiketleme (Annotation)	22
3.2.3. Veri Setinin Bölünmesi ve Ön İşleme	25
3.3. Kullanılan Yapay Zekâ Modeli: YOLOv5.....	26
3.3.1. YOLO Mimarisine Genel Bakış.....	27
3.4. Modelin Eğitilmesi	29
3.4.1. Eğitim Ortamı ve Parametreler	29
3.4.2. Eğitim Sürecinin İzlenmesi	30
3.5. Modelin Değerlendirilmesi ve Sonuçların Analizi	31
3.5.1. Değerlendirme Metrikleri	31

3.5.2. Eğitim Sonuçlarının Analizi	32
3.5.3. Modelin Görsel Çıktılarının Değerlendirilmesi	33
4. BULGULAR VE TARTIŞMA	34
4.1. Model Performansına İlişkin Bulgular	34
4.1.1. Nicel Bulgular: Sayısal Performans Analizi	34
4.1.2. Nitel Bulgular: Görsel Analiz	39
4.2. Bulguların Literatür Çerçevesinde Tartışılması.....	42
4.3. Geliştirilen Modelin İSG Alanındaki Potansiyel Uygulamaları ve Katkıları.....	43
4.4. Karşılaşılan Zorluklar ve Etik Hususlar	44
5. SONUÇLAR VE ÖNERİLER	46
5.1. Sonuçlar	46
5.2. Öneriler	47
KAYNAKLAR.....	50
EKLER.....	566
Ek-A Model Eğitim Sürecinin Konsol Çıktısı.....	566

SİMGELER VE KISALTMALAR LİSTESİ

AI	: Yapay Zekâ (Artificial Intelligence)
AP	: Ortalama Duyarlılık (Average Precision)
COCO	: Nesne Tespiti Modellerinin Eğitiminde Kullanılan Standart Veri Seti (Common Objects in Context)
DETR	: Tespit Transformatörü (Detection Transformer)
DL	: Derin Öğrenme (Deep Learning)
FFH	: Yüksekten Düşme (Fall from Height)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
FPS	: Saniyedeki Kare Sayısı (Frames Per Second)
GDPR	: Genel Veri Koruma Yönetmeliği (General Data Protection Regulation)
GIGO	: Garbage In, Garbage Out (Çöp Girse, Çöp Çıkar)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
IBM	: Uluslararası İş Makineleri Şirketi (International Business Machines Corporation)
ID-CNN	: Tek Boyutlu Konvolüsyonel Sinir Ağı (One-Dimensional Convolutional Neural Network)
ILO	: Uluslararası Çalışma Örgütü (International Labour Organization)
IP	: İnternet Protokolü
IoT	: Nesnelerin İnterneti (Internet of Things)
IoU	: Tahmin Kutusu ile Gerçek Kutunun Örtüşme Oranı (Intersection over Union)
İSG	: İş Sağlığı ve Güvenliği (Occupational Health and Safety)
KKD	: Kişisel Koruyucu Donanım (Personal Protective Equipment)
mAP	: Ortalama Doğruluk (Mean Average Precision)
MBS	: Mevzuat Bilgi Sistemi (Legislation Information System)
ML	: Makine Öğrenmesi (Machine Learning)

MYCIN	: Enfeksiyon teşhisi ve antibiyotik seçimi için kural tabanlı yapay zekâ Sistemi (Rule-Based Artificial Intelligence System for Infection Diagnosis and Antibiotic Selection)
OCR	: Optik Karakter Tanıma (Optical Character Recognition)
OHS	: İş Sağlığı ve Güvenliği (Occupational Health and Safety)
OS	: Nesne Çarpması (Struck by Object)
P	: Kesinlik (Precision)
PPE	: Kişisel Koruyucu Donanım (Personal Protective Equipment)
PRISMA	: Sistematik İncelemeler ve Meta-Analizler için Tercih Edilen Raporlama Maddeleri (Preferred Reporting Items for Systematic Reviews and Meta-Analyses)
R	: Geri Çağırma / Duyarlılık (Recall)
REDECA	: Risk Evrimi, Tespiti, Değerlendirilmesi ve Kazaların Kontrolü (Risk Evolution, Detection, Assessment, and Accident Control)
ReID	: Yeniden Kimlik Tespiti (Re-Identification)
SSD	: Tek Geçişli Çoklu Nesne Algılayıcı (Single Shot MultiBox Detector)
TP	: Doğru Pozitif (True Positive)
WHO	: Dünya Sağlık Örgütü (World Health Organization)
YOLO	: Tek Aşamalı Nesne Tespit Algoritması (You Only Look Once)
YSA	: Yapay Sinir Ağları (Artificial Neural Networks)
YZ	: Yapay Zekâ (Artificial Intelligence)

ŞEKİLLER LİSTESİ

Şekil 1.1. Yapay Zekâ, makine öğrenmesi ve derin öğrenme ilişkisi	11
Şekil 3.1. Veri seti için görüntü işleme adımları	21
Şekil 3.2. Veri etiketleme dosyaları.....	22
Şekil 3.3. Veri etiketleme	23
Şekil 3.4. Veri setinin yükleme arayüzü	24
Şekil 3.5. Veri seti dağılımı	26
Şekil 3.6. YOLO algoritmasının çalışma prensibi	28
Şekil 4.1. 100 Epoch'luk eğitimin tamamlanma çıktısı ve performans özeti	35
Şekil 4.2. Loss fonksiyon grafikleri	37
Şekil 4.3. Modelin performans metrikleri grafikleri (Precision, Recall, mAP)	39
Şekil 4.4. Modelin test görüntüleri üzerindeki başarılı tespit örnekleri (val_batch0_labels.jpg).....	40
Şekil 4.5. Modelin farklı senaryolardaki nesne tespiti çıktıları.....	41
Şekil 4.6. Örnek görüntüler üzerinde sınırlayıcı kutularla etiketleme	42

TABLÖLAR LİSTESİ

Tablo 4.1. Modelin sınıf bazında performans metrikleri.....	36
---	----

YAPAY ZEKÂ DESTEKLİ İŞ GÜVENLİĞİ MODELLEMESİ

ÖZET

Bu tez çalışmasında, iş sağlığı ve güvenliği (İSG) alanında kazaları önlemek için proaktif bir yaklaşım geliştirilmesi amaçlanmış ve yapay zekâ (YZ) tabanlı bir modelleme önerilmiştir. Geleneksel İSG yöntemleri genellikle reaktif nitelik taşımakta ve kazalar meydana geldikten sonra önlemler alınmaktadır. Bu tezde sunulan model ile iş yerlerinde meydana gelebilecek potansiyel tehlikelerin ve güvensiz durumların anlık tespit edilmesi, muhtemel kazaların ise önceden önlemesi hedeflenmektedir.

Çalışmanın temel amacı, kişisel koruyucu donanım (KKD) kullanımını otomatik olarak izleyen bir bilgisayarlı görü sistemi geliştirmektir. Bu amaçla, “You Only Look Once (YOLOv5)” algoritması kullanılarak bir nesne tespiti modeli oluşturulmuştur. Modeli eğitmek için, “insan”, “kask”, “yelek” ve “eldiven” sınıflarını içeren 2512 görüntüden oluşan bir veri seti hazırlanmıştır. Görüntüler, eğitim (%70), doğrulama (%20) ve test (%10) kümelerine ayrılarak etiketleme sürecinden geçirilmiştir. Bu süreç, sistemin görsel girdilerden öğrenmesini ve doğru sınıflandırmalar yapmasını sağlayacak temel adım olmuştur.

Eğitim, 100 devir (epoch) boyunca, kayıp fonksiyonlarını azaltmayı ve ortalama duyarlılık (mAP) metriklerini iyileştirmeyi hedefleyerek yürütülmüştür. Sonuçlar, modelin mAP@0.5'te %86,6 başarı oranına ulaştığını göstermektedir. Kask (%97,8) ve yelek (%96,5) sınıflarında, kesinlik ve geri çağırma oranları %97'nin üzerinde gerçekleşmiştir. Bu, bulgu modelin bu ekipmanları tespit etmede yüksek performans sergilediğini ortaya koymaktadır. Ancak eldiven tespiti (%56,5), nesnelerin küçük boyutu, farklı türleri ve sıkça örtülü olması nedeniyle daha düşük bir performans göstermiştir. Bu durum, modelin pratik uygulamadaki sınırlılıklarını ve geliştirilmesi gereken yönlerini açıkça ortaya koymaktadır.

Geliştirilen sistem, mevcut güvenlik kameralarına entegre edilerek KKD ihlallerini gerçek zamanlı olarak tespit edebilir. Veri setinin çeşitlendirilmesi, farklı aydınlatma koşullarının ve farklı KKD türlerinin eklenmesi, modelin doğruluğunu artıracaktır. Ayrıca, sistemin etik boyutları (örneğin, çalışan mahremiyetinin korunması ve yanlış tespitlerin yol açabileceği hukuki sorumluluklar) ayrıntılı biçimde ele alınmalıdır. İleride yapılacak saha testleri ve sektörlerde gerçekleştirilecek uyarlamalar, "sıfır kaza" hedefine ulaşmada önemli bir adım olacaktır.

Anahtar Kelimeler: İş sağlığı ve güvenliği, Yapay zekâ, Makine öğrenmesi, Derin öğrenme, Bilgisayarlı görü, YOLOv5, Kişisel koruyucu donanım.

ARTIFICIAL INTELLIGENCE–ASSISTED OCCUPATIONAL SAFETY MODELING

ABSTRACT

In this thesis, a proactive approach to accident prevention in the field of Occupational Health and Safety (OHS) is proposed through an artificial intelligence (AI)-based modeling framework. Traditional OHS methods are typically reactive, with interventions occurring after accidents have taken place. The model presented here aims to enable real-time detection of potential hazards and unsafe conditions in workplaces and to prevent possible accidents in advance.

The primary objective of the study is to develop a computer vision system that automatically monitors the use of personal protective equipment (PPE). To this end, an object detection model was built using the “You Only Look Once (YOLOv5)” algorithm. For model training, a dataset of 2,512 images containing the classes “person,” “helmet,” “vest,” and “glove” was assembled. The images were split into training (70%), validation (20%), and test (10%) sets and subjected to an annotation process. This process constitutes the foundational step that enables the system to learn from visual inputs and perform accurate classifications.

Training was conducted for 100 epochs, targeting the reduction of loss functions and the improvement of mean Average Precision (mAP) metrics. The results indicate that the model achieved an mAP@0.5 of 86.6%. For the helmet (97.8%) and vest (96.5%) classes, both precision and recall exceeded 97%, demonstrating strong detection performance for these categories. However, glove detection (56.5%) was comparatively weaker, likely due to the small size of the objects, their diverse types, and frequent occlusions. These findings clearly reveal the model’s practical limitations and the areas requiring improvement.

The developed system can be integrated into existing security camera infrastructures to detect PPE violations in real time. Diversifying the dataset—by incorporating different lighting conditions and additional PPE types—may further enhance accuracy. Moreover, the system’s ethical dimensions (e.g., safeguarding employee privacy and addressing potential legal liabilities stemming from false detections) should be examined in detail. Future field tests and sector-specific adaptations will represent important steps toward achieving the “zero-accident” goal.

Keywords: Occupational health and safety, Artificial intelligence, Machine learning, Deep learning, Computer vision, YOLOv5, Personal protective equipment.

1. GİRİŞ

Sanayi devrimleri, üretim yöntemlerini dönüştürmenin ötesinde, çalışma hayatını, iş sağlığı ve güvenliği (İSG) anlayışını ve toplumsal yapıyı köklü bir şekilde değiştirmiştir. Özellikle “Endüstri 4.0” ile ortaya çıkan siber-fiziksel sistemler, nesnelerin interneti (IoT), büyük veri ve yapay zekâ (YZ) gibi teknolojiler, sanayinin her alanında derin etkiler yaratmıştır (Schwab, 2017). Bu yenilikler, üretimde verimliliği artırırken, İSG alanında hem yeni fırsatlar hem de farklı zorluklar ortaya çıkarmıştır (Gürcan, 2021).

İSG, çalışanların yalnızca fiziksel sağlığını değil, aynı zamanda ruhsal ve sosyal refahını da koruyarak güvenli ve sürdürülebilir bir çalışma ortamı sağlamayı hedefleyen çok disiplinli bir alandır (ASBÜ, 2017). Uluslararası Çalışma Örgütü (ILO), her yıl yaklaşık 3 milyon insanın iş kazaları veya meslek hastalıkları nedeniyle hayatını kaybettiğini, milyonlarca çalışanın ciddi şekilde yaralandığını rapor etmektedir (Url-1, 2025). Bu kayıplar, bireysel trajedilerin yanı sıra işletmelere ve ülke ekonomilerine büyük maliyetler yüklemektedir. Türkiye’de özellikle inşaat, madencilik ve ağır sanayi gibi yüksek riskli sektörlerde iş kazaları oldukça yaygındır (Ceylan, 2014; Atalay, 2015). Geleneksel İSG yaklaşımları, genellikle denetimlere, kurallara ve kaza sonrası analizlere dayanmaktadır. Ancak bu reaktif yöntemler, kazaların kök nedenlerini ortadan kaldırmada veya kalıcı bir güvenlik kültürü oluşturmada yetersiz kalmaktadır (Howard, 2019). İnsan hataları, dikkatsizlik, yorgunluk ve kurallara uymama, kazaların büyük bir kısmını oluşturmaktadır. Bu noktada, teknolojik destekli proaktif çözümlere ihtiyaç duyulmaktadır.

YZ, bu ihtiyacı karşılamada en umut verici teknolojilerden biridir. Karmaşık verileri analiz etme, örüntü tanıma ve insan benzeri kararlar alma yeteneğiyle yapay zekâ, İSG’de devrim yaratabilir (Howard, 2019; Murat vd., 2021). Bilgisayarlı görü, makine öğrenmesi ve derin öğrenme gibi teknolojiler, güvensiz davranışları anında tespit etme, riskleri öngörme ve meslek hastalıklarını erken teşhis etme gibi uygulamalarda öne çıkmaktadır (Gürcan, 2021).

Bu tez çalışması, YZ'nın İSG'deki dönüştürücü potansiyeline odaklanarak, özellikle kişisel koruyucu donanım (KKD) kullanımını otomatik denetleyen bir bilgisayarlı görü modeli geliştirmiştir. Modelin sahadaki uygulanabilirliği ve etkisi detaylı bir şekilde incelenmiştir. Çalışmada, bu sistemin iş kazalarını önlemede nasıl proaktif bir araç olabileceği ve mevcut İSG sistemlerine nasıl entegre edilebileceği tartışılmıştır.

1.1. İş Sağlığı ve Güvenliği

1.1.1. İş Sağlığı ve Güvenliğinin Tanımı ve Önemi

Dünya Sağlık Örgütü (WHO) ve ILO tarafından yapılan ortak tanıma göre, İSG; çalışanların fiziksel, ruhsal ve sosyal iyilik hallerini en üst düzeyde tutmayı, çalışma koşullarından kaynaklanan sağlık sorunlarını önlemeyi ve çalışanları fizyolojik ile psikolojik durumlarına uygun iş ortamlarında çalıştırmayı hedefleyen çok disiplinli bir alan olarak tanımlanmaktadır (Jilcha ve Kitaw, 2016).

Türkiye'de İSG, 2012'de yürürlüğe giren 6331 sayılı İş Sağlığı ve Güvenliği Kanunu ile sağlam bir yasal zemine kavuşturulmuştur. Bu kanun, işveren ile çalışanların görev, yetki ve yükümlülüklerini, işyerlerinde risklerden korunma ilkesini belirlemiştir. Kanun, risklerden kaçınılmasını, kaçınılması mümkün olmayan riskleri analiz etmeyi, risklerle kaynağında mücadele etmeyi, tehlikeli olanı tehlikesiz veya az tehlikeli olan ile değiştirmeyi vb. yerine getirilmesi gereken ilkeleri işveren yükümlülükleri arasında belirlemiştir (MBS, 2012).

İSG'nin önemi üç temel boyutta toplanabilir:

a) İnsani boyut: Her çalışanın güvenli ve sağlıklı bir ortamda çalışması yasal zorunluluk değil, temel bir insani haktır. İş kazaları ya da meslek hastalıkları, sadece çalışanı değil, ailesini, arkadaşlarını, iş yerini ve çevresini de derinden etkilemektedir. Bir inşaat işçisinin yüksekte düşmesi ya da bir fabrika çalışanının kimyasal bir maddeye maruz kalarak sağlık sorunları yaşaması sadece bir istatistiki veri olarak değerlendirilmemeli ayrıca insan yaşamlarını değiştiren olaylar olarak da düşünülmelidir. İSG'nin temel amacı bu iş kazaları ve meslek hastalıklarını önlemektir.

b) Ekonomik boyut: Meslek hastalıklarının ve iş kazalarının maliyeti, işletmeler açısından oldukça yüksektir. İş kazası maliyetleri, direkt ve endirekt diğer bir ifadeyle dolaylı ve dolaysız maliyet olarak da iki ana gruba ayrılmaktadır (Bütüner ve Uzun, 2010). Devletin yasama yetkisini kullanarak getirdiği yasal düzenlemeler sonucu ortaya çıkan maliyetler dolaysız maliyetlerdir. Bunlar; tıbbi harcamalar, tazminatlar ya da sigortalıya ödenen vb. maliyetler iken, dolaylı maliyetler; işin durdurulması, üretimde aksamalar, iş gücü kaybı, iş günü kaybı, hasar gören makineler, mahkeme masrafları ya da işletmenin prestij kaybı vb. olabilmektedir (Demir, 2009).

c) Yasal boyut: İşverenler, çalışanlarının sağlığını ve güvenliğini hem ulusal hem de uluslararası düzenlemeler gereği korumakla yükümlüdür. Bunlarla ilgili bazı sözleşmeler şunlardır; eşit ücret sözleşmesi, zorla çalıştırmanın yasaklanması sözleşmesi, asgari yaş sözleşmesi vb. Bu yükümlülöklere uymamak, ciddi para cezaları ya da hukuki yaptırımlarla sonuçlanabilmektedir (Url-2, 2025).

Sonuç olarak İSG, sadece prosedür ya da yönetmelikten ibaret değildir. İSG alanının temel odak noktasını, iş kazaları ve meslek hastalıklarının önlenmesidir.

5510 sayılı Sosyal Sigortalar ve Genel Sağlık Sigortası Kanunu'nun 13. maddesine göre iş kazası; sigortalının işyerinde bulunduğu sırada, işveren tarafından yürütölmekte olan iş nedeniyle, sigortalının görevli olarak işyeri dışında başka bir yere gönderilmesi sırasında veya emziren kadın sigortalının çocuğuna süt vermek için ayrılan zamanlarda meydana gelen ve sigortalıyı hemen veya sonradan bedenen ya da ruhen engelli hale getiren olaydır (MBS, 2006). İş kazalarının tek bir deneni yoktur, birçok faktörün birbirleri ile etkileşimleri neticesinde meydana gelmektedir. Genellikle ani ve beklenmedik olaylar sonucu ortaya çıkar ve etkileri anında görülür. Örneğın, çalışanların yorgun ve dikkatsiz olması, yetkisiz kişilerin çalıştırılması, düzensiz ve dağınık işyeri ortamı, cihazların gerekli bakımlarının yapılmaması, gerekli uyarı işaret ve yazılarının konmamış olması, iletişim eksikliği gibi birçok etken iş kazalarına neden olmaktadır (Ceylan & Avan, 2012).

İş kazalarının başında dikkatsiz çalışma ve güvensiz hareketler gelmektedir. Buna bağılı olarak iş kazalarının önüne geçebilmek için makineler tasarlanırken çalışanların

yapabilecekleri hatalar göz önünde bulundurularak bunlara uygun tedbirler alınmalıdır (Uşar vd, 2018). İş kazalarının nedenleri iki ana grupta toplanır:

1) Tehlikeli Durumlar: İş yerinin çevresel ve fiziksel faktörleri ile ilgili olup çalışanların kontrolü dışındaki durumlardır. Örneğin, kaygan zemin, bakımı yapılmamış makina, yetersiz aydınlatma, havalandırmanın yetersiz olması gibi.

2) Tehlikeli Davranışlar: Tamamen insan faktörü ile alakalı olup, çalışanın tavır, hal ve hareketlerinden kaynaklı ortaya çıkan tehlikelerdir. Örneğin, bir işçinin KKD kullanmadan çalışması, bir teknisyenin yetkisi olmadığı halde bir makineyi tamir etmeye kalkması ya da yorgun bir çalışanın dikkatsizce hareket etmesidir. Araştırmalar, iş kazalarının %80'i çalışan, %18'i fiziksel ve mekanik çevre şartları, %2'si ise beklenmedik olaylardan kaynaklandığını göstermektedir (Bozkurt ve Naycı, 2021).

Meslek Hastalıkları; sigortalının yaptığı işin niteliğinden dolayı tekrarlanan sebeplerle veya işin yürütüm koşullarından dolayı ortaya çıkan kalıcı ya da geçici hastalıklar, bedensel veya ruhsal engellilik halleridir (Url-3, 2025). Örneğin, kaynak dumanları başlıca solunum yoluyla alınır. Zararlı etkilerini öncelikle solunum yollarında ve akciğerlerde gösterirler. Zamanla tüm vücutta çeşitli etkilere de neden olabilirler. Dumanı boğazda, gözlerde, burunda yanma, bulantı, kusma, baş ağrısı, nefes darlığı, ateş gibi etkilere neden olabilir. Sigara içen, iyi havalandırılmayan iş ortamlarında çalışan ve kişisel koruyucu malzemelerin kullanımına özen göstermeyen çalışanlarda solunum fonksiyonları daha çok bozulur ve kaynakçı akciğeri, kaynakçı pnömokonyoz hastalığı görülür (Cömert ve ark., 2014).

Meslek hastalıkları genellikle uzun vadede ortaya çıktığından tespiti iş kazalarına göre daha zordur. Ancak etkin bir İSG yönetimiyle büyük ölçüde engellenebilir. Bu noktada, risklerin doğru bir şekilde tanımlanması büyük önem taşımaktadır.

1.2.2. Risk Değerlendirmesi ve Yönetimi

Risk değerlendirme, işyerinde var olan ya da dışarıdan gelebilecek tehlikelerin belirlenmesi, bu tehlikelerin riske dönüşmesine yol açan faktörler ile tehlikelerden kaynaklanan risklerin analiz edilerek derecelendirilmesi ve kontrol tedbirlerinin kararlaştırılması amacıyla yapılması gereken sistematik çalışmalardır (Url-4, 2025). Risk değerlendirme çalışmalarında tehlikelerin tanımlanması, tehlikelere bağlı olarak gelişen risklerin belirlenmesi ve analizi, risklerin derecelendirilmesi, kontrol uygulanması ve izleme aşamaları sistematik olarak uygulanır.

Risk değerlendirme süreci şu adımlardan oluşur:

a) Tehlikelerin tanımlanması: Tehlikelerin belirlenmesi aşamasında güvensiz davranış ve güvensiz koşullara dikkat edilmesi gerekmektedir (Kabakulak, 2019). Çalışma ortamında bulunan tehlikeler ve bunların etkileşimi sonucu ortaya çıkabilecek durumlar belirlenir ve kayda alınır (MBS, 2012). Örneğin, işyerindeki kaygan zeminler (fiziksel), kaynak sektöründe ortamda bulunan gazlar (kimyasal), çalışanların sandalye yüksekliği ve oturuş biçimleri (ergonomik) gibi.

b) Risklerin belirlenmesi ve analizi: İşletmeye uygun doğru risk analiz metodunun seçimi önemlidir. Tehlikeler ayrı ayrı dikkate alınarak tespit edilmeli, bu tehlikelerden kaynaklanacak risklerin hangi sıklıkta oluşabileceği ve hangi şiddette zarar verebileceği belirlenir. Sürekli kontrol yapılarak mevcut durum gözden geçirilerek tedbirler alınmalıdır (MBS, 2012).

c) Risklerin derecelendirilmesi: Risk değerlerinin bulunmasının amacı, varlıkları tehdit eden risklere değerler atayıp onları derecelendirmektir (Eskiyörük, 2007). Her tehlike için risk skoru olasılık ve şiddet değerlerinin belirlenip çarpılmasıyla elde edilir.

$$(\text{Risk} = \text{Olasılık} \times \text{Şiddet})$$

$$(1.1)$$

Belirlenen tehlikenin meydana gelme olasılığı değerini belirlemede, tehlikeye maruziyetin süresi ve sıklığı, kişisel koruyucu donanımların sağladığı koruma ve kullanılma durumları

ve çalışanların güvensiz davranışları da dikkate alınır. Tehlikenin oluşturduğu risk meydana geldiğinde sonucu (şiddeti) hakkında değer vermek için bir değer belirlemesi yapılır (Kabakulak, 2019).

d) Kontrol önlemlerinin planlanması: Bir iş yerindeki risk değerlendirme sürecinin kritik bir aşaması, yüksek riskli olarak belirlenen tehlikeler için etkili kontrol tedbirlerinin planlanması ve uygulanmasıdır. Risk kontrol hiyerarşisi 'ne göre tedbirler alınmalıdır.

Bu hiyerarşi en üstten en alta doğru gerçekleştirilir. Risk kontrol Hiyerarşisi'nin ilk basamağında risklerin ortadan kaldırılması (yok etme) ve az riskli olan ile yer değiştirme (ikame) yer alır. Örneğin, zararlı bir solvent yerine çevre dostu bir ürün kullanmak. Buna rağmen tehlike devam ediyorsa, mühendislik uygulamaları devreye girer. Bu kontroller, işletmenin finansal yapısıyla ilgili olup, tehlikeyi kaynağında azaltacak fiziksel çözümler sunar. Örneğin, iş yerinin havalandırma sisteminin iyileştirilmesi veya risk teşkil eden makineye koruyucu bir kapak takmak.

Mühendislik kontrolleri de yetersiz kaldığında, idari kontroller uygulanır. Bunlar, çalışma şeklini ve süreçlerini düzenleyen kuralları içerir. Örneğin, her sektörün taşıdığı risklere göre çalışanlarına eğitimler vermek, tehlikeli bir alanda geçirilen süreyi azaltmak veya çalışanların KKD kullanımının sağlanması (Şardan, 2005).

e) Uygulama ve izleme: Süreç verimliliğini ve etkinliğini belirleyen en önemli faktörlerden biri kontrol önlemlerinin hayata geçirilmesinin ardından, bu tedbirlerin etkinliğinin sürekli olarak izlenmesi büyük önem taşır (Kılıç, 2017). İşyerinde meydana gelen değişiklikler, yeni makinelerin alınması veya çalışma koşullarındaki değişimler, risk değerlendirme sürecinin güncellenmesini ve kontrol tedbirlerinin gözden geçirilmesini gerektirir. Bu döngüsel süreç, iş sağlığı ve güvenliğinin dinamik ve sürekli gelişen bir yapı olduğunu vurgular.

Geleneksel risk değerlendirme yöntemleri uzmanların görüşlerine ve manuel analizlere dayanmaktadır. Ancak YZ tabanlı sistemler, özellikle yapay sinir ağları (YSA) gibi yaklaşımlar, nicel risk değerlendirmesi için bir alternatif sunar. YSA yaklaşımı, büyük veri setlerini analiz ederek olası kazaların sıklığını öngörebilme ve hataları minimize edebilme

potansiyeline sahiptir. Böylece, risk yönetimi, YSA'nın öğrenme ve genelleme yapma yeteneği sayesinde daha doğru tahminler yaparak daha hızlı, etkin ve öngörücü bir hale gelmektedir (Koçar ve Dizdar, 2018).

1.2. Yapay Zekâ ve İlgili Teknolojiler

1.2.1. Yapay Zekânın Tanımı ve Tarihsel Gelişimi

YZ, insan Zekâsını bilgisayar aracılığıyla taklit etmektir (Pirim, 2006). Öğrenme, akıl yürütme, problem çözme, algılama, dil anlama ve yaratıcılık gibi bilişsel işlevler, YZ'nin kapsamına giren temel yetkinliklerdir (Russell&Norvig, 2003). YZ, bir makinenin insanların öğrenme ve problem çözme gibi insan zihniyle ilişkilendirilen bilişsel fonksiyonları taklit etmesi anlamına gelir (Banger, 2018).

Yapay zekâ, çevresini algılayıp bu bilgilere dayanarak eylemler gerçekleştiren 'ajan' adı verilen sistemlerin geliştirilmesiyle ilgilenir. Daha akıllı ajanlar, belirli bir hedefe ulaşmak için en uygun eylem yollarını seçer. Bu nedenle, bazı eylemlerin diğerlerinden daha avantajlı olduğu düşüncesi, yapay zekânın temel dayanaklarından biridir (Sezer, 2025). Bu tanımların her biri, YZ'nin insanın bilişsel yeteneklerini taklit etme çabasını vurgulanmaktadır.

1950'de Alan Turing, bir makinenin zeki davranış sergileyip sergileyemeyeceğini belirlemek için bir yöntem olan Turing Test'ini önerir (Birer, 2024). YZ kavramı, 1956'da Dartmouth Konferansı'nda John McCarthy tarafından ilk kez ortaya atıldığında, bilim dünyasında büyük bir heyecan yaratmıştır.

1960'lar ve 1970'lerde yapay Zekâ araştırmacıları, bir nesil içinde insan benzeri makineler yaratma konusunda cesur tahminlerde bulunmuştur. Örneğin, MYCIN Stanford Üniversitesi'nde geliştirilen ciddi enfeksiyonlara neden olan bakterileri tespit eden uzman bir sistemdir (Birer, 2024). YZ birçok dallara ayrılmaktadır. Çoğu zaman YZ denildiğinde ilk önce uzman sistemler akla gelmektedir. Bunun nedeni uzman sistemlerin YZ'nin diğer dallarından önce geliştirilmiş olmaya başlanmasıdır. Bu sistemler herhangi bir karşımaşık sistemin uzman bir kişinin yaptığı bir işi bilgisayarın yapabildiği bir programdır. Örneğin,

bir doktorun yaptığı gibi teşhis koyabilen ya da mühendisin bilgi birikimini doğrultusunda yaptığı analiz ve sınıflandırmalardır (Allahverdi, 2002).

1970'ler ve 1980'lerde yüksek beklentileri karşılayamamasıyla bu alanda yapılan araştırmalara olan fon ve ilgi düşer, "YZ Kışı" olarak adlandırılan bir durgunluk dönemine girilir. 1990'larda YZ, gelişmiş bilgi işlem gücü ve daha pratik uygulamalarla geri dönmüştür. IBM'in Deep Blue bilgisayarı 1997 yılında dünya satranç şampiyonu Garry Kasparov'u yenerek YZ'nin bu alandaki potansiyelini ortaya koymuştur (Birer, 2024).

2000'li yıllarda bilgi işlem gücündeki artış, büyük veri (big data) kavramının ortaya çıkışı ve yeni algoritmaların geliştirilmesiyle yapay zekâ, özellikle de makine öğrenmesi alt dalı, yeniden yükselişe geçmiştir. 2010'lu yıllar, derin öğrenme devriminin öne çıktığı bir dönem olmuştur. 2011'de IBM'in Watson sistemi, doğal dili anlama ve büyük veri işleme kapasitesini ortaya koyarak Jeopardy yarışmasını kazanmıştır. 2012'de derin öğrenme, görüntü tanıma alanında çığır açan başarılar elde etmiş ve yapay zekâyâ yönelik yeni bir heyecan dalgası yaratmıştır. 2016'da ise Google'ın AlphaGo programı, karmaşık stratejik oyunlarda da üstünlük sağlayabileceğini göstererek dünya şampiyonu bir Go oyuncusunu mağlup etmiştir (Birer, 2024).

Günümüzde YZ, yalnızca akademik bir çalışma alanı olmamakla birlikte finans, sağlık, ulaşım ve eğlence gibi pek çok sektörde kullanılan bir teknoloji haline gelmiştir. Bugün bu teknoloji sayesinde hasta verilerinin analiz edilmesi, veri modellerinin ortaya konması ve doktorlara istatistiksel çözümlemelere dayalı raporlar sunulması mümkündür. İnsanların farklı yeteneklere ve özelliklere sahip olması, yapay zekâ destekli bireyselleştirilmiş eğitim içerikleri ve yöntemlerinin geliştirilmesini de mümkün kılmaktadır. Bunun yanında, ülkelerin istihbarat kurumları yapay zekâdan yararlanarak bazı olayları daha gerçekleşmeden öngörebilmekte ve önlem alabilmektedir. Dolayısıyla yapay zekâ artık geleceğin değil, günümüzün bir gerçeği haline gelmiştir. Her ne kadar bazı riskleri barındırsa da, insan yaşamını kolaylaştırma potansiyeli nedeniyle geleceğin en önemli teknolojilerinden biri olarak değerlendirilmektedir (Kılıç, 2020).

Ayrıca OpenAI, yapay zekâ teknolojisinde mevcut doğal dil işleme modellerine kıyasla daha gelişmiş performans ve kullanıcı deneyimi sunan o3 ve o3-mini modellerini tanıttı.

2025'in ilk aylarında kullanıma sunulacak bu modeller, özellikle karmaşık problem çözme ve insan benzeri mantıksal akıl yürütme yetenekleriyle öne çıkmaktadır. O3 modeli, 'özel düşünce zinciri' yöntemi sayesinde yanıt üretmeden önce verileri analiz edip değerlendirebiliyor ve mantıksal akıl yürütme gerektiren zorlu görevlerde üstün performans sergiliyor. Daha kompakt bir versiyonu olan o3-mini ise düşük hesaplama gücüyle hızlı ve etkili sonuçlar sunarak hız ve verimlilik açısından önemli bir avantaj sağlıyor (Aydın, 2025).

Yapay zekâ, genellikle iki kategoriye ayrılır:

a) Dar (zayıf) yapay zekâ (Narrow AI): Belirli bir görevi yerine getirmek üzere tasarlanmış ve eğitilmiş YZ sistemleridir. Örneğin, yüz tanıma sistemleri, spam filtreleri veya bu tezde geliştirilen KKD tespit modeli dar yapay zekâ örnekleridir. Günümüzde kullanılan YZ uygulamalarının tamamı bu kategoridedir.

b) Genel (güçlü) yapay zekâ (General AI): İnsan gibi geniş bir yelpazedeki bilişsel görevleri anlama, öğrenme ve uygulama yeteneğine sahip, henüz teorik aşamadaki YZ sistemleridir (Url-5, 2025).

Bu çalışma, dar yapay zekâ kapsamında, spesifik bir İSG problemini çözmeye yönelik bir uygulama geliştirmeye odaklanmaktadır.

1.2.2. Makine Öğrenmesi ve Derin Öğrenme

Makine Öğrenmesi (Machine Learning - ML), yapay zekânın en hızlı gelişen alt dallarından biridir. Bu dal, makinelerin belli bir bilgiyi öğrendikten sonra o bilgiyi kullanarak tahmin çıkarımlarıyla ilgilenir (Kavasoğlu, 2023). Bilgisayarda yürütülen her bir program kendinin veya kullanıcının yaptığı yanlışlıkları bir kez gördükten ve düzelttikten sonra aynı yanlış yapmaması gerekir, yani her bir programın önceki işlemleri hafızada koruması gibi bir özelliğe sahip olması gerekir. Bu özelliğin olması ise; programın düzenlenmesini zorlaştırmaktadır. Danışarak, örneklere göre, problem çözerek, keşif yaparak, benzerliğe göre sinirsel ağlar yardımı ile genetik algoritmalarla öğrenme çeşitli öğrenme stratejileridir (Allahverdi, 2002).

Geleneksel programlamada, bir problemi çözmek için kurallar (program) ve veriler sisteme verilir ve cevaplar alınır. Makine öğrenmesinde ise, veriler ve bu verilere karşılık gelen cevaplar (etiketler) sisteme verilir ve sistemin bu ilişkiden kuralları (modeli) kendisinin öğrenmesi beklenir. Mesela, bir sistemin bir kediye tanımayı öğrenmesi için binlerce kedi fotoğrafı ve “bu kedi” etiketi gerekir.

Makine öğrenmesine ait öğrenme kavramları;


a) Öğretmenli öğrenme (Supervised Learning): Girişe ait çıkışı yani sınıflandırma durumu bilinen verilerin kullanılmasıdır. Bu tezde kullanılan nesne tespiti modeli de bir öğretmenli öğrenme uygulamasıdır.

b) Öğretmensiz öğrenme (Unsupervised Learning): Girişe ait çıkış durumu bilinmeyen, öğrenme ile verilerden sınıflandırmanın yapılmasıdır.

c) Yarı öğretmenli öğrenme (Semi-Supervised Learning): Hem öğretmenli hem öğretmensiz öğrenmeye benzerlikleri bulunan bir kavramdır. Verilerin içinde sınıflandırması bilinen ve bilinmeyen örnekler bir arada bulunur.

ç) Takviyeli öğrenme (Reinforcement Learning): Girişe ait çıkışın istem tarafından hesaplandığında doğru veya yanlış şekilde tetiklenmesine dayanan öğrenme sistemidir.

d) Yoğun öğrenme (Deep Learning): Çok katmanlı yapay sinir ağları kullanılarak lineer ve lineer olmayan dönüşümlerden öğrenmenin sağlanmasıdır (Yılmaz, 2020).



Şekil 1.1. Yapay Zekâ, makine öğrenmesi ve derin öğrenme ilişkisi

Derin öğrenme (Deep Learning - DL), belirli bir veri seti üzerinde sonuçları tahmin etmek için kullanılan ve birden çok katmandan oluşan bir makine öğrenme tekniğidir (Kavasoğlu, 2023). DL, makine öğrenmesinin alt dalı olup, insan beyninin yapısından esinlenerek çok katmanlı yapay sinir ağları (deep neural networks) kullanarak öğrenme gerçekleştirmektedir. Örneğin bir çocuğa “ bak bu kedi, tüyleri, kulakları ve bıyıkları var” dediğimizde çocuk o bilgiyi alır ve daha sonra kedi fotoğrafı gördüğünde tanır. Derin öğrenmede bu şekilde çalışır. DL modellerinde YSA, resimdeki bir kedinin tüm özelliklerini (renk, şekil, kulak, bıyık vb.) her katmanda farklı şekilde inceler. Her katman, bir sonraki katmanın bilgisini işler ve sonraki katmana aktarır. Böylece en üstteki katman "Bu bir kedi!" sonucuna ulaşır.

Bir sinir ağının her katmanı, girdi verilerini sonraki katmanlarda daha karmaşık temsillerin öğrenilmesini kolaylaştıracak şekilde dönüştürmek üzere tasarlanmıştır. Böylece katman sayısı arttıkça karmaşık örüntüleri öğrenebilmektedir. Bu da yapay sinir ağları ile oluşan derinliği oluşturur ve bu yönteme adını verir. Derin öğrenme modelleri, özellikle çok büyük ve karmaşık veri setleri (görüntü, ses, metin vb.) üzerinde çalışırken, geleneksel makine öğrenmesi algoritmalarına kıyasla çok daha yüksek başarı göstermektedir. Görüntü tanıma, doğal dil işleme ve ses tanıma gibi alanlardaki son yıllardaki devrim niteliğindeki

ilerlemelerin temelinde derin öğrenme teknolojisi bulunmaktadır (LeCun vd., 2015). Derin öğrenme, özellikle durum ve nesne tespiti teknolojisi, endüstri ve sağlık gibi farklı alanlarda kullanılmaktadır (Doğan vd., 2019). Bu tezde kullanılan YOLOv5 modeli de bir derin öğrenme mimarisidir.

1.2.3. Bilgisayarlı Görü (Computer Vision)

Bilgisayarlı görü, fiziksel etkileşim olmaksızın, optik araçlar vasıtası ile cisimleri algılama ve bulgularla bilgi toplama ve süreçleri yönetme kavramıdır. Optik tanıma ise bilginin Zekâyâya sahip bir makine yolu ile alınarak bu bilginin başka bir faaliyet için kullanılması anlamına gelmektedir (Yılmaz, 2020). İnsan gözünün gördüğünü anlaması gibi, bu teknoloji de makinelerin dijital görüntüler ya da videolar aracılığı ile verileri anlamasını, yorumlamasını, karar vermesini ve buna bağlı olarak eylemler gerçekleştirmesi hedeflenir. Bilgisayarlı görünün temel görevleri şunlar:

Görüntü Sınıflandırma: Bir görüntüye tek bir etiket atamak. Mesela, bir fotoğraftaki hayvanın kedi mi köpek mi olduğunu belirlemek.

Nesne Tespiti: Bir görüntüdeki nesnelerin yerlerini sınırlayıcı kutular (bounding boxes) ile belirlemek ve her bir nesneyi sınıflandırmak. Örneğin, bir inşaat sahasında kask takan ve takmayan çalışanları tespit etmek. Bu tez çalışmasının temel görevi nesne tespittir.

Görüntü Bölütleme: Bir görüntüyü piksel seviyesinde analiz ederek, her bir pikseli ait olduğu nesneye veya bölgeye atamak. Bu, nesne tespitinden daha detaylı bir analiz sunar.

Yüz Tanıma: Görüntülerdeki insan yüzlerini tespit etme ve kimliklendirme.

Optik Karakter Tanıma (OCR): Görüntüdeki metni okuyup dijital metne çevirmek.

İnşaat işçileri eğitim almalarına rağmen çalışma alanlarındaki tehlikeleri çoğu zaman görmekte başarısızdırlar. Bilgisayarlı görü, iş sahalarındaki görsel verileri (kamera görüntüleri) analiz ederek İSG alanında gerçek zamanlı tehlike tespiti konusunda güvenlik denetimlerini otomatikleştirmek için güçlü bir potansiyel sunmaktadır. İnşaat

işyerlerindeki ortamındaki çalışanların sürekli izlenerek tehlikelerin tespiti, KKD kullanımlarının izlenmesi bilgisayarlı görü teknolojileri ile yaşanabilecek iş kazalarına erken müdahaleyi mümkün kılmaktadır (Jeelani vd., 2021). İnşaat güvenliği yönetimi bilgi yoğun bir iştir; örneğin, güvenlik yöneticileri bir şantiye güvenliği denetimi sırasında güvenlik yönetmeliklerine ve önceki bilgilerine güvenirler. Video izleme sistemleri ve derin öğrenme algoritmalarının gelişmesiyle birlikte, görüntülerden güvenlikle ilgili bilgileri çıkarmak için bilgisayarlı görme kullanılarak tehlikeleri ve bunlara karşılık gelen azaltmaları anlamsal olarak akıl yürüterek güvenliğin yönetimini kolaylaştırmak için bilgisayarlı görme ve ontoloji tekniklerini birleştiren kavramsal bir çerçeve sunulmuştur (Wu vd., 2021). Ayrıca, derin öğrenme tabanlı bilgisayarlı görü sistemleri, gerçek zamanlı veri analizi sayesinde iş kazalarının önlenmesinde proaktif bir rol üstlenmekte ve “sıfır kaza” vizyonuna katkı sağlamaktadır (Fang vd., 2020). Bu teknolojiler, insan gözlemcilerin kaçırabileceği ayrıntıları yakalayarak ve sürekli bir izleme sağlayarak İSG'de proaktif bir devrim yaratmaktadır.

2. KAYNAK ÖZETLERİ

Bu bölümde, tezin teorik temelini oluşturan konuyla ilgili mevcut literatür taraması yapılmış ve aşağıda özetlenmiştir.

Shehadeh ve Alshboul (2025), inşaat projelerinde İSG'yi iyileştirmek için makine öğrenmesini uygulamışlardır. Kaza ve riskleri tahmin etmek için forest, gradient, random, boosting ve LightGBM gibi topluluk makine öğrenmesi algoritmalarını karşılaştırmıştır. Gerçek dünyadaki inşaat sahalarından elde edilen büyük bir veri seti eğitim ve test için kullanılmıştır. Analiz sonuçlarına göre LightGBM modelinin risk tahmininde en yüksek doğruluk ve performansı gösterdiğini ortaya konmuştur.

Şengöz ve Bozkurt (2025), iş kazalarının ve bu kazalardan sonra yapılması gereken uygulamaların neler olduğu, farklı sektörlerdeki iş kazalarına karşı hangi önlemlerin alınması gerektiği, YZ ve uzman sistem teknolojilerinin iş kazalarını önlemedeki rolünü incelemiş ve bu teknolojilerin İSG'ye olan katkılarını tartışmışlardır. Yapay zekâ teknolojileri ve uzman sistem uygulamaları sayesinde çalışanların kişisel hatalarının azaltılabileceği ve zaman tasarrufunun sağlanabileceği belirtilmiştir. Çalışmada, iş kazalarının %80'inin çalışanlardan kaynaklandığı belirtilmiştir. Farklı sektörlerde (inşaat, maden, petro-kimya vb.) YZ uygulamalarının başarılı örnekleri sunulmuştur.

Ozobu ve arkadaşları (2025), inceleme için toplam 144 çalışma seçilmiştir. İnşaat, petrol ve gaz endüstrilerinden simülasyon ve vaka çalışmaları kullanılmıştır. Sistemin temel bileşenleri arasında, çalışanların hayati belirtilerini ve çevresel parametreleri izlemek için giyilebilir IoT sensörleri, büyük veri setlerini işlemek için YZ güdümlü analizler ve fiziksel tehlikeleri belirlemek için bilgisayarlı görü (computer vision) yer almaktadır. Ön simülasyonlar ve vaka çalışmaları, sistemin işyeri yaralanmalarını önemli ölçüde azaltma ve tehlike müdahale sürelerini iyileştirme potansiyeline işaret etmiştir. Bu çalışmada, örneğin, büyük ölçekli bir inşaat projesinde düşmeye bağlı olaylar %40 oranında azalırken, bir rafineride güvenlik olaylarında %30 oranında bir azalma rapor edilmiştir.

Jetha ve arkadaşları (2025), 2018-2024 yılları arasında İSG'ye yönelik YZ uygulamaları konusunda yayımlanmış, hakemli dergilerdeki ilgili 1255 makale PRISMA(Sistematik İncelemeler ve Meta-Analizler için Tercih Edilen Raporlama Maddeleri) adı verilen bir metodoloji kullanılarak incelenmiştir. Yapılan bu detaylı inceleme sonucunda sadece ikisi, YZ'nin iş kazaları üzerindeki etkisini doğrudan ölçen nicel çalışma kriterleri karşılamıştır. Bu iki çalışmadan biri düşük kalitede, diğeri ise orta kalitede olarak değerlendirilmiştir. Orta kalitedeki çalışmada, YZ destekli bir sohbet robotunun (chatbot) çalışanların kas-iskelet sistemi semptomlarını hafiflettiği tespit edilmiştir. Bu da, gelecekteki araştırmaların, YZ araçlarının İSG üzerindeki etkinliğini belirleyen tasarım ve uygulama faktörlerini daha derinlemesine incelemesi gerektiğini vurgulamaktadır.

Yazdi (2024) çalışmasında, iş yerinde yapay zekânın, büyük verinin ve nesnelerin interneti (IoT) gibi yeni teknolojilerin iş yerindeki güvenlik yönetimini nasıl değiştirdiğini vurgulanmıştır. Pproaktif İSG yönetimin İSG sonuçlarını iyileştirmedeki önemi, YZ teknolojilerinin risk değerlendirmesini ve olay müdahalesini nasıl yeniden şekillendirdiği açıklanmıştır. Bu teknolojilerin uygulanmasındaki etik hususlara ve zorluklara da değinilmiştir. Ayrıca, bu teknolojilerin uygulanmasındaki zorluklara değinilerek nasıl aşılacağı tartışılmıştır.

Park ve Kang (2024) çalışmalarında, yapay Zekânın ve akıllı teknolojilerin iş güvenliğini nasıl iyileştirdiğini incelemek için, bu konudaki bilimsel makalelerin yer aldığı 187 çalışmayı gözden geçirmişler ve bunların arasından 65 tanesini detaylı olarak analiz etmişlerdir. İnceleme, inşaat, endüstriyel güvenlik, afet ve kamu güvenliği gibi sekiz farklı sektöre odaklanmıştır. Böylece iş güvenliğine olan yaklaşımın "reaktif"ten "proaktif"e doğru değiştiği ortaya koyulmuştur. Yapay Zekâ destekli çözümlerin (örneğin, tahmine dayalı analizler, IoT sensörleri) kazaları önceden tahmin ederek oranlarını düşürdüğü tespit edilmiştir. Bunun yanında veri güvenliği ve etik konuların YZ teknolojilerinin benimsenmesinde kritik zorluklar oldukları vurgulanmıştır.

Jin ve arkadaşları (2024) çalışmasında, işçilerin emniyet kaskını yanlış takma sorununa çözüm bulmak amacıyla iyileştirilmiş YOLOv5n'e dayalı, "YOLO-ESCA" adlı standart bir kask takma davranış tespit modeli önermişlerdir. Model, farklı ortamları (yoğun hedefler, uzun mesafe hedefleri, yetersiz aydınlatma) içeren, araştırmacılar tarafından oluşturulmuş

4400 adet görüntüden oluşan bir veri seti kullanılarak eğitilmiştir. Bu veri seti, "standart kask takma" durumunu hedefleyen ilk veri setidir. İyileştirilmiş YOLOv5n modelinin, şantiyelerdeki kask takma davranışının standart olup olmadığını gerçek zamanlı ve doğru bir şekilde tespit etmede etkili bir araç olduğu sonucuna varılmıştır.

Lee ve arkadaşları (2023) çalışmasında, tünel inşaatında çalışan işçilerin nerede olduğunu veya ne tür risklerle karşı karşıya olduğunu takip etmek için güvenliğini artırmak için akıllı teknolojiler önermiştir. Bunlar; akıllı baretler, tünel içi tarayıcılar, sıcaklık, basınç ve hava kalitesini izleyen çevresel sensörler ve verileri toplayıp analiz eden mobil cihazlardan oluşmaktadır. Güney Kore'de gerçek bir tünel şantiyesinde yapılan denemede, bu sistemin ne kadar etkili olduğu kanıtlanmıştır. Aylık inşaat maliyetlerinde %37, yıllık inşaat maliyetlerinde ise %77 gibi çok büyük bir azalma sağlanmıştır. Böylece, sadece güvenliği artırmakla kalmayıp, aynı zamanda maliyetleri de önemli ölçüde düşürdüğü gösterilmiştir.

Aslan ve Yağımlı (2023), KKD kullanımının zorunlu olduğu alanlara yetkisiz giriş yapan çalışanları tespit etmek için bir yapay Zekâ modeli geliştirmiştir. Derin öğrenme adı verilen YOLOv5 mimarisiyle bu model eğitilmiştir. Model, yüzlerce fotoğrafa bakarak, hangi çalışanın KKD kullandığını, hangisinin KKD kullanmadığını, kimin yetkili olduğu, kimin yetkisiz olduğu öğretilmiş ve yapılan test sonucunda modelin yüzde 90'ın üzerinde bir doğrulukla riskleri tespit ettiği görülmüştür. Özetle, bu çalışma, yapay Zekânın, iş güvenliği kurallarını ihlal eden durumları otomatik olarak tespit ederek, iş kazalarını önlemede güçlü bir araç olabileceğini gösterilmiştir.

Dhole, Gunjal ve Deshmukh (2023), gerçek zamanlı kask tespiti için nesne algılama algoritmaları olan YOLOv5 ve YOLOv7 modellerini karşılaştırılmışlardır. Modeller, çeşitli endüstriyel ortamlardaki çalışanların kask takma durumlarını içeren bir veri seti üzerinde eğitilmiş ve test edilmiştir. Çalışmanın amacı, hangi modelin daha yüksek doğruluk ve performansa sahip olduğunu belirlemektir. Yapılan karşılaştırmalar sonucunda YOLOv7 modelinin, kask tespiti görevinde YOLOv5'ten daha yüksek doğruluk ve daha iyi performans gösterdiği bulunmuştur.

Zhang ve arkadaşları (2022), geleneksel güvenlik denetimlerinin yetersiz kaldığı durumlarda, şantiyelerdeki emniyet kaskı takma durumunu tespit etmek için YOLOv5s

algoritması kullanmışlardır. "Kask takmama", "kask takma", "sadece şapka takma", "kaskı olup takmama", "kaskı doğru takma" ve "çene kayışını takmadan kask takma" gibi altı farklı durumu içeren bir veri seti oluşturulmuştur. Bu veri seti, modelin daha iyi bir şekilde eğitilmesini sağlamıştır. İyileştirilmiş algoritmanın orijinal YOLOv5s algoritmasından daha doğru sonuçlar elde ettiği görülmüştür. Bu algoritma, bu tür akıllı programların, insan gözünün kaçırabileceği güvenlik hatalarını bile tespit ederek inşaat sahalarını daha güvenli hale getirme potansiyeline sahip olduğunu göstermiştir.

Li ve arkadaşları (2022), inşaat sahalarında sıkça meydana gelen yüksekten düşme (FFH) ve nesne çarpması (OS) kazalarını önlemek için derin öğrenme tabanlı bir denetim yöntemi önermiştir. Gevşek kask ve emniyet kemerinin kancasının takılmaması gibi iki kazaya yol açabilecek davranış incelenmiştir. İlk olarak, YOLOv5'e dayalı olarak kask ve kanca için bir tespit modeli oluşturulmuştur. Nesne tespit modeli ve Openpose algoritması, üç güvensiz ve bir güvenli davranışı içeren 1200 video tanımak için kullanılmıştır. Bu videolardan 600'ünün verisi tek boyutlu konvolüsyonel sinir ağı (ID-CNN) modelini eğitmek için kullanılmış, diğer 600 video verisi ise modeli test etmek için kullanılmıştır. Önerilen derin öğrenme tabanlı denetim yönteminin, inşaat sahalarındaki KKD kullanımını etkili bir şekilde denetleyerek, güvenlik yönetiminin verimliliğini artırabileceği sonucuna varılmıştır.

Aksoy (2022) çalışmasında, YOLOv5 mimarisi kullanılmıştır. Model, KKD kullanımının zorunlu olduğu bir alanda, yetkili ve yetkisiz çalışanların KKD kullanıp kullanmama davranışlarını içeren özel olarak hazırlanmış bir veri kümesiyle eğitilmiştir. Derin öğrenme tabanlı risk analizi yönteminin yüksek doğruluk oranı (%96 F1 skoru), geleneksel risk değerlendirme yöntemlerine göre çok daha güçlü ve etkili bir seçenek olabileceğini gösterilmiştir.

Cheng ve arkadaşları (2022), şantiyede işçilerin güvenliğini izlemek için akıllı bir sistem geliştirmişler. Bu sistem, iki farklı yapay Zekâ teknolojisi bu sistemde bir araya getirilmiştir. Bunlar; işçilerin yeniden kimlik tespiti (ReID) ve KKD sınıflandırmasıdır. Bir işçinin gerekli koruyucu ekipmanı takmadığı her anı otomatik olarak kaydeden bir sistem iki program birleştirilerek oluşturulmuştur. Yapılan testler, geleneksel yöntemlere kıyasla: İşçileri tanıma doğruluğunu %4, koruyucu ekipman kontrolü doğruluğunu ise %13

oranında artırdığını göstermiştir. Ayrıca bu yöntem, çalışanların hareketlerinin ve KKD durumlarının daha kapsamlı analiz edilmesini sağlamaktadır.

Aylak, Oral ve Yazıcı (2021) çalışmalarında, YZ ve makine öğrenmesi teknolojilerin lojistik süreçlerindeki yerini ve etkinliğini göstermek amacıyla kapsamlı bir literatür taraması yapmışlardır. Araştırma sonuçlarına dair bulgular değerlendirilmiştir. Değerlendirme sonuçlarında bu teknolojilerin lojistik süreçlerini ne kadar etkili hale getirdiğini göstermektedir. Ayrıca, sürücüsüz araçlar, depolama ve raf robotları gibi uygulamaların lojistiğe entegrasyonu ele alınmıştır. Bu teknolojiler sayesinde, depolama, paketleme, sevkiyat ve rotalama gibi süreçler daha hızlı ve daha düzenli hale geldiği tespit edilmiştir. Böylece, yapay Zekâ teknolojilerinin lojistik sektörünü daha hızlı, daha akıllı ve daha düşük maliyetli hale getirdiği vurgulanmıştır.

Zhou ve diğerleri (2021), inşaat sahalarında ve diğer tehlikeli ortamlarda çalışanların baretlerini doğru bir şekilde takıp takmadığını kontrol etmek için yapay Zekâ kullanan bir sistem geliştirmişler. Görüntüleri hızlı ve verimli bir şekilde analiz edebilen bir yapay Zekâ YOLOv5 kullanmıştır. Farklı açılardan, çeşitli ışık koşullarında ve arka planlarda çekilmiş "kask takan" ve "kask takmayan" insanların fotoğraflarından oluşan özel bir veri seti oluşturulmuştur. Yapılan eğitim sonucunda, model, test veri seti üzerinde %98,4 gibi yüksek bir mAP (ortalama hassasiyet) değerine ulaşmıştır. Ayrıca, modelin tespit hızı da oldukça yüksektir, yani canlı bir video akışını bile anında analiz edebilmektedir. Bu bulgular, şantiyelerde ve diğer endüstriyel alanlarda güvenlik ihlallerini anında tespit ederek kazaları önlemede etkili bir araç olarak kullanılabileceğini kanıtlamaktadır.

Li ve arkadaşları (2020), kafa yararlanmalarının 2015'ten 2018'e kadar yayınlanan kaza istatistiklerine göre, kaydedilen 78 inşaat kazasından 53'ü, işçilerin baretlerini doğru şekilde takmamasından kaynaklandığı görülmüştür. Geleneksel güvenlik denetimlerinin (yani, bir görevlinin şantiyeyi gezerek kontrol etmesi gibi) artık bu karmaşık ortam için yeterli olmadığı, insan gözünün her şeyi aynı anda kontrol edemediği durumlarda, kaza yaşanma olasılığı artmaktadır. İş yerindeki video izleme sistemlerinden manuel olarak yakalanan fotoğraflar ve web tarama teknolojisi kullanılarak internetten elde edilen açık görüntülerden olmak üzere iki kaynaktan toplanan 3261 güvenlik kaskı görüntüsü içeren bir veri kümesi oluşturulmuştur. Bu çalışmada Evrişimli sinir ağlarına dayanan SSD-

MobileNet algoritması modeli eğitmek için kullanılmıştır. Elde edilen verilerle eğitilen model, inşaat sahasında çalışanların baretlerini takıp takmadığını doğru bir şekilde tespit edebileceği gösterilmiştir. Bu çalışma, yapay Zekânın geleneksel denetimlere göre çok daha etkili ve sürekli bir gözetim sağlayarak, inşaat çalışanlarının güvenliğini artırmak için yeni ve güçlü bir yol sunduğunu gösterilmektedir.



3. MATERİYAL VE YÖNTEM

Bu bölümde, "*Yapay Zekâ Destekli İş Güvenliği Modellemesi*" başlıklı tez çalışmasının pratik uygulamasını oluşturan adımlar ayrıntılı bir şekilde ele alınmıştır. Çalışma, veri setinin hazırlanmasından modelin eğitime ve performans değerlendirmesine kadar tüm aşamaları kapsamaktadır. Kullanılan yapay Zekâ modeli (YOLOv5), veri toplama süreci, eğitim aşamaları ve değerlendirme yöntemleri gibi teknik detaylar, çalışmanın tekrarlanabilirliğini sağlamak amacıyla detaylı bir şekilde sunulmuştur.

3.1. Araştırmanın Modeli

Çalışmada, İSG alanında KKD kullanımını denetlemek amacıyla derin öğrenmeye dayalı bir bilgisayarlı görü modeli geliştirilmiştir. Çalışma, uygulamalı ve nicel araştırma modelini temel almıştır. Araştırma süreci, sahadaki güvensiz durumları ve özellikle KKD kullanım ihlallerini sürekli ve etkili bir şekilde denetleme zorluklarının belirlenmesiyle başlamıştır. Bu doğrultuda, "insan", "kask", "yelek" ve "eldiven" sınıflarını içeren bir veri seti oluşturulmuştur. Modelin eğitimi için gerekli görsel veriler toplanmış, etiketlenmiş ve işlenmiştir.

Probleme uygun ve gerçek zamanlı performansı yüksek bir derin öğrenme modeli olarak YOLOv5 tercih edilmiştir. Seçilen model, hazırlanan veri setiyle eğitilmiş ve performansı optimize edilmiştir. Performans ölçümü için eğitilen modelin değerlendirilmesi sırasında, görsel incelemeler gibi nitel analizler ve mAP, Precision (P), Recall (R) gibi nicel metrikler kullanılmıştır. Son olarak, elde edilen bulgular literatür ve pratik uygulamalar bağlamında tartışılarak yapay Zekânın İSG alanındaki potansiyelinin ortaya konulması amaçlanmıştır.

3.2. Veri Setinin Oluşturulması ve Hazırlanması

Veri setinin hazırlanması denetimli makine öğrenmesinin zaman alıcı aşamalarından biridir. Bir makine öğrenmesi projesinin başarısı, veri setinin kalitesine ve çeşitliliğine bağlıdır. “Çöp girerse, çöp çıkar” (Garbage In, Garbage Out-GIGO) ilkesi, bu çalışmada veri hazırlama sürecine neden özel bir önem verildiğini açıklamaktadır.

Eğer bir sisteme (bilgisayar programı, algoritma, makine öğrenmesi modeli vb.) ne kadar düşük kaliteli, hatalı, eksik veya anlamsız veri (yani çöp veri) girerseniz o sistemden alacağınız sonuç veya çıktı da o kadar düşük kaliteli, hatalı ve anlamsız (yani çöp) olacaktır.

3.2.1. Veri Toplama

Modelin farklı ışık koşulları, arka planlar, kamera açıları ve insan pozisyonlarında yüksek doğrulukla çalışabilmesi için çeşitli ve dengeli bir veri seti oluşturulmuştur. Bu amaçla çeşitli kaynaklardan yararlanılmıştır.



Şekil 3.1. Veri seti için görüntü işleme adımları

İş güvenliği ve KKD tespiti üzerine Roboflow ve Kaggle gibi platformlarda bulunan daha önce oluşturulmuş halka açık veri setleri incelenerek çalışmanın amacına uygun görseller seçilmiştir (Url-6, 2023; Url-7, 2023). Ayrıca, KKD kullanan çalışanların atölye, inşaat ve fabrikalar ortamlarında çekilmiş yüksek çözünürlüklü stok fotoğraflar kullanılmıştır. Bunun yanı sıra, Google Images gibi arama motorları kullanılarak "inşaat işçisi", "baretli

“çalışan”, “iş güvenliği yeleği”, “iş eldiveni” gibi anahtar kelimelerle ilgili görseller toplanmıştır. Toplamda 2512 adet görüntüden oluşan bir ham veri seti elde edilmiştir. Şekil 3.1’de bu görüntülerin sisteme yüklenme adımları göstermiş olup, elde edilen bu görüntüler modelin eğitileceği platforma yüklenmiştir.

3.2.2. Veri Etiketleme (Annotation)


Roboflow, bilgisayarla görme alanında kullanılan veri setlerinin hazırlanması amacıyla “Roboflow Annotate” adlı yapay zekâ destekli bir etiketleme aracı sunmaktadır. Bu araç, “yapay zekâ destekli etiketleme araçlarıyla verilerin hızlı bir şekilde işaretlenmesini sağlayan bir sistem” olarak tanımlanmaktadır. Söz konusu platform, bounding box, poligon ve benzeri farklı etiketleme yöntemlerini desteklemekte, bu sayede kullanıcıların görüntüleri hızlı, tutarlı ve standartlara uygun biçimde etiketlemesine olanak tanımaktadır. Ayrıca yapay zekâ tabanlı destekleyici özellikler, etiketleme sürecini hızlandırmakta ve veri hazırlama maliyetlerini azaltmaktadır (Roboflow, 2025).

Etiketleme işlemi manuel yapılan bir işlemdir. Toplanan ham görüntülerin, denetimli öğrenme modelinin anlayabileceği bir formata dönüştürülmesi gerekmektedir. Bu işlem “etiketleme” veya “annotation” olarak adlandırılır. Etiketleme, tespit edilmek istenen her bir nesnenin etrafına sınırlayıcı kutular (bounding boxes) çizilerek görsel veri ile aynı ismi taşıyan “*.txt” uzantılı bir dosyada koordinatlarının ve sınıf bilgilerinin kaydedilmesi işlemidir (Aslan & Yağımlı, 2023).

	00004_jpg.rf.b8c091ca500b908b98a92a7aa209...	31.07.2023 13:31	JPG Dosyası	57 KB
	00004_jpg.rf.b8c091ca500b908b98a92a7aa209...	8.12.2023 19:19	Metin Belgesi	1 KB
	10_JPG_jpg.rf.c8c30ad6d56b4e103a27bc1504c...	31.07.2023 13:31	JPG Dosyası	70 KB
	10_JPG_jpg.rf.c8c30ad6d56b4e103a27bc1504c...	8.12.2023 19:19	Metin Belgesi	1 KB
	00011_jpg.rf.82e3a609f4103246a9ab6fb5b41f...	31.07.2023 13:31	JPG Dosyası	53 KB
	00011_jpg.rf.82e3a609f4103246a9ab6fb5b41f...	8.12.2023 19:19	Metin Belgesi	1 KB
	00014_jpg.rf.3d33c7b3f3de8be20a1fc9b235a6...	31.07.2023 13:31	JPG Dosyası	56 KB
	00014_jpg.rf.3d33c7b3f3de8be20a1fc9b235a6...	8.12.2023 19:19	Metin Belgesi	1 KB

Şekil 3.2. Veri etiketleme dosyaları

Bu çalışmada, dört sınıf belirlenmiştir: “insan”, “kask”, “yelek” ve “eldiven”




Şekil 3.3. Veri etiketleme

Bu çalışmada kullanılan veri setindeki görüntülerin etiketleme işlemleri makesense.ai platformu aracılığıyla gerçekleştirilmiştir. Makesense.ai, internet üzerinden çalışan ve ücretsiz olarak kullanılabilen bir fotoğraf etiketleme aracıdır. Herhangi bir program indirmeden, yalnızca tarayıcı üzerinden görüntülerin işaretlenmesine olanak tanır. Araştırmacılar veya uygulayıcılar, bu sistem sayesinde fotoğraflar üzerinde nesneleri kutucuklarla (bounding box), çizgilerle (poligon) ya da noktalarla işaretleyebilirler. Etiketlenen bu veriler daha sonra makine öğrenmesi ve yapay zekâ modellerini eğitmek için kullanılabilir.

Makesense.ai'nin en önemli özelliklerinden biri, verilerin doğrudan kullanıcının bilgisayarında işlenmesi ve dışarıya gönderilmemesidir; bu da gizlilik açısından güvenli bir ortam sunar. Ayrıca farklı dosya formatlarına (örneğin YOLO, Pascal VOC, CSV) uygun çıktı vermesi, bu aracı çeşitli yapay zekâ uygulamalarında kullanılabilir hale getirir. Ek olarak, bazı yapay zekâ destekli özellikleri sayesinde etiketleme sürecini hızlandırabilir ve kullanıcının iş yükünü azaltabilir (Makesense.ai, 2025).

Etiketleme işlemi, Roboflow platformu gibi çevrimiçi bir etiketleme aracı kullanılarak gerçekleştirilmiştir. Her bir görüntü dikkatlice incelenmiş, tüm hedef nesneler yukarıdaki sınıflara göre etiketlenmiş ve tutarlılık sağlamak için etiketleme süreci belirli yönergeler doğrultusunda yürütülmüştür. Aşağıda Şekil 3.4’te etiketleme arayüzünü ve etiketlenmiş görüntü sayıları gösterilmektedir.

Sınıf sayısı arttığında annotatörlerin daha fazla hata yaptığını ve bu durumun veri kalitesini düşürerek modellerin doğruluk ve güvenilirliğini olumsuz etkileyebileceğini vurgulamaktadır (Everingham et al., 2010). Etiketleme işlemi, modelin neyi öğrenmesi gerektiğini açısında kritik önem taşımaktadır. GIGO prensibine göre etiketlemede yapılacak küçük hatalar bile modelin doğruluk ve performansını olumsuz etkileyebilmektedir (Vădineanu et al., 2022).



Şekil 3.4. Veri setinin yükleme arayüzü


3.2.3. Veri Setinin Bölünmesi ve Ön İşleme

2512 görüntüden oluşan veri seti, modelin eğitimi ve performansının değerlendirilmesi amacıyla üç alt bölüme ayrılmıştır. Bunlar;

Eğitim seti (train set): Bu set, modelin öğrenme işlemini gerçekleştirdiği ilk kısımdır. Veri setinin en büyük bölümünü oluşturur. Model, bu setteki örnekleri tekrar tekrar inceler, her seferinde yaptığı tahmini gerçek cevapla karşılaştırır ve arasındaki hata payını ölçer, geri bildirim ile daha sonra bu hata payını azaltana kadar bu süreç devam eder. Örneğin, bir öğrenci gibi tüm konuları burada öğrenir, tıpkı bir kitaptaki örnek soruları çözerek konuyu öğrenmesi gibi. Eğitim seti toplam 1756 görüntüden (%70) oluşmaktadır.

Doğrulama seti (validation set): Bu set, modelin her bir eğitim turu (epoch) sonundaki performansını kontrol etmek için kullanılır. Bu setteki veriler modelin eğitimine dahil edilmez; yalnızca performansı ölçmek ve aşırı öğrenme (overfitting-ezber yapma) yapıp yapmadığını belirlemek amacıyla değerlendirilir. Bu set, toplam 505 görüntüden (%20) oluşmaktadır.

Test seti (test set): Son olarak, modelin nihai performansını ölçmek için test seti (test set) oluşturulmuştur. Modelin daha önce hiç görmediği görüntülerden oluşur ve gerçek dünya performansının en iyi göstergesidir. Eğitim bittikten sonra sadece bir kez bu set üzerinde çalıştırılır ve nihai başarı oranı elde edilir. Toplam 251 görüntü (%10) bu amaçla ayrılmıştır. Çalışmada yer alan veri seti dağılımı Şekil 3.5'te yer almaktadır.



Şekil 3.5. Veri seti dağılımı

Veri setine, modelin daha iyi çalışması için temel ön işleme adımları uygulanmıştır: tüm görüntüler 640x640 piksel boyutuna dönüştürülmüş, otomatik yönlendirme (auto-orient) ile hizalanmış ve tüm formatlar tek bir format haline getirilmiştir. Veri artırma (augmentation) teknikleri (döndürme, kırpmaya, renk değişikliği vb.) bu aşamada uygulanmamış olup bu teknikler, gelecekte modelin daha farklı durumlara uyum sağlayabilmesi ve daha sağlam sonuçlar üretmesi için eklenebilecek yöntemler olarak değerlendirilmektedir.


3.3. Kullanılan Yapay Zekâ Modeli: YOLOv5

Yolo'nun nesne tespiti için birçok versiyonu bulunmakla birlikte hızlı ve yüksek doğrulukla çalışabilen YOLO (You Only Look Once) ailesinden YOLOv5 algoritması kullanılmıştır. (Neftali vd., 2022).

3.3.1. YOLO Mimarisine Genel Bakış

YOLO, 2016 yılında Joseph Redmon ve arkadaşları tarafından geliştirilen, nesne tespitinde önemli bir dönüm noktası olan bir algoritmadır (Url-8, 2025).

YOLO'nun yöntemi, eski yöntemlere göre tek aşamalı yaklaşımdır. Görüntüye sadece bir kez bakarak, tüm nesnelerin sınırlayıcı kutularını (bounding boxes) ve sınıf olasılıklarını tek bir sinir ağı geçişinde tahmin eder. Bu tek aşamalı yaklaşım, YOLO'yu son derece hızlı kılar. YOLO'nun çalışma prensibi şu şekildedir: İlk olarak, görüntü $S \times S$ boyutlu bir ızgaraya (grid) bölünür. Bir nesnenin merkez noktası hangi ızgara hücresine düşerse, o hücre o nesneyi tespit etmekten sorumlu olur. Her ızgara hücresi, B adet sınırlayıcı kutu ve bu kutular için güven skorları (confidence scores) tahmin eder. Güven skoru, kutunun bir nesnenin var olup olmadığını ve ne kadar isabetli olduğunu yansıtır. Ayrıca, her hücre C adet sınıf için koşullu olasılıkları (conditional class probabilities) tahmin eder. Eğer kutuda bir nesne varsa, bu nesnenin "kedi mi, araba mı, insan mı" olduğuna dair ihtimalleri sıralar. Bu bilgiler birleştirilerek görüntüdeki tüm nesnelerin yerleri ve sınıfları belirlenir (Url-9, 2025). Şekil 3.6, YOLO algoritmasının genel çalışma prensibini göstermektedir.



Şekil 3.6. YOLO ile çalışanların KKD uyumluluğunun tespiti

YOLOv5, bir yapay Zekâ programıdır. 2020 yılında Ultralytics firması tarafından geliştirilmiş ve PyTorch Kütüphanesi üzerine inşa edilmiştir. Kullanım çok kolay olması ve yüksek performansı dolayısıyla kısa sürede en çok tercih edilen popüler nesne tespiti modellerinden biri oldu.

YOLOv5, birçok temel avantajlarının başında hız ve esneklik gelmektedir. Farklı boyutlardaki (nano, small, medium, large, extra-large) modelleri sayesinde, donanım kapasitesine göre hız ve doğruluk arasında optimum denge kurulabilmektedir. Özellikle YOLOv5s gibi küçük modeller, bir saniyede yüzlerce fotoğraf veya kareyi (FPS) işleyebildiği için canlı video akışları için idealdir.

Bu modelin diğerk bir avantajı ise ne kadar doğru çalıştığıdır. MS COCO veri setinde yapılan testlerde YOLOv5, kendi sınıfındaki diğerk tek aşamalı nesne tespit algoritmalarına göre nesneleri ne kadar doğru tahmin ettiğini gösteren puanı (mAP) , kendi benzerleri arasında oldukça yüksektir (Jocher et al., 2020). Bu da onun güvenilir olduğunu gösterir.

Bu çalışmada, hız ve doğruluk arasında iyi bir denge sunan standart bir YOLOv5 versiyonu kullanılmıştır. Model, özellik çıkarımı (backbone), özellik birleştirme (neck) ve tespit (head) olmak üzere üç ana bölümden oluşmaktadır. Bu yapı, farklı ölçeklerdeki nesnelerin etkin bir şekilde tespit edilmesini sağlamaktadır.

3.4. Modelin Eğitilmesi

Modelin eğitimi, hazırlanan veri setini kullanarak YOLOv5'in ağırlıklarını KKD tespiti görevine optimize etme sürecidir. Eğitime başlamadan önce, görsel verilerin hepsinin aynı boyutta olması gerekir. Bu yüzden, bütün görsel veriler belli bir boyuta getirilerek sınıflandırılmıştır.

3.4.1. Eğitim Ortamı ve Parametreler

Eğitim süreci, yüksek işlem gücü gerektiren bir görevdir ve bu nedenle Grafik İşlem Birimi (GPU) üzerinde gerçekleştirilmiştir. Bu tez çalışmasında, Google Colab Pro ortamında NVIDIA Tesla T4 GPU kullanılmıştır.

Eğitim sürecinde, modelin performansını optimize etmek için bazı temel hiper-parametreler ayarlanmıştır. Burada bahsedilen hiper-parametreler doğru ölçü değeridir. İlk olarak, epoch sayısı 100 olarak belirlenmiştir. Bu da, eğitim setinin model tarafından 100 defa inceleneceği ve her incelemeden sonra kendini geliştireceği anlamına gelir. Her bir eğitim adımında modele aynı anda verilecek görüntü sayısını belirten batch büyüklüğü ise kullanılan GPU'nun bellek kapasitesine göre ayarlanmıştır. Batch büyüklüğü ise, her seferinde modele aynı anda verilecek görüntü sayısını belirlemektedir. Bu sayı, kullanılan bilgisayarın GPU belleğinin kapasitesine göre ayarlanır. Çünkü bu işlemci, aynı anda ne kadar veriyi işleyebileceğini belirler. YOLO için standart bir ölçü boyutu yoktur.

360x360'tan 1024x1024'a kadar çeşitli piksel büyüklüklerinde eğitim dosyaları hazırlanabilir. Eğitim piksel boyutunun daha büyük olması modelin daha doğru sonuçlar çıkarmasına, daha küçük olması da daha hızlı çıkarım yapmasını sağlar. Bu çalışmada risk olduğu an tespit edileceğinden çıkarım hızı oldukça önemlidir ve boyut olarak 640x640 piksel büyüklüğü seçilmiştir. Şekil 3.3'te normalizasyonu tamamlanmış veri setinden örnekler yer almaktadır (Aslan & Yağımlı, 2023).

Modelin eğitimi, COCO veri setinde önceden eğitilmiş (pre-trained) ağırlıklar kullanılarak başlatılmıştır. Artık onu sıfırdan eğitmek yerine nesnelerin genel şekilleri, renklerini ve kenarlıklarını ayırt etme yeteneği gibi temel bilgileri kullanarak iş yerindeki KKD'leri tanımayı öğretiyoruz. Bu yöntem, transfer öğrenmesi (transfer learning) olarak adlandırılır ve modelin COCO veri setinden elde ettiği bilgileri kullanarak KKD tespiti gibi yeni bir göreve daha hızlı ve etkili bir şekilde adapte olmasını sağlamıştır. COCO veri setinde ise her görüntü birden fazla nesne içerir ve her nesne için ayrıntılı etiketlemeler sağlanır (Yıldız, 2023). Örneğin İspanyolca bilen birine İngilizceyi öğretmek, gramer yapıları aynı olduğu için çok daha hızlı ve kolay öğretilir.

3.4.2. Eğitim Sürecinin İzlenmesi

Modelin performansı eğitim süreci boyunca sürekli olarak izlenmiştir. Her epoch sonunda, modelin hem eğitim setindeki hem de doğrulama setindeki performansı çeşitli nicel metriklerle ölçülmüştür. EK-A'da eğitim sürecinin örnek konsol çıktısını göstermektedir.

Eğitim sürecini değerlendirmek için kullanılan önemli metrikler şunlardır: box_loss sınırlayıcı kutunun konum doğruluğuyla, obj_loss bir kutunun nesne içerip içermediğiyle ve cls_loss sınıflandırma doğruluğuyla ilgili kayıp değerlerini ifade eder. Performans metrikleri arasında ise kesinlik (Precision) tahminlerin doğruluğunu, geri çağırma (Recall) mevcut nesnelerin ne kadarının yakalandığını gösterir.

Ortalama duyarlılık (mAP) ise iki farklı şekilde hesaplanmıştır: mAP_0.5, IoU (Intersection over Union) eşik değeri 0.5 iken hesaplanan ortalama duyarlılıktır. Daha katı bir metrik olan mAP_0.5:0.95 ise IoU eşik değeri 0.5'ten 0.95'e kadar farklı adımlarla hesaplanan ortalama duyarlılıkların ortalamasını ifade eder.

Eğitimin temel amacı, tüm kayıp değerlerini düşürerek Precision, Recall, mAP gibi performans metriklerini yükseltmektir. Model başlangıçta veri setindeki bilgileri hızla öğrenir ve performansı artar. Bu performans modelin hiç görmediği doğrulama seti ile ölçülür. Eğer model bu süreçte yeni bir bilgi öğrenmiyor ve öğrendiği bilgiler işe yaramıyorsa erken durdurma (early stopping) ile sonlandırılabilir veya önceden belirlenen epoch sayısına ulaşıldığında tamamlanabilir. Bir epoch, modelin tüm eğitim verisini bir kez görüp öğrenmesidir. Bu çalışma 100 epoch sonunda tamamlanmıştır.

3.5. Modelin Değerlendirilmesi ve Sonuçların Analizi

Eğitim süreci tamamlandıktan sonra, modelin nihai performansını değerlendirmek için test seti kullanılmaktadır. Değerlendirme, hem nicel metriklerle hem de nitel (görsel) analizle yapılmaktadır.

3.5.1. Değerlendirme Metrikleri

Nesne tespiti modellerinin performansını ölçmek için kullanılan temel metrikler aşağıda açıklanmıştır (Everingham et al., 2010):

Intersection over Union (IoU): Bu metrik, modelin tahmin ettiği sınırlayıcı kutu ile gerçek kutunun ne kadar örtüştüğünü ölçer. Değeri 0 ile 1 arasında değişir ve yüksek bir IoU değeri, tahminin isabetli olduğunu gösterir. Matematiksel olarak aşağıdaki şekilde ifade edilir:

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} \quad (3.1)$$

Kesinlik (Precision): Modelin yaptığı pozitif tahminlerin ne kadarının doğru olduğunu ölçer. Yüksek kesinlik, modelin yanlış pozitif (False Positive - FP) oranının düşük olduğunu gösterir. Doğru pozitif eğitim modelimizin performansını artıran sonuçtur. Yanlış negatif ve yanlış pozitif ise performansı düşüren sonuçlardır. Formülü aşağıdaki gibidir:

$$P = \frac{\text{Doğru Pozitif Örnekler (TP)}}{\text{Modelin pozitif olarak tahmin ettiği tüm örnekler (TP)+(FP)}} \quad (3.2)$$

Geri Çağırma (Recall / Duyarlılık): Görüntüdeki mevcut tüm pozitif nesnelerin ne kadarının model tarafından doğru bir şekilde tespit edildiğini ölçer. Yüksek geri çağırma, modelin yanlış negatif (False Negative - FN) oranının düşük olduğu anlamına gelir. Kesinlik ve duyarlılık 0 ile 1 arasında bir değer alır. 1'e ne kadar yakınsa model başarılı o derece yüksektir. Formülü aşağıdaki gibidir:

$$R = \frac{\text{Doğru Pozitif Örnekler (TP)}}{\text{Pozitif olarak etiketlenen tüm örnekler (TP)+(FN)}} \quad (3.3)$$

Ortalama Duyarlılık (Average Precision - AP): Tek bir sınıf için, farklı geri çağırma seviyelerindeki kesinlik değerlerinin ortalaması alınarak hesaplanan bir metriktir. Precision-Recall eğrisinin altında kalan alanı temsil eder.

$$\text{Ortalama Hassasiyet (AP)} = \int_0^1 p(r)dr \cong \sum_{k=1}^n p(k) \cdot \Delta r(k) \quad (3.4)$$

Ortalama Duyarlılık Ortalaması (mean Average Precision - mAP): Tüm sınıflar için hesaplanan AP değerlerinin ortalamasıdır. Nesne tespiti modelleri için en standart ve en kapsamlı başarı metriği olarak kabul edilir. Genellikle belirli bir IoU eşliğinde (örneğin, mAP@0.5) veya bir IoU aralığında (örneğin, mAP@0.5:0.95) raporlanır (Lin et al., 2014). mAP performans değeri 0 ile 1 arasında değişir; 1'e yakınsa model başarılı, 0'a yakınsa başarısızdır. mAP değeri genellikle yüzde olarak ifade edilir.

$$\text{Genel Ortalama Hassasiyet (mAP)} = \frac{\sum \text{AP}}{\text{Sınıf sayısı}} \quad (3.5)$$

3.5.2. Eğitim Sonuçlarının Analizi

Eğitim sürecinin sonunda elde edilen sonuçlar, modelin 100 epoch'luk eğitimini başarılı bir şekilde tamamladığını ve öğrenme işlemini etkin bir şekilde gerçekleştirdiğini göstermektedir. Bu, modelin özellikle box_loss, obj_loss ve cls_loss gibi kayıp (loss) değerlerinin eğitim boyunca sürekli olarak düştüğü, buna karşın Precision, Recall ve mAP gibi performans metriklerinin ise yükselme eğilimi gösterdiği anlamına gelmektedir. Bu durum, modelin hem sınırlayıcı kutu yerleşimi ve sınıflandırma görevlerinde daha doğru

hale geldiğini hem de aşırı öğrenme (overfitting) gibi istenmeyen durumların kontrol altında tutulduğunu doğrulamaktadır. Dolayısıyla, modelin KKD tespiti görevine başarılı bir şekilde adapte olduğu söylenebilir.

3.5.3. Modelin Görsel Çıktılarının Değerlendirilmesi

Nicel metriklerin yanı sıra, modelin performansını anlamak için test görüntüleri üzerindeki görsel çıktıların incelemek de önemlidir. Modelin farklı pozlardaki ve farklı arka planlardaki insanları, kaskları, yelekleri ve eldivenleri yüksek bir doğrulukla tespit ettiği görülmektedir. Sınırlayıcı kutular, nesneleri doğru bir şekilde çevrelemektedir. Ayrıca modelin daha kalabalık ve karmaşık sahnelerdeki performansını göstermektedir. Model, birden fazla çalışanın ve KKD'nin bulunduğu sahnelerde bile başarılı tespitler yapabilmektedir. Ancak, bazı küçük veya kısmen örtülmüş nesneleri (özellikle eldivenleri) kaçırabildiği veya yanlış sınıflandırabildiği de gözlemlenebilir. Bu gözlemler, Tablo 4.1'deki nicel sonuçlarla tutarlıdır.

4. BULGULAR VE TARTIŞMA

Önceki bölümde detaylandırılan yöntemlerle eğitilen YOLOv5 modelinin performansı analiz edilmiş ve elde edilen bulgular, literatürle karşılaştırılarak tartışılmıştır. Modelin nicel (sayısal) ve nitel (görsel) sonuçları, sistemin etkinliğini, sınırlılıklarını ve İSG alanındaki potansiyelini ortaya koymayı amaçlamıştır.

4.1. Model Performansına İlişkin Bulgular

Geliştirilen yapay zekâ modelinin performansı hem sayısal metrikler hem de görsel analizler üzerinden değerlendirilmiştir. Bulgular, modelin kişisel koruyucu donanım tespitinde genel olarak yüksek bir başarı sergilediğini, ancak nesne türüne bağlı olarak değişken performans gösterdiğini ortaya koymuştur.

4.1.1. Nicel Bulgular: Sayısal Performans Analizi

Modelin performansı, eğitim sonrası doğrulama ve test veri setleri üzerinde ölçülen metriklerle değerlendirilmiştir. Bu analiz, modelin etkinliğine dair nesnel veriler sunmaktadır.

Aşama 1: Genel Performans

Şekil 4.1'deki terminal çıktısına göre, model tüm sınıflarda $mAP@0.5$ 'te %86,6 gibi yüksek bir doğruluk oranı elde etmiştir. Bu, modelin iş sahalarında KKD'leri ve çalışanları genellikle doğru bir şekilde tespit edebildiğini göstermektedir. $mAP@0.5$, nesnelerin sınıflandırılmasında ve konumlarının en az %50 doğrulukla (IoU) tahmin edilmesinde modelin güvenilir olduğunu kanıtlamaktadır. Ancak, daha katı bir metrik olan $mAP@0.5:0.95$ 'te %59,3'lük bir oran elde edilmiştir.

```

100 epochs completed in 0.671 hours.
Optimizer stripped from runs/train/yolov5s_results/weights/last.pt, 14.8MB
Optimizer stripped from runs/train/yolov5s_results/weights/best.pt, 14.8MB

Validating runs/train/yolov5s_results/weights/best.pt...
Fusing layers...
custom_YOLOv5s summary: 182 layers, 7254609 parameters, 0 gradients

```

Class	Images	Instances	P	R	mAP50	mAP50-95: 100% 16/16 [00:09<00:00, 1.60it/s]
all	505	2409	0.884	0.823	0.866	0.593
insan	505	752	0.949	0.915	0.955	0.678
kask	505	711	0.962	0.954	0.978	0.701
yelek	505	609	0.962	0.921	0.965	0.738
eldiven	505	337	0.663	0.501	0.565	0.256

```

Results saved to runs/train/yolov5s_results
CPU times: user 27.9 s, sys: 2.99 s, total: 30.9 s
Wall time: 41min 11s

```

Şekil 4.1. 100 Epoch'luk eğitimin tamamlanma çıktısı ve performans özeti

Aşama 2: Sınıf Bazında Performans

Modelin genel performansı (tüm sınıflar için) mAP@0.5'te %86,6 gibi oldukça yüksek bir değerdedir. Tablo 4.1'de detaylandırılan sınıf bazlı analiz, modelin güçlü ve zayıf yönlerini açıkça ortaya koyaktadır:

a) Üstün Performans (Kask ve Yelek): Kask (%97,8) ve yelek (%96,5) sınıflarında model, neredeyse hatasız bir performans sergilemektedir. Bu KKD'lerin parlak renkleri (sarı, turuncu) ve sabit geometrik şekilleri, modelin öğrenmesini kolaylaştırmaktadır. Yüksek kesinlik (P) ve geri çağırma (R) oranları, yanlış pozitif (FP) ve yanlış negatif (FN) oranlarının çok düşük olduğunu göstermektedir.

b) Yüksek Performans (İnsan): İnsan vücudunun değişken duruşlarına rağmen elde edilen (%95,5) yüksek başarı, veri setinin çeşitliliğinin ve modelin genelleme yeteneğinin bir kanıtıdır. Bu, sistemin bir alandaki çalışan varlığını güvenilir bir şekilde belirleyebileceğini ve KKD ihlallerini kişilerle ilişkilendirebileceğini göstermektedir.

c) Zayıf Performans (Eldiven): Eldiven sınıfı (%56,5), modelin en çok zorlandığı alan olmuştur. Eldivenlerin P (kesinlik) değeri %66,3 iken, R (geri çağırma) değeri %50,1'de kalmıştır. Bu, modelin eldiven olarak tahmin ettiği nesnelerin üçte ikisinin doğru olduğunu, ancak sahadaki tüm eldivenlerin sadece yarısını tespit edebildiğini göstermektedir. Bu düşük performansın olası nedenleri şunlardır:


- **Küçük Nesne Boyutu:** Eldivenler, kask veya yeleğe göre daha küçük nesnelerdir (az piksel kaplama).
- **Çeşitlilik:** Çok farklı renk, şekil ve malzemede eldiven bulunmaktadır.
- **Örtülme (Occlusion):** Eldivenler genellikle aletler veya taşınan malzemeler tarafından kısmen veya tamamen kapatılmaktadır.
- **Deformasyon:** Eldivenler, el hareketine bağlı olarak sürekli şekil değiştirmektedir.

Tablo 4.1. Modelin sınıf bazında performans metrikleri

Sınıf (Class)	Görüntü Sayısı	Örnek Sayısı (Instances)	P (Precision)	R (Recall)	mAP@.5	mAP@.5:.95
All	505	2409	0,884	0,823	0,866	0,593
İnsan	505	752	0,949	0,915	0,955	0,678
Kask	505	711	0,962	0,954	0,978	0,701
Yelek	505	609	0,962	0,921	0,965	0,738
Eldiven	505	337	0,663	0,501	0,565	0,256

Aşama 3: Öğrenme Süreci

Modelin sadece nihai sonuçları değil, öğrenme süreci de sağlıklı bir gelişim gösterdiğini kanıtlamaktadır. Epoch artışına bağlı olarak grafik değerleri değişmektedir Şekil 4.2’de veri setinin loss fonksiyon grafiği verilmiştir.




Şekil 4.2. Loss fonksiyon grafikleri.

a) Hata Oranları (Loss): Şekil 4.2'deki grafikler, train/box_loss, train/obj_loss ve train/cls_loss gibi eğitim setlerinde ve val/box_loss, val/obj_loss ve val/cls_loss gibi doğrulama setlerinde kayıp değerlerinin istikrarlı bir şekilde azaldığını göstermektedir. Sınırlama kutusu kaybı (box_loss): Eğitim sırasında, modelin tahmin ettiği sınırlama kutularıyla, eğitimde kullanılmak üzere manuel olarak etiketlenen sınırlama kutuları her epoch sırasında karşılaştırılır. Karşılaştırma sonucu oluşan hata, box-loss olarak adlandırılır. Böylece eğitim sırasında hatalar düzeltilir. Model, doğru sınırlama kutusu oluşturmayı öğrenir ve hatayı en aza indirmek için kendini sürekli düzenler. Model eğitim bittikten sonra ilk defa karşılaşılabileceği yeni bir veride nesneleri ne kadar doğru kutu içine alabildiği hakkında genel bir fikir oluşur. Sınırlama kutusu kaybı eğitim verileri ile karşılaştırıldığında, epoch sayısı artıktıkça kaybın 0.035'e kadar düştüğü, ancak, doğrulama verileri ile karşılaştırıldığında 0.03 değerinde kaldığı görülmektedir.

Sınıflandırma Kaybı (cls_loss): Eğitilen modelin sınıf tahminlerini ne kadar başarılı şekilde gerçekleştirdiğini gösteren bir ölçüdür. Eğitilen modelin tahmin ettiği sınıf ile etiketleme ile atanmış sınıfın ne kadar eşleştiğini gösterir. Düşük bir cls_loss, kaybın az olduğunu ve modelin tahminlerinin doğru olduğunu, yüksek bir cls_loss ise kaybın yüksek olduğunu ve modelin tahminlerinin yanlış olduğunu gösterir. Bu çalışmada sınıflandırma kaybı hem eğitim verilerinde (train/cls_loss) hem de doğrulama verilerinde (val/cls_loss) 0.01 değerinin altına kadar düştüğü görülmektedir (Aslan & Yağımlı, 2023).

b) Başarı Metrikleri: Şekil 4.3'teki grafikler, kesinlik, geri çağırma (duyarlılık) ve mAP değerlerinin ilk 40-50 epoch'a kadar hızla yükseldiğini ve sonrasında doygunluğa ulaştığını göstermektedir. Bu, 100 epoch'luk eğitimin modelin potansiyelini ortaya çıkarmak için yeterli olduğunu teyit etmektedir. Bu grafiklerde ise, kesinlik, geri çağırma ve mAP değerlerinin epoch sayısı arttıkça hızla yükseldiği ve belirli bir seviyede doygunluğa ulaştığı görülmektedir.

Kesinlik ve duyarlılık 0 ile 1 arasında bir değer alır. 1'e ne kadar yakınsa model başarılı o derece yüksektir. Bu da sağlıklı bir öğrenme sürecinin göstergesidir. mAP50 performansın 0,5 güven eşiği ile ölçüldüğünü gösterirken, mAP50-95 performansın 0,5- 0,95 güven eşiği ile ölçüldüğünü gösterir. mAP performans değeri 0 ile 1 arasında değişir; 1'e yakınsa model başarılı, 0'a yakınsa başarısızdır. mAP değeri genellikle yüzde olarak ifade edilir (Aslan & Yağımlı, 2023).



Şekil 4.3. Modelin performans metrikleri grafikleri (Precision, Recall, mAP)

4.1.2. Nitel Bulgular: Görsel Analiz

Sayısal veriler modelin başarı oranını gösterirken, görsel çıktılar pratik ortamlardaki etkinliğini değerlendirmede kritik bir rol oynamaktadır.


Aşama 1: Görsel Başarı Kanıtları

Şekil 4.5, modelin test veri setindeki performansını farklı senaryolarda (değişken aydınlatma, arka planlar, insan pozisyonları) göstermektedir. Örneğin, tek başına bir kaskın, kalabalık bir gruptaki KKD'lerin veya farklı açılardaki yeleklerin doğru tespit edilmesi, modelin gerçek saha koşullarına uyum sağlayabildiğini göstermektedir. Bu bulgu, teorik başarının pratik ortamlara da yansıyabileceğini göstermektedir.




Aşama 2: Karmaşık Sahneler ve Veri Kalitesi

Şekil 4.4, modelin kalabalık ve karmaşık sahnelerde (birden fazla çalışan ve KKD'nin bulunduğu ortamlarda) başarılı tespitler yapabildiğini ortaya koymaktadır. Şekil 4.5'teki titiz etiketleme süreci, bu başarının temelini oluşturmaktadır.



Şekil 4.5. Modelin farklı senaryolardaki nesne tespiti çıktıları



Şekil 4.6. Örnek görüntüler üzerinde sınırlayıcı kutularla etiketleme

Ancak, küçük veya örtülü eldivenlerin zaman zaman kaçırılması, Tablo 4.1'deki düşük eldiven performansı ile uyumlu bir sınırlılık olarak değerlendirilmektedir.

4.2. Bulguların Literatür Çerçevesinde Tartışılması

Bilgisayarlı görü teknolojisi sayesinde, kişisel koruyucu donanım kullanımı anlık olarak denetlenebilmektedir. Bu durum, YZ'nin reaktif yaklaşımlardan proaktif bir güvenlik çerçevesine geçişini doğrulamaktadır (Protex.ai, 2025; Lumana, 2024). Heinrich'in kaza piramidinde modelin bir ihlali anında tespit edip uyarı üretebilme potansiyeli, çok önemli bir kaza önleme ilkesini ortaya koymaktadır: Piramidin tabanını oluşturan küçük olayları azaltmak, mutlaka büyük kazaları önleyecektir (Fu vd., 2020). Bir çalışanın yakın çevresindeki maruz kalma risklerinin öngörülmesi ve kontrol edilmesinde YZ'nin oynadığı rolü vurgulayan Risk Evrimi, Tespiti, Değerlendirilmesi ve Kazaların Kontrolü (REDECA), İSG araştırmalarında YZ'ye dair kanıtların çoğunda, çalışanları tehlikeli koşullardan uzaklaştıran sensörler, tehlikeli durumları tespit etmek için sensörlerin geliştirilmesi ve olayları tespit etmek için sensörlerin kullanılması olmuştur. Geleneksel denetimlerin periyodik ve insan gücüne bağımlı yapısının aksine, geliştirilen model YZ'nin

insan hatalarını azaltma ve tehlikeleri oluşmadan önce tespit etme yeteneğini doğrulamaktadır (Pishgar vd., 2021).

Çalışmamızda, YOLOv5 algoritmasını kullanarak "insan", "kask", "yelek" ve "eldiven" gibi dört farklı nesne sınıfını aynı anda tespit etmeye odaklanılmıştır. 2512 görüntülük bir veri setinin kullanılması, modelin çoklu nesne sınıflarını ayırt etmesini sağlamıştır. Bu çoklu sınıf tespiti, her bir sınıf için performansı etkilemiştir. Genel mAP@0.5 değeri %86.6 olarak belirlenmiş, bu da Patel vd. ve Jin vd. çalışmalarının tek nesne veya özel olarak geliştirilmiş modellerine göre daha düşük bir genel başarıyı göstermektedir. Şekil 3.4 ve 4.6'daki veri hazırlama süreci, bir yapay Zekâ modelinin başarısı için kaliteli verinin kritik önemini vurgulamıştır. Özellikle eldiven tespitindeki düşük performans, veri çeşitliliğinin artırılması gerektiği yönündeki literatür bulgularıyla paralellik göstermektedir.

Son olarak, yapay Zekâ destekli sistemlerin pasif izlemeden öteye geçerek, çalışan davranışlarını anlık olarak analiz edebilme ve güvenlik ihlallerini proaktif bir şekilde tespit edebilme yeteneğini doğrulamaktadır (Akman,2024). Şekil 4.4 ve 4.5'teki elde edilen görsel başarılar, şantiye ortamlarında bilgisayarlı görünün etkinliğini gösteren araştırmalarla örtüşmektedir. Modelimizin elde ettiği yüksek başarı oranları çalışmaların işaret ettiği üzere, bilgisayarlı görünün inşaat sektöründe kazaları önlemede ve güvenlik kültürünü geliştirmede ne kadar etkili bir araç olduğunu somutlaştırmaktadır (Jeelani vd., 2021; Wu vd., 2021).

4.3. Geliştirilen Modelin İSG Alanındaki Potansiyel Uygulamaları ve Katkıları

Geliştirilen YZ modeli, iş yerindeki kameralara entegre edildiğinde, bir güvenlik ihlali tespit ettiğinde anında bir uyarı gönderebilir. Bu uyarı, ihlalin yapıldığı yer ve zamanın yanı sıra, ihlale ait bir görüntü veya kısa video kaydını da içerebilir. Eğer bir çalışan kasksız bir alana girerse, sistem hoparlörler aracılığıyla "Lütfen kaskınızı takınız" gibi otomatik ve bağlam odaklı sesli uyarılar yaparak anında müdahale edebilir.

Model, toplanan verileri analiz ederek hangi bölgelerde ihlallerin daha sık olduğunu gösteren bir risk haritası oluşturabilir. Bu harita, yöneticilerin güvenlik kaynaklarını en çok ihtiyaç duyulan alanlara yönlendirmesine yardımcı olur. Ayrıca, sürekli olarak aynı türde

ihlal yapan çalışanlar veya ekipler belirlenerek, bu kişilere yönelik daha hedeflenmiş ve kişiselleştirilmiş İSG eğitimleri planlanabilir.

Otomatik bir denetim sisteminin varlığı, çalışanlarda sürekli olarak izleniyor olma hissi yaratacağı için güvenlik kültürünün güçlenmesine katkıda bulunabilir. Bu potansiyel uygulamalar, geliştirilen modelin sadece bir "tespit" aracı olmadığını, aynı zamanda bir "yönetim", "analiz" ve "kültür geliştirme" aracı olarak da işlev görebileceğini göstermektedir.

4.4. Karşılaşılan Zorluklar ve Etik Hususlar

Bu tez çalışması, YZ tabanlı bir İSG sisteminin geliştirilmesinde karşılaşılan bazı teknik zorluklar ve önemli etik hususları ortaya koymuştur.

A-Teknik Zorluklar:

Veri Kalitesi ve Miktarı: Bir derin öğrenme modelinin başarısı, doğrudan eğitildiği veri setinin kalitesi ve miktarı ile ilişkilidir. Gerçek dünya koşullarını (farklı hava ve ışık koşulları, kamera kaliteleri, kısmi örtülmeler gibi) doğru bir şekilde yansıtan, çeşitli ve büyük ölçekli, doğru etiketlenmiş veri setleri oluşturmak oldukça maliyetli ve zaman alıcı bir süreçtir. Bu çalışmada eldiven tespiti elde edilen düşük performans (%56,5), bu zorluğun somut bir yansımasıdır. Eldiven gibi küçük, değişken ve kolayca örtülebilen nesnelerin tespiti için daha fazla ve çeşitli veriye ihtiyaç duyulmaktadır.

Genelleme Problemi: Eğitilen bir modelin, eğitildiği ortamdan farklı bir coğrafyada veya farklı bir endüstrideki bir iş yerinde aynı yüksek performansı göstermesi garanti değildir. Bu durum, YZ modellerinin genelleme problemi olarak adlandırılmaktadır. Modellerin farklı ortamlara adaptasyonunu sağlamak için sürekli olarak yeniden eğitilmesi veya daha geniş kapsamlı ve çeşitli veri setleriyle eğitilmesi gerekmektedir. Bu sınırlılık, sistemin farklı işyerlerine ölçeklenmesini zorlaştıran önemli bir faktördür.

Hesaplama Maliyeti: Derin öğrenme modellerinin eğitimi, güçlü ve pahalı grafik işlemci birimlerine (GPU) ciddi bir yatırım yapılmasını gerektirir. Aynı şekilde, eğitilen modelin

gerçek zamanlı olarak birden fazla kamera akışını işleyebilmesi için de önemli bir hesaplama gücüne (inference) ihtiyaç duyulur. Bu yüksek maliyet, özellikle küçük ve orta ölçekli işletmeler için yapay Zekâ tabanlı İSG çözümlerini benimseme konusunda önemli bir yatırım engeli teşkil edebilir.

B-Etik Hususlar ve Veri Gizliliği:

Çalışan Mahremiyeti ve Güvenlik Kaygıları: Çalışanların kameralarla sürekli olarak izlenmesi, mahremiyet haklarının ihlali ve "Büyük Birader" endişelerini beraberinde getirmektedir. Avrupa İş Sağlığı ve Güvenliği Ajansı'nın da vurguladığı gibi, yapay Zekânın çalışan yönetimi için kullanılması, veri koruma ve etik ilkeler açısından dikkatli bir yaklaşım gerektirir (EU-OSHA, 2022). Sürekli gözetim altında olmak, çalışanlarda stres ve moral bozukluğuna yol açabilir (Jarota, 2023). Bu nedenle, bu tür sistemlerin uygulanmasından önce çalışanların bilgilendirilmesi, açık rızalarının alınması ve verilerin nasıl kullanılacağına dair şeffaf politikaların oluşturulması hayati önem taşımaktadır.

Veri Güvenliği: Toplanan görsel verilerin güvenli bir şekilde saklanması ve yetkisiz erişimden korunması en önemli hususlardan biridir. Veri sızıntıları, yalnızca kişisel mahremiyetin ihlaline yol açmakla kalmaz, aynı zamanda hukuki yaptırımları da beraberinde getirir. Bu nedenle, verilerin işlenmesi ve saklanması süreçlerinde en güncel veri güvenliği protokollerinin ve yasal düzenlemelerin (örneğin GDPR) titizlikle uygulanması gerekmektedir.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Bu tez çalışmasında, iş yerlerindeki güvenlik önlemlerini daha etkili hale getirmek için YZ tabanlı bir sistemin nasıl geliştirilebileceği anlatılmıştır. Bu sistem koruyucu ekipmanlarını (baret, yelek, eldiven gibi) kullanan çok sayıda (tam olarak 2512) fotoğrafı içeren bir veri seti oluşturulmuş ve gerçek zamanlı nesne tespiti konusunda güçlü bir performansa sahip YOLOv5 derin öğrenme algoritması ile eğitilmiştir. Model, 100 aşamalı bir eğitimden sonra test edildiğinde hem sayısal verilerle hem de görsel analizlerle çok başarılı olduğu görülmüştür. Kısacası, bu çalışma, yapay Zekânın insan denetiminin gözden kaçırabileceği güvenlik ihlallerini anında tespit ederek, kazaların yaşanmasını önlemede ne kadar büyük bir potansiyel taşıdığını göstermektedir.

Yapay Zekâ destekli bir sistemin İSG alanında ne kadar etkili olabileceğini somut bulgularla ortaya koyulmuştur. Çalışmamızın temel sonuçları aşağıdaki gibi özetlenebilir:

Yüksek Performanslı Model Geliştirildi: Eğitilen bu YOLOv5 modeli, nesneleri ne kadar doğru tespit ettiğini gösteren bir ölçüm olan mAP@0.5 değerinde yüzde 86,6 gibi yüksek bir başarı elde etmiştir. Bu modelin, iş yerindeki koruyucu ekipmanları (KKD) bulma ve tanıma konusunda oldukça güvenilir bir potansiyele sahip olduğunu göstermektedir.

Kritik Ekipmanlarda Neredeyse Hatasız Tespit: Model, iş kazalarında hayati önem taşıyan kask (%97,8) ve yelek (%96,5) gibi kritik ekipmanları tespit etmede neredeyse hatasız bir performans sergilemiştir. Bu sayede, ölümcül sonuçlara yol açacak kazaların önüne geçme konusunda önemli bir katkı sağlanabilir.

Geliştirilmesi Gereken Alanlar: Modelin, eldiven gibi küçük, değişken ve sıkça örtülen nesnelerde gösterdiği performans (%56,5) olarak ölçülmüştür. Bu durum, veri setine daha çeşitli eldiven örnekleri eklenmesi veya veri artırma tekniklerinin daha yoğun kullanılması

gerektiğini ortaya koymaktadır. Gelecek çalışmalarda, bu tür zorlu nesnelerin tespitini iyileştirmek için daha karmaşık model mimarilerinin (YOLOv9, YOLOv10, YOLOv11, DETR vb.) denenmesi faydalı olacaktır.

Proaktif Güvenlik Yaklaşımı: Bu çalışma, yapay zekânın İSG'de reaktif (kaza sonrası müdahale) yaklaşımlardan proaktif (kaza öncesi önleme) yaklaşımlara geçişi destekleyebileceğini açıkça göstermiştir. Model, bir güvenlik ihlali anında tespit ederek tehlikenin kazaya dönüşmesini önleme fırsatı sunmaktadır. Bu yaklaşım, "sıfır kaza" hedefine ulaşmak için teknoloji destekli bir yol haritası sunmaktadır.

Özetle, bu tez, YZ destekli bir modelin iş yerlerini daha güvenli hale getirme potansiyeline sahip olduğunu ortaya koymuştur. Bu teknoloji, güvenlik denetçilerinin yerine geçmekten ziyade, onların yeteneklerini tamamlayan bir "yardımcı teknoloji" olarak konumlandırılmalıdır. İnsanların gözden kaçırabileceği tehlikeleri veya ihlalleri anında tespit ederek, denetçilerin daha önemli işlere odaklanmasına yardımcı olabilir. Ancak, bu teknolojinin başarısı, yalnızca teknik zorlukların aşılmasıyla sınırlı değildir; etik, mahremiyet ve veri gizliliği gibi insani boyutların da dikkatle ele alınması gerekmektedir.

5.2. Öneriler

Araştırmamızın bulguları ve karşılaştığımız sınırlılıklar için şu öneriler sunulmaktadır:

Veri Seti Çeşitliliği ve Kapsamı: Gelecek çalışmalarda, genellenebilir bir model oluşturulması için veri setinin kapsamı genişletilmelidir. Mevcut veri setine madencilik, kimya ve tarım gibi farklı sektörlerden elde edilen görüntüler eklenmelidir. Ayrıca, yağmur, sis ve gece gibi zorlu çevresel koşullarda çekilmiş görüntülerle veri seti zenginleştirilerek modelin değişen ortamlara uyum sağlama yeteneği artırılmalıdır. Yalnızca kask gibi temel kişisel koruyucu donanımların tespiti yerine, emniyet kemeri, koruyucu gözlük, maske ve iş ayakkabısı gibi diğer KKD türleri de sınıflara dahil edilmelidir. Özellikle eldiven gibi zorlu nesnelerin tespiti için daha fazla ve çeşitli örnekler toplanarak veri artırma tekniklerinin etkinliği artırılabilir.

Yeni Model Mimarileri ve Yaklaşımları: Model performansının optimizasyonu için daha güncel ve gelişmiş YZ mimarilerinin kullanılması önerilmektedir. YOLO'nun daha yeni versiyonları (örneğin YOLOv9, YOLOv10) veya Transformer tabanlı nesne tespiti modelleri (DETR) gibi yaklaşımlar test edilerek mevcut model ile karşılaştırmalı analizler yapılabilir (Carion et al., 2020). Nesnelerin yalnızca sınırlayıcı kutularla değil, piksel düzeyinde daha hassas bir şekilde tespit edilmesi için görüntü bölütleme (image segmentation) modellerinin entegrasyonu da araştırılabilir (He et al., 2017).

Çok Modlu Sistem Entegrasyonu: Sadece görsel veriye dayalı yaklaşımların ötesine geçilerek çok modlu YZ modelleri geliştirilmelidir (Baltrušaitis et al., 2018). Görsel veriye ek olarak, makine arızaları veya uyarı çığlıkları gibi ses verileri, gaz veya sıcaklık gibi sensör verileri ve kaza raporları gibi metin verileri birleştirilerek daha bütüncül bir risk analizi yapılabilir (Hermann, et al., 2016).

Etik ve Sosyal Boyutların İncelenmesi: YZ tabanlı gözetim sistemlerinin çalışanlar üzerindeki etik ve sosyal etkileri kapsamlı bir şekilde araştırılmalıdır. Bu sistemlerin çalışan motivasyonu, iş tatmini ve psikolojik sağlığı üzerindeki potansiyel etkileri sosyolojik ve psikolojik açıdan incelenmelidir.

Pilot Uygulamalar ve Gerçek Zamanlı Testler: Modelin endüstriyel ortamlardaki performansını değerlendirmek için, pilot bir iş sahasında mevcut kamera sistemleriyle entegre edilerek gerçek zamanlı testler yapılmalıdır. Bu süreçte, modelin saha koşullarındaki doğruluğu, yanlış alarm oranları ve karşılaşılabilecek pratik zorluklar belirlenerek sistemin pratik kullanıma uygunluğu test edilmelidir. Elde edilen geri bildirimler, modelin operasyonel verimliliğini artırmak için kritik öneme sahiptir.

Mevcut Sistemlerle Entegrasyon: Geliştirilen modelin işletmenin mevcut İSG yönetim yazılımları, insan kaynakları sistemleri ve acil durum müdahale protokolleriyle bütünleşik bir şekilde çalışması sağlanmalıdır. Bu entegrasyon sayesinde, bir İSG ihlali tespit edildiğinde uyarı, raporlama ve kayıt altına alma gibi süreçler otomatik olarak başlatılabilir. Bu otomasyon, insan hatasını minimize ederek ve müdahale sürelerini kısaltarak iş güvenliği yönetimini daha etkin hale getirecektir.

Şeffaf ve Katılımcı Yaklaşım Benimsenmesi: YZ temelli gözetim sistemlerinin işyerlerinde başarıyla uygulanabilmesi için şeffaf ve katılımcı bir yaklaşım benimsenmelidir. Modelin uygulamaya konulmasından önce, çalışanlar ve sendika temsilcileri süreç hakkında bilgilendirilmelidir. Sistemin amacının cezalandırmak değil, korumak olduğu net bir şekilde vurgulanmalı, veri gizliliği politikaları açıkça paylaşılmalı ve çalışanların endişeleri dikkate alınmalıdır. Bu şeffaflık, teknolojiye karşı oluşabilecek olası direnci azaltarak sistemin işyeri kültürüne entegrasyonunu kolaylaştıracaktır.



KAYNAKLAR

- Akman, S. (2024). Yapay Zekâ Tabanlı İSG Analizleri ile İş Güvenliği Kültürünün Arttırılması, TMMOB Makine Mühendisleri Odası İzmir Şubesi, 411. Bülten.
- Aksoy, M. (2022). *İş sağlığı ve güvenliğinde derin öğrenme tabanlı risk tespit ve analizi* [Yüksek Lisans Tezi, Fırat Üniversitesi]. Fırat Üniversitesi Akademik Arşiv Sistemi.
- Allahverdi, N. (2002). Uzman Sistemler Bir Yapay Zekâ Uygulaması, Atlas Yayın Dağıtım.
- ASBÜ, (2017). İş Sağlığı ve Güvenliği (İSG) Nedir. <https://isg.asbu.edu.tr/tr/isg-nedir>
- Aslan, T., ve Yağımlı, M. (2023). İş Sağlığı ve Güvenliğinde Derin Öğrenme Tabanlı Risk Tespit ve Analizi. *The Journal of International Scientific Researches*, 8(2), s. 223–236.
- Atalay, F. (2015). The History of the Coal Mining Industry and Mining Accidents in the World and Turkey. *Turkish Thoracic Journal*, 16(1), s. 5-8.
- Aydın, C. (2025, Şubat). OpenAI'nin o3 ve o3-mini modelleri ile yapay Zekâda yeni bir dönemin kapıları açılıyor. *Bilim ve Teknik Dergisi*, 58(687), 58-59.
- Aylak, B. L., Oral, O., ve Yazıcı, K. (2021). Yapay Zekâ ve Makine Öğrenmesi Tekniklerinin Lojistik Sektöründe Kullanımı. *El-Cezerî Fen ve Mühendislik Dergisi*, 8(1), s. 74-93.
- Banger, G. (2018). Endüstri 4.0 Uygulama ve Dönüşüm Rehberi, 1.Baskı, Ankara:Dorlion Yayınları:37
- Baltrušaitis, T., Ahuja, C., and Morency, L. P. (2018). *Multimodal Machine Learning: A Survey and Taxonomy*. IEEE Transactions on Pattern Analysis and Machine Intelligence.
- Birer, G. C. (2024, Ekim). Yapay genel Zekâ: İnsanlığın yeni ufku. *Bilim ve Teknik*, 5(683), s. 26-37.
- Bozkurt, Y., ve Naycı, G. (2021). Metal sektöründe meydana gelen iş kazalarında cinsiyet faktörü. *Akademik Yaklaşımlar Dergisi*, 12(1), s. 191-200.
- Bütüner, O., ve Uzun, D., (2010), İş Kazalarının Maliyetleri ve Hesaplamaları Üzerine Bir Arştırma, MYO-ÖS Ulusal Meslek Yüksekokulları Öğrenci Sempozyumu, Düzce.
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., and Zagoruyko, S. (2020). *End-to-End Object Detection with Transformers*. European Conference on Computer Vision.

Ceylan, H. (2014). Türkiye’de İnşaat Sektöründe Meydana Gelen İş Kazalarının Analizi. *International Journal of Engineering Research and Development*, 6(1), s.1-6.

Ceylan, H., ve Avan, M. (2012). Türkiyede’ki İş Kazalarının Yapay Sinir Ağları ile 2025 Yılına Kadar Tahmini. *International Journal of Engineering Research and Development*, 4(1), s. 46–54.

Cheng, J. C. P., Wong, P. K.Y., Luo, H., Wang, M., and Leung, P. H. (2022). Vision-based monitoring of site safety compliance based on worker re-identification and personal protective equipment classification. *Automation in Construction*, 139, 104312.

Cömert, M. A., Yılmaz, H., Erden Gebeşoğlu, B., Tutkun, E., Keskinçilic, B. ve Soydal, T. (2014). Kaynak İşçilerinde Pnömkonyoz Gelişimi Yönünden Risk Faktörlerinin Değerlendirilmesi. *Ankara Medical Journal*, 14(1), s. 11–14.

Demir, E. (2009). Metal iş kolunda meydana gelen iş kazaları ve iş kazalarının oluşturduğu, kayıpların ekonomik yönden analizi. Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Dhole, A. R., Gunjal, S. N., and Deshmukh, R. B. (2023). Helmet detection for industrial safety using YOLOv5 & YOLOv7. *Procedia Computer Science*, 218, 1729-1738.

Doğan, F., ve Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *DÜMF Mühendislik Dergisi*, 10(2), s. 409–445.

Eskiyörük, D. (2007). BGYS-Risk Yönetim Süreci Kılavuzu, TÜBİTAK Ulusal Elektronik ve Kriptoloji Araştırma Enstitüsü.

Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., and Zisserman, A. (2010). *The Pascal Visual Object Classes (VOC) challenge*. *International Journal of Computer Vision*, 88(2), 303–338.

EU-OSHA, (2022). Artificial intelligence for worker management: implications for occupational safety and health, Report, European Agency for Safety and Health at Work.

Fang, W., Ding, L., Luo, H., and Love, P. E. D. (2020). Falls from heights: A computer vision-based approach for safety harness detection. *Automation in Construction*, 113,

Fu, G., Xie, X., Jia, Q., Li, Z., Chen, S., and Ge, Y. (2020). The development history of accident causation models in the past 100 years: 24Model, a more modern accident causation model. *Process Safety and Environmental Protection*, 134, 47–82.

Gürçan, F. (2021). Endüstri 4.0 ve iş sağlığı güvenliğinde yapay zekâ uygulamaları. *Mühendislik Bilimleri Dergisi*, 27(3), s. 341-356.

He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017). *Mask R-CNN*. IEEE International Conference on Computer Vision.

Hermann, M., Pentek, T., and Otto, B. (2016). *Design Principles for Industrie 4.0 Scenarios*. 49th Hawaii International Conference on System Sciences.

Howard, J. (2019). Artificial intelligence: Implications for the future of work. *American Journal of Industrial Medicine*, 62(11), 939–945.

Jarota, M. (2023). Artificial intelligence in the work process. A reflection on the proposed European Union regulations on artificial intelligence from an occupational health and safety perspective. *Computer Law ve Security Review*, 49.

Jeelani, I., Asadi, K., Ramshankar, H., Han, K., and Albert, A. (2021). Real-Time Vision-Based Worker Localization & Hazard Detection For Construction. *Automation in Construction*, 121, 103448.

Jetha, A., Bakhtari, H., Irvin, E., Biswas, A., Smith, M. J., Mustard, C., Arrandale, V. H., Dennerlein, J. T., and Smith, P. M. (2025). Do occupational health and safety tools that utilize artificial intelligence have a measurable impact on worker injury or illness? Findings from a systematic review. *Systematic Reviews*, 14(146), 1–10.

Jilcha, K., and Kitaw, D. (2016). A Literature Rewiev on Global Occupational Safety And Health Practice And Accidents Severity. *International Journal for Quality Research*, 10(2), 279–310.

Jin, P., Li, H., Yan, W., and Xu, J. (2024). YOLO-ESCA: A high-performance safety helmet standard wearing behavior detection model based on improved YOLOv5. *IEEE Access*, 12, 23854-23868.

Jocher, G., Chien, H., and Yu, S. (2020). YOLOv5. GitHub deposu. <https://github.com/ultralytics/yolov5>

Kabakulak T.(2019), Bir Tekstil İşletmesinde Risk Değerlendirme Uygulaması: 5x5 Matris ve HAZOP. *Karaelmas İş Sağlığı Ve Güvenliği Dergisi*. 3(2), s. 97-111

Kavasoğlu, B. R. (2023). *Yapay Zekâ ve görsel tasarım uygulamaları*. IKSAD Publishing House.

Kılıç, B. (2020, Mayıs). Yapay Zekâ uygulamaları. *TÜBİTAK BİLGEM Kurumsal Dergisi*, (9), s. 26-30.

Kılıç, H. (2017). Kamuda Bulut Bilişim Kullanımına Yönelik Risk Analizi ve Yönetimi. (Uzmanlık Tezi). Çevre ve Şehircilik Bakanlığı. Ankara.

Koçar, O., ve Dizdar, E. N. (2018). İş Sağlığı ve Güvenliği Yönetim Sistemlerinde Risklerin Yapay Sinir Ağlarıyla Değerlendirilmesi. *Academic Platform Journal of Engineering and Science*, 6 (3), s. 73-83.

- Lee, J., Park, S. H., Chung, Y., and Byon, C. (2023). A Study on the Application of Smart Construction Safety Management System to Tunnel Construction Based on Worker Location Monitoring Technology. *Preprints*.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Li, Y., Wei, H., Han, Z., Huang, J., and Wang, W. (2020). Deep Learning-Based Safety Helmet Detection in Engineering Management Based on Convolutional Neural Networks. *Advances in Civil Engineering*, 2020, Article ID 9703560, 1-10.
- Li, J., Zhao, X., Zhou, G., and Zhang, M. (2022). Standardized use inspection of workers' personal protective equipment based on deep learning. *Safety Science*, 150, 105689.
- Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context
- Lumana. (2024, 23 Ocak). Journey to Zero: Using AI EHS Solutions to Prevent Workplace Accidents.
- Makesense.ai. (2025). <https://www.makesense.ai/>
- Murat, B., Motorcu, A. R., ve Kayır, Y. (2021). İş sağlığı ve güvenliği faaliyetlerinde yapay zekâ ve uzman sistem uygulamalarının değerlendirilmesi. 5. *Uluslararası Mühendislik ve Teknoloji Yönetimi Kongresi*. Güven Plus Grup A.Ş. Yayınları. s. 240-248.
- Naftali, M. G., Sulistyawan, J. S., and Julian, K. (2022). Comparison of Object Detection Algorithms for Street-level Objects. arXiv preprint arXiv: 2208.11315
- Ozobu, C. O., Adikwu, F. E., Odujobi, C., Onyeke, F. O., and Nwulu, E. O. (2025). Advancing Occupational Safety with AI-Powered Monitoring Systems: A Conceptual Framework for Hazard Detection and Exposure Control. *World Journal of Innovation and Modern Technology*, 9(1), 186-213.
- Park, J., and Kang, D. (2024). Artificial Intelligence and Smart Technologies in Safety Management: A Comprehensive Analysis Across Multiple Industries. *Applied Sciences*, 14(11934).
- Patel, K., Patel, V., Prajapati, V., Chauhan, D., Haji, A., and Degadwala, S. (2023). Safety Helmet Detection Using YOLO V8. *2023 3rd International Conference on Pervasive Computing and Social Networking (ICPCSN)*, 22-26.
- Pirim, H. (2006). Yapay Zekâ.
- Pishgar, M., Issa, S. F., Sietsema, M., Pratap, P., and 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(12), 6705.
- Protex.ai, (2025). Protex AI - Proactive Safety Powered by AI. <https://protex.ai/>

Roboflow. (2025). *Roboflow Annotate*. Roboflow. <https://roboflow.com/annotate>

Russell, S., and Norvig, P. (2003). *Artificial Intelligence A Modern Approach*, Pearson Education Inc.

Sezer, İ. Ç. (2025). Bilgisayar Biliminin Nobeli Turing Ödülü Pekiştirmeli Öğrenmenin Mimarlarına. *Bilim ve Teknik Dergisi*, 58(692), s. 44–45.

Schwab, K. (2017). *Dördüncü Sanayi Devrimi* (Çev. B. Doğru). Optimist Yayınları.

Shehadeh, A., and Alshboul, O. (2025). Enhancing occupational safety in Construction: Predictive analytics using advanced ensemble machine learning algorithms. *Engineering Applications of Artificial Intelligence*, 159, 111761.

Şardan, H. S. (2005). İş Sağlığı ve Güvenliğinde Yeni Oluşumlar; Risk Değerlendirmesi ve OHSAS 18001. (Yüksek Lisans Tezi). Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.

Şengöz, T. E., ve Bozkurt, Y. (2025). İş Sağlığı ve Güvenliği Kapsamında Sektörel İş Kazalarının Yapay Zekâ Teknolojileri ve Uzman Sistem Uygulamaları Yönünden İncelenmesi. *Sürdürülebilir Mühendislik Uygulamaları ve Teknolojik Gelişmeler Dergisi*, 8(1), s. 17-44.

T. C. Cumhurbaşkanlığı Mevzuat Bilgi Sistemi (MBS, 2006). Sosyal Sigortalar ve Genel Sağlık Sigortası Kanunu. Kanun Numarası: 5510. Kabul Tarihi: 31.05.2006. Yayımlandığı Resmî Gazete Tarihi: 16.06.2006. Sayı: 26200. Yayımlandığı Düstur: Tertip:5 Cilt: 45.

T. C. Cumhurbaşkanlığı Mevzuat Bilgi Sistemi (MBS, 2012). 6331 sayılı İş Sağlığı ve Güvenliği Kanunu, Kanun Numarası: 6631. Kabul Tarihi: 20.06.2012. Yayımlandığı Resmî Gazete Tarihi: 30.06.2012. Sayı: 28339. Yayımlandığı Düstur: Tertip:5 Cilt: 52.

T. C. Cumhurbaşkanlığı Mevzuat Bilgi Sistemi (MBS, 2012). İş Sağlığı ve Güvenliği Risk Değerlendirmesi Yönetmeliği, Yayımlandığı Resmî Gazete Tarihi: 29.12.2012. Sayı: 28512.

TİSK, (2023). Türkiye'nin Sıfır Kazaya Yolculuğu, İSG Raporu. (TİSK, Mikrocerrahi ve Rekonstrüksiyon Vakfı, intenseye).

Url-1 <https://www.ilo.org/tr/resource/news/yakla%C5%9F%C4%B1k-3-milyon-ki%C5%9Fi-i%C5%9F-kazalar%C4%B1-ve-meslek-hastal%C4%B1klar%C4%B1-nedeniyle> Erişim Tarihi: 01.08.2025

Url-2 https://www.isgturkiyesinav.com/wp-content/uploads/16.-KONU-ULUSAL-VE-ULUSLARARASI-IS-SAGLIGI-VE-GUVENLIGI-KURUM-VE-TESKILAT-YAPILARI-@isg_turkiye_sinav.pdf Erişim Tarihi: 01.08.2025

Url-3 <https://www.csgb.gov.tr/Media/fgwlc5ol/meslekhastaliklari.pdf> Erişim Tarihi: 01.08.2025

Url-4 <https://www.karmaisg.com/blog/risk-degerlendirmesi-nedir> Erişim Tarihi: 02.08.2025

Url-5 https://ischool.syracuse.edu/types-of-ai/?utm_source=chatgpt.com Erişim Tarihi: 02.08.2025

Url-6 <https://roboflow.com/> Erişim Tarihi: 07.12.2023

Url-7 <https://www.kaggle.com/> Erişim Tarihi: 07.12.2023

Url-8 <https://blog.roboflow.com/guide-to-yolo-models/> Erişim Tarihi: 02.08.2025

Url-9 <https://medium.com/deep-learning-turkiye/yolo-algoritmas%C4%B1n%C4%B1-anlamak-290f2152808f> Erişim Tarihi: 02.08.2025

Uşar, D., Uras, M., Ersoy, S., ve Bozkurt, Y. (2018). Günümüzde Makineleşmenin İş Kazalarına Etkisi. *SETSCI-Conference Proceedings*, 2, s. 361-365.

Vădineanu, Ş., Pelt, D. M., Dzyubachyk, O., and Batenburg, K. J. (2022). *An analysis of the impact of annotation errors on the accuracy of deep learning for cell segmentation*. In *Proceedings of The 5th International Conference on Medical Imaging with Deep Learning* (pp. 1251–1267). Proceedings of Machine Learning Research. <https://proceedings.mlr.press/v172/vadineanu22a.html>

Yazdi, M. (2024). *Artificial Intelligence in Workplace Health and Safety: Data-Driven Technologies, Tools and Techniques*. CRC Press.

Yıldız, M. (2023, 28 Nisan). *Derin Öğrenme Modellerinin Eğitiminde Kullanılan 5 Önemli Veri Seti*. Medium. <https://medium.com/academy-team/derin-%C3%B6%C4%9Frenme-modellerinin-e%C4%9Fitiminde-kullan%C4%B1lan-5-%C3%B6nemli-veri-seti-788a1d71f9fd>

Yılmaz, A. (2020). Yapay Zekâ (7.bs.) KODLAB Yayın Dağıtım, s. 45-46.

Wu, H., Zhong, B., Li, H., Love, P., Pan, X., and Zhao, N. (2021). Combining Computer Vision With Semantic Reasoning For On-Site Safety Management in Construction. *Journal of Building Engineering*, 42, 103036.

Zhang, Y. J., Xiao, F. S., and Lu, Z. M. (2022). Helmet Wearing State Detection Based on Improved Yolov5s. *Sensors*, 22(24), 9843.

Zhou, F., Zhao, H., and Nie, Z. (2021). Safety helmet detection based on YOLOv5. In *2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA)* (pp. 6-11). IEEE.f

EKLER

Ek-A Model Eğitim Sürecinin Konsol Çıktısı

```

+ Kod + Metin
Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
33/99 1.97G 0.03965 0.04414 0.01147 118 416: 100% 110/110 [00:18:00:00, 5.83it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:04:00:00, 3.63it/s]
all 505 2409 0.839 0.763 0.804 0.513

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
34/99 1.97G 0.03966 0.04491 0.01141 84 416: 100% 110/110 [00:19:00:00, 5.77it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:04:00:00, 3.93it/s]
all 505 2409 0.829 0.779 0.807 0.507

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
35/99 1.97G 0.03965 0.04337 0.01094 90 416: 100% 110/110 [00:19:00:00, 5.56it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:04:00:00, 3.80it/s]
all 505 2409 0.845 0.765 0.816 0.515

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
36/99 1.97G 0.03925 0.04372 0.01107 107 416: 100% 110/110 [00:18:00:00, 5.95it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:05:00:00, 3.20it/s]
all 505 2409 0.859 0.762 0.812 0.506

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
37/99 1.97G 0.03884 0.04276 0.01093 96 416: 100% 110/110 [00:18:00:00, 5.96it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:04:00:00, 3.88it/s]
all 505 2409 0.832 0.779 0.813 0.517

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
38/99 1.97G 0.03854 0.04231 0.01123 94 416: 100% 110/110 [00:20:00:00, 5.50it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:04:00:00, 3.95it/s]
all 505 2409 0.846 0.778 0.82 0.512

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
39/99 1.97G 0.03838 0.04229 0.01109 95 416: 100% 110/110 [00:18:00:00, 5.97it/s]
Class Images Instances P R mAP50 mAP50-95: 100% 16/16 [00:05:00:00, 3.17it/s]
all 505 2409 0.861 0.786 0.824 0.53

Epoch GPU_mem box_loss obj_loss cls_loss Instances Size
40/99 1.97G 0.03801 0.042 0.01089 127 416: 65% 72/110 [00:12:00:00, 4.09it/s]

```

▼ Evaluate Custom YOLOv5 Detector Performance