

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE İŞ SAĞLIĞI VE GÜVENLİĞİ
UYGULAMALARI

İlkay GİRGIN

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2023

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

MAKİNE ÖĞRENMESİ İLE İŞ SAĞLIĞI VE GÜVENLİĞİ UYGULAMALARI

İlkay GİRGIN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Mehmet Serdar GÜZEL

Uluslararası Çalışma Örgütü (ILO)'nun yayınladığı son rapora göre yılda 374 milyon işçi ölümcül olmayan kazalara maruz kalırken, 2,78 milyon işçi ise hayatını kaybetmektedir. Yaşanan kazaların çoğu, insan hatası, eksik bilgi, eksik hazırlık, rahatsız ya da yorgun iken çalışma ve güvenlik prosedürlerinin tam olarak uygulanmamasından kaynaklanmaktadır. Son yıllarda çok önemli gelişmeler gösteren makine öğrenmesi çalışmalarının katkıları ile insan tarafından kolaylıkla tespit edilemeyecek işyeri güvenliği ihlallerini tespit edecek, raporlayacak, alarm üretilip gerekli önlemleri alabilecek modeller eğitilerek bu alanlarda kullanılmakta, böylece yaralanma ve ölümlerin önüne geçilebilmektedir. Bu çalışmada iş sağlığı ve güvenliği alanında makine öğrenmesi uygulamaları ve çeşitleri ile kullanım alanları incelenmiş, kişisel koruyucu ekipman modellerinin eğitiminde kullanılan dört farklı özellikte veri seti seçilerek bu veri setleri üzerinde YOLOv5, YOLOv7 ve YOLOv8 mimarileri ile aktarımlı olarak eğitilen modeller karşılaştırmalı olarak incelenmiştir. Farklı veri setleri üzerinde YOLO mimarileri ile gerçekleştirilen eğitimler sonucunda YOLOv8 mimarisinin genel olarak YOLOv5 ve YOLOv7 mimarilerinden daha iyi sonuçlar verdiği, YOLOv7 modelinin ise yüksek çözünürlüklü görüntüler içeren veri setinde daha iyi sonuçlar verdiği tespit edilmiştir. Makine öğrenmesi modellerinin başarısını etkileyen en önemli etmenlerden olan hiper-parametrelerin, optimizasyon problemlerinin çözümünde etkili olarak kullanılan genetik algoritma kullanılarak YOLOv5 ve YOLOv7 mimarisinde CHV veri seti üzerinde optimize edilmiş ve YOLOv5 için standart hiper-parametrelere göre insan tespitinde mAP doğruluk değeri %96.3'ten %97.4'e, precision değeri % 92.1'den %92.6'ya ve YOLOv7 için AP ortalama doğruluk değeri %93.4'ten %96.3'e, F1-Skor değerinin %90'dan %94'e yükseltilmiş ve tüm değerlerde ortalama %3.34 daha başarılı sonuçlar elde edilmiştir.

Eylül 2023, 41 sayfa

Anahtar Kelimeler: Makine Öğrenmesi, İş Sağlığı ve Güvenliği, YOLO, Hiper-Parametre Optimizasyonu, Genetik Algoritmalar

ABSTRACT

Master Thesis

OCCUPATIONAL HEALTH AND SAFETY APPLICATIONS WITH MACHINE LEARNING

İlkay GİRGIN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Doç. Dr. Mehmet Serdar GÜZEL

According to the latest report published by the International Labor Organization (ILO), 374 million workers are exposed to non-fatal accidents, while 2.78 million workers die annually. Most of the accidents are caused by human error, lack of experience, incomplete preparation, working while feeling uncomfortable or tired and failure to fully implement safety procedures. With the contributions of machine learning studies, which have shown very important developments in recent years, injuries and deaths can be prevented by training models that can detect and report workplace safety violations that cannot be easily detected by humans, generate alarms and take the necessary precautions. In this study, machine learning applications and types and usage areas in the field of occupational health and safety were examined, four personal protective equipment datasets with different features selected and models trained on these datasets with YOLOv5, YOLOv7 and YOLOv8 architectures and results are compared. As a result of the trainings carried out with YOLO architectures on different datasets, it was determined that YOLOv8 architecture generally gave better results than YOLOv5 and YOLOv7 architectures, while the YOLOv7 model gave better results in the dataset containing high resolution images. Hyper-parameters, which are one of the most important factors affecting the success of machine learning models, were optimized on the CHV data set in YOLOv5 and YOLOv7 architectures by using the genetic algorithm used effectively in the solution of optimization problems, for YOLOv5 person detection mAP value changed from %96.3 to %97.4, precision value changed from %92.1 to %92.6 and for the YOLOv7 the average accuracy value of mAP was changed from 93.4% to 96.3%, F1-Score value was increased from 90% to 94% and average 3.34% more successful results were obtained in all values than standard hyper-parameters.

September 2023, 41 pages

Keywords: Machine Learning, Occupational Health and Safety, YOLO, Hyperparameter Optimization, Genetic Algorithms

TEŞEKKÜR

Yüksek Lisans eğitimimde bilgi ve tecrübesiyle tüm çalışma sürecimde yardım ve desteğini esirgemeyen, her zaman yol gösterici yaklaşımıyla motive eden saygıdeğer hocam Doç.Dr. Mehmet Serdar GÜZEL'e (Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı) saygı ve teşekkürlerimi sunarım.

Ayrıca tüm bu süreçte her koşulda yanımda olan ve hiç bir zaman desteğini esirgemeyen eşime, beni bu günlere getiren ve hep arkamda duran annem, babam ve kardeşime ve bu süreçte aramıza katılan ve motivasyon kaynağım olan minik güneşim oğlum Aren'e sonsuz teşekkürlerimi sunarım.

İlkay GİRĞİN
Ankara, Eylül 2023

İÇİNDEKİLER

TEZ ONAY SAYFASI	
ETİK.....	i
ÖZET.....	ii
ABSTRACT.....	iii
TEŞEKKÜR.....	iv
KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	viii
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ	3
2.1 İş Sağlığı ve Güvenliğinde Makine Öğrenmesi Uygulamaları.....	3
2.1.1 Kişisel koruyucu ekipman izleme uygulamaları	3
2.1.2 Tehlike tespiti uygulamaları.....	4
2.1.3 Sağlık izleme uygulamaları.....	5
2.1.4 Makine koruması uygulamaları.....	6
2.1.5 Yangın ve termal izleme uygulamaları.....	6
2.1.6 Mesafe izleme uygulamaları.....	7
2.2 Derin Öğrenme.....	8
2.3 Yapay Sinir Ağları.....	9
2.4 Evrişimli Sinir Ağları.....	10
2.5 YOLO Algoritması.....	11
2.6 Genetik Algoritma.....	14
3. MATERYAL VE YÖNTEM.....	17
3.1 Veri Setleri.....	17
3.2 Modellerin Eğitilmesi.....	19
3.2.1 SODA veri seti.....	20
3.2.2 CHV veri seti.....	22
3.2.3 GDUT-HWD veri seti.....	24
3.2.4 Harvard Hardhat veri seti.....	26
3.2.5 Genetik algoritma ile hiper-parametre optimizasyonu.....	28
4. TARTIŞMA VE SONUÇ.....	36
4.1 Modellerin Karşılaştırılması.....	36
4.2 Sonuç.....	36
KAYNAKLAR.....	38
ÖZGEÇMİŞ.....	41

KISALTMALAR DİZİNİ

CHV	Color Helmet Vest
CNN	Convolutional Neural Network
COCO	Common Objects in Context
CPU	Central Processing Unit
EU-OSHA	European Union Occupational Safety and Health Administration
GDUT-HWD	GDUT Hardhat Wearing Detection
GRNN	General Regression Neural Network
ILO	International Labour Organization
KKE	Kişisel Koruyucu Ekipman
LSTM	Long Short-Term Memory
OCD	Object Corelation Detection
R-CNN	Recursive Convolutional Neural Network
RAM	Random Access Memory
SODA	Site Object Detection Dataset
ST-GCN	Spatial-Temporal Graph Convolutional Network
VR	Virtual Reality
YSA	Yapay Sinir Ağları
WHO	World Health Organization
YOLO	You Only Look Once

ŞEKİLLER DİZİNİ

Şekil 2.1 Genel derin öğrenme sinir ağı yapısı	9
Şekil 2.2 Genel evrişimli sinir ağı yapısı	11
Şekil 2.3 YOLO mimarisi	12
Şekil 2.4 Genetik algoritma genel çalışma şeması.....	16
Şekil 3.1 Veri setleri görüntü örnekleri.....	19
Şekil 3.2 SODA veri seti YOLOv5x model eğitim grafikleri.....	21
Şekil 3.3 SODA veri seti YOLOv7 model eğitim grafikleri.....	21
Şekil 3.4 SODA veri seti YOLOv8 model eğitim grafikleri.....	22
Şekil 3.5 CHV veri seti YOLOv5x model eğitim grafikleri	23
Şekil 3.6 CHV veri seti YOLOv7 model eğitim grafikleri	23
Şekil 3.7 CHV veri seti YOLOv8 model eğitim grafikleri	24
Şekil 3.8 GDUT-HWD veri seti YOLOv5x model eğitim grafikleri.....	25
Şekil 3.9 GDUT-HWD veri seti YOLOv7 model eğitim grafikleri.....	25
Şekil 3.10 GDUT-HWD veri seti YOLOv8 model eğitim grafikleri.....	26
Şekil 3.11 Harvard Hardhat veri seti YOLOv5x model eğitim grafikleri.....	27
Şekil 3.12 Harvard Hardhat veri seti YOLOv7 model eğitim grafikleri.....	27
Şekil 3.13 Harvard Hardhat veri seti YOLOv8 model eğitim grafikleri.....	28
Şekil 3.14 CVH veri seti YOLOv5 genetik algoritma ile hiper-parametre optimizasyonu eğitim grafikleri.....	29
Şekil 3.15 CVH veri seti YOLOv7 genetik algoritma ile hiper-parametre optimizasyonu eğitim grafikleri.....	32

ÇİZELGELER DİZİNİ

Çizelge 2.1 YOLOv5, v7 ve v8 temel özellikleri.....	14
Çizelge 3.1 Veri setleri ve temel özellikleri.....	17
Çizelge 3.2 SODA veri seti model eğitim sonuç değerleri	21
Çizelge 3.3 CHV veri seti model eğitim sonuç değerleri.....	22
Çizelge 3.4 GDUT-HWD veri seti model eğitim sonuç değerleri	24
Çizelge 3.5 Harvard Hardhat veri seti model eğitim sonuç değerleri	26
Çizelge 3.6 YOLOv5 için ilk ve optimize edilmiş hiper-parametre değerleri	30
Çizelge 3.7 YOLOv7 için ilk ve optimize edilmiş hiper-parametre değerleri	33
Çizelge 3.8 CHV veri seti model eğitim sonuç değerleri(optimize).....	35

1. GİRİŞ

Endüstrinin en önemli yapı taşı olan işçilerin sağlığının ve güvenliğinin sağlanması bu alanda her zaman önemli bir konu olmuştur. Geçmişte bu alanda alınan belirli tedbirler olsa da bunlar işletme özelinde kalması ve denetlenmemesi nedeniyle iş kazaları ve yaralanmalar kaçınılmaz olmuştur. İş sağlığı ve güvenliğinin tüm dünyada önem kazanması ve iş sağlığı ve güvenliği konusunda kuralların ve prosedürlerin uluslararası kuruluşlar tarafından belirlenip kontrol edilmesiyle bu alanda hızlı bir ilerleme sağlanmıştır. İşletmeler çalışanları için güvenli ve sağlıklı bir çalışma ortamı sağlamak için gerekli tedbirleri alarak sorumluluklarını yerine getirmeye başlamışlardır. Önceleri iş sağlığı ve güvenliği ile ilgili çabalar daha çok el emeği işlerine yoğunlaşmıştır, ancak günümüzde tüm çalışanların fiziksel sağlığından, zihinsel sağlığına kadar kısa ve uzun vadeli tüm çevresel tehlikeleri kapsayacak şekilde genişletilmiştir. İş sağlığı ve güvenliği uygulamaları her geçen gün artmakla birlikte alınan tedbirler her zaman yeterli olmamaktadır. Tedbirlerin tam zamanlı olarak denetlenmesi ve olası tehlikelerin tespit edilmesi personelin gözle denetlenmesiyle sağlanamayacak kadar karmaşık ve zaman alan bir işlem haline gelmiştir. Bu nedenle tedbirlerin takip ve kontrolünün otomasyon ve bilgisayar sistemleri yapılması önem kazanmıştır.

Makine öğrenmesinin son zamanlardaki hızlı gelişimi birçok sektör ve alanda kullanılmaya başlaması ile birlikte daha da artmaktadır. Tüm alanlarda olduğu gibi iş sağlığı ve güvenliği alanında da makine öğrenmesi teknikleri kullanılarak bu alandaki ihtiyaçların da karşılanması mümkün hale gelmiştir. Makine öğrenmesi metotları ve alt dalları kullanılarak işyerinde ortaya çıkabilecek ve işçinin sağlık ve güvenliğini etkileyebilecek durumların hem tahmin edilerek gerekli tedbirlerin çok daha önceden alınabilmekte, hem de kısa sürede tespit edilerek oluşabilecek riskler ortadan kaldırılabilmekte veya en kısa sürede gerekli destek ve yardım sağlanabilmektedir. İnsan gözü ile tespit edilemeyecek riskler gerçek zamanlı olarak izlenerek eksik ve hatalar tespit edilip personel uyarılabilmekte, gerektiğinde iş makineleri durdurularak kazaların oluşması engellenebilmektedir. Makine öğrenmesi ile birlikte geçmişte yaşanan kazalar ve hatalar ayrıntılı olarak analiz edilerek risk yönetimi yapılabilmekte ve riskler oluşmadan yöneticilerin tedbir almalarına imkan sağlanabilmektedir. Bu

alandanda oluřan ihtiyalar da deęerlendirilerek bir ok alıřma yapılmıř olup, alıřmaların inřaat alanında yoęunlařtıęı grlmektedir.

Bu tez alıřmasında iř saęlıęı ve gvenlięi alanında kullanılan kiřisel koruyucu ekipmanlar nesne tespit algoritmaları ile llp llemeyeceęi arařtırma sorusundan yola ıkarak, iř saęlıęı ve gvenlięi maksadıyla kullanılan kiřisel koruyucu ekipmanlar makine ęrenmesi tabanlı modellerle tespit edilebilir, hipotezi iřlenmiřtir. Tezin amacı, tehlikeli olabilecek iř alanlarında alıřanların iř saęlıęı ve gvenlięi tedbiri olarak alıřanları ve kiřisel koruyucu ekipmanlarının tespit edilmesinde gncel nesne tespit algoritmalarından olan YOLOv5, YOLOv7 ve YOLOv8 algoritmaları ile drt farklı veri seti zerinde eęitilen modellerin bařarı, avantaj ve dezavantajlarının ortaya konulması ve rneklem olarak seilen bir veri seti zerinden, YOLOv5 ve YOLOv7 algoritmalarının hiper-parametreleri zerinde genetik algoritma kullanılarak hiper-parametre optimizasyonunun yapılması ile kiřisel koruyucu ekipman tespit bařarısının artırılmasıdır.

2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ

2.1 İş Sağlığı ve Güvenliğinde Makine Öğrenmesi Uygulamaları

2.1.1 Kişisel koruyucu ekipman izleme uygulamaları

Kişisel koruyucu ekipmanlar, çalışanı çalışma ortamında oluşabilecek risklere ve kazalara karşı koruyan, kazanın yaralanma ve ölümle sonuçlanmasının önüne geçmeyi hedefleyen ekipmanlardır. Bunlar işin yapısına göre belirlenmekle birlikte, koruyucu başlık, eldiven, gözlük, yelek, bot vb. ekipmanlardan oluşurlar. İnşaat alanlarında kullanılan ve çalışanların kafalarını muhtemel darbelerden koruyan koruyucu başlık, inşaat alanlarında ölümle sonuçlanan kazaların en sık karşılaşılan tramvatic beyin yaralanmalarının önüne geçmek için kullanılmaktadır. Bu nedenle tüm inşaat alanlarına girişte koruyucu başlık kullanımı inşaat alanına giren herkes için zorunlu tutulmaktadır. Ancak bilinçli yada bilinçsiz olarak gerçekleşebilecek ihmallere karşı, personelin gerekli ekipmanları sürekli kullandığı takip ve kontrol edilmelidir. Bu amaçla özellikle inşaat alanlarında gerçek zamanlı olarak personeli izleyerek koruyucu ekipman kullanımını kontrol edecek ve ihlal durumunda sorumlu personeli ikaz edecek sistemlere ihtiyaç duyulmaktadır. Bu alanda yapılan çalışmalarda, kamera görüntüleri kullanılarak etiketlenen görüntüler ile makine öğrenmesi yöntemleri ile eğitilen modeller kullanılarak gerçek zamanlı koruyucu ekipman kontrolü gerçekleştirilebilmektedir. Bu çalışmalar makine öğrenmesi teknikleri kullanılarak personelin sağlığı ve güvenliği için kullanması zorunlu olan ekipmanları sürekli kullandığının, dalgınlık ve ihmal sonucunda bu ekipmanların eksikliğinin tespit edilmesine dayanmaktadır.

Yu vd. (2022) tarafından yapılan, işçinin kişisel koruyucu ekipmanlarını gerçek zamanlı olarak hibrit makine öğrenmesi teknikleri kullanarak tespit etmeyi hedefleyen çalışmada, üç farklı CNN (Convolutional Neural Network) tabanlı derin öğrenme tekniği işçinin yerinin tespiti, nesne sınıflandırma ve ince özelliklerin tespiti için kullanılmıştır. Bu teknikler Faster-R CNN, YOLO ve DenseNet'tir. Yapılan testlerde

%95 oranında Hatırlama ve %90 oranında kesinlik ile yüksek bir tespit oranına ulaşılmıştır.

Nath vd. (2020) tarafından yapılan, derin öğrenme teknikleri ile kişisel koruyucu ekipman tespiti yapmayı amaçlayan çalışmada YOLO mimarisine bağlı üç ayrı derin öğrenme yöntemi kullanılarak yapılan çalışmada, ilk yaklaşımda önce işçileri, ve kişisel koruyucu ekipmanları tespit edip ardından işçinin kişisel koruyucu ekipmanları uygun bir şekilde giydiğinin kontrolü yapılmış. İkinci yaklaşımda algoritma eş zamanlı olarak hem işçiyi tespit edip hem de kişisel koruyucu ekipman uygunluğunu tek bir CNN yapısı kullanarak kontrol etmektedir. Üçüncü yaklaşımda ise görüntüde önce sadece işçiler tespit edilip kırılarak, CNN tabanlı sınıflandırıcılar kullanılarak görüntülerin kişisel koruyucu ekipman varlığına göre sınıflandırılmaktadır. Çalışmada ikinci yaklaşımın %72.3 ortama hassaslıkla tespit yapabildiği görülmüştür.

2.1.2 Tehlike tespiti uygulamaları

İş yerlerinde, çalışan işçilerin sağlığını tehdit edebilecek bir çok risk faktörü bulunmaktadır. İş makineleri, tezgahlar, kesici ekipmanlar, yüksekte çalışma, uygun olmayan zeminler ve araçlar bu risklerden bazılarıdır. İş yerlerinde işçinin güvenliğinin sağlanması için bu risklerin oluşturabilecekleri tehlikelerin gerçek zamanlı olarak izlenebilmesi ve tespit edilebilir olması, işçi sağlığının korunması için büyük önem taşımaktadır. Bu maksatla tehlikeli olabilecek durumların izlenmesi ve tespit edilebilmesi için makine öğrenmesi metotları kullanan sistemler geliştirilmekte ve kullanılmaktadır. Tehlike tespiti kapsamında, makinelerin hareket alanında bulunan bölgelere canlı geçişinin tespiti, yüksekte yada iskele üzerinde çalışan personel için güvensiz olan davranışların tespiti gibi alanlarda geliştirilmiş metotlar kullanılmaktadır.

Isleyen vd. (2021) tarafından yapılan çalışmada madenlerde tavan çökmesi konusunu ele alınmış olup, jeolojik nedenlerle madenlerde sıklıkla karşılaşılabilen ve can ve mal kayıplarına yol açabilecek tavan çökmesinin önceden tespit edilebilmesi için, tehlikeli ve tehlikeli olmayan koşullara ait görüntüler kullanılarak bir CNN mimarisi

geliştirilmiştir. Bu mimari ile yapılan testlerde tehlikeli görüntüleri tespit edilmesinde %86.4 başarı sağlanmıştır.

İnşaat endüstrisinde meydana gelen kazaların büyük çoğunluğu yüksekte çalışmaktan kaynaklı, yüksekte düşme problemidir. Yüksekte iskele üzerinde çalışanların durumlarının izlenmesi ve tehlikeli davranışların tespit edilmesi kazaların önüne geçebilir. Khan vd. (2021) tarafından yapılan çalışmada güvenli olmayan davranışların tespit edilebilmesi için korelasyon tabanlı bir yaklaşım önerilmiştir. Derin sinir ağı ve mask R-CNN (Recursive Convolutional Neural Network) metotları ile işçinin tespit edilmesi ve ayrıştırılması sağlanırken aynı zamanda Nesne Korelasyon Tespit (OCD) Modülü ile güvenli ve güvenli olmayan davranışları tespit edilmektedir. Bu çalışmada işçinin güvenli olmayan davranışlarının tespit edilmesinde %86 başarı sağlanmıştır.

2.1.3 Sağlık izleme uygulamaları

İş sağlığı ve güvenliği uygulamalarının temelini oluşturan işçilerin sağlığının korunması konusunda önemli hususlardan birisi de işçinin beden sağlığının korunması ve takip edilmesidir. İş esnasında vücuda fazla yük binmesi, hava ve oksijen koşullarının sağlıksız olması, kas yapısı ve fiziksel yapıyı zorlayacak hareketlerde bulunulması, aşırı yorgunluk gibi işçinin sağlığını ve hayatını tehlikeye düşürecek durumların izlenmesi de iş sağlığı ve güvenliğini pekiştirecek uygulamalardır. Bu maksatlarla kullanılacak makine öğrenmesi tabanlı izleme ve tespit uygulamaları, birçok tehdit ve tehlikenin erken önlenmesine fayda sağlayacaktır. Sağlık izleme çalışmaları genel olarak işçinin üzerinde bulunabilecek giyilebilir teknolojiler olabileceği gibi, görüntü tabanlı tespit yapabilen kamera sistemleri de kullanılabilmektedir.

Papoutsakis vd. (2022) tarafından yapılan, otomobil montaj fabrikasında çalışan işçilerinin maruz kaldığı fiziksel yük ve yorgunluğunu tespit edilmesini amaçlayan çalışmada, görsel veriler kullanılarak işçilerin bedensel duruşlarının ergonomik olarak uygunluğunun tespiti ile senkronize olarak kalp atış hızı ile korelasyonu değerlendirilerek, sağlıksız beden pozisyonlarının tespiti sağlanmıştır. Görsel verilerin sınıflandırılmasında beden pozisyonlarının tespit edebilmek için kullanılan ST-GCN

(Spatial-Temporal Graph Convolutional Network) modeli kullanılmıştır. Kalp atış hızının tahmin edilmesinde ise LSTM (Long Short-Term Memory) sinir ağı kullanılmıştır.

Wu vd. (2021) tarafından yapılan, eğitim ve müsabakalarda sporcuların sakatlıklarının önlenmesi için sağlık durumlarının gerçek zamanlı olarak izlenmesi ve değerlendirilmesi için deep learning tabanlı bir izleme ve tespit sisteminin önerildiği çalışmada, giyilebilir sağlık cihazlarından alınan veriler derin sinir ağı algoritmaları kullanılarak analiz edilip gerektiğinde uygun tedavi ve tespitlerin yapılmasına yardımcı olmaktadır.

2.1.4 Makine koruması uygulamaları

İş makinesi ve tezgahları endüstrinin neredeyse tüm alanlarında kullanılmakta ve üretime sürat ve kolaylık sağlamaktadır. Ancak bu araçlar aynı zamanda birçok tehlikeli parça ve ekipmanı da üzerlerinde bulundurmaktadır. Bu makineler ile birlikte çalışan işçilerin sebep olabileceği insan hatası veya makinelerde meydana gelebilecek arızalardan kaynaklanan hatalar iş sağlığı ve güvenliği tehditleri oluşturabilmektedir. Bu maksatla her makinenin kendine özgü güvenlik önlemleri ve kullanım prosedürleri bulunmaktadır. Ancak bu prosedürlerin doğru olarak uygulandığının kontrol edilmesi ve izlenmesi insan hatasından kaynaklanabilecek kazaların önüne geçebilecektir. Kesici ve yaralayıcı parçalar bulunduran makinelerin emniyetsiz bölgelerinin izlenmesi, hareketli parçaların hareket alanlarının izlenmesi, insan sağlığına zarar verebilecek ısı ve gaz üreten makinelerin tehlikeli bölgelerinin izlenmesi bu durumlara örnek olarak gösterilebilir.

Moreno-Rabel (2016) tarafından yapılan çalışmada, makine erişim kontrolü ve makine devir takibi yaparak makine güvenliği sağlanması amaçlanmıştır. Gerçek zamanlı güvenlik alanı görüntülerinden CVS (Computer Vision System) kullanılarak analizinin yapılması ile, izlenen alana giren canlı ve nesnelerin tespit edilmesi, makinenin devir takibi, uyarı ve alarm sinyal yönetimi yapılarak, makinenin yalnızca tüm işyeri koşulları

sağlandığında çalışmasına devam etmesinin sağlanması görevlerini yerine getirmektedir.

2.1.5 Yangın ve termal izleme uygulamaları

İş sağlığı ve güvenliği açısından en büyük tehditlerden biri de tüm çalışanların hayatını olumsuz etkileyebilecek can ve mal kaybına sebep olabilecek olan yangınlardır. Yangınların erken tespit edilmesi olası zararları engelleyebilecektir. Bu amaçla yapılmış birçok yangın tespit ve söndürme sistemleri yaygın olarak kullanılmaktadır. Bu alanda makine öğrenmesi uygulamaları ile verilerin analiz edilmesi ile karar verme sistemlerinin yönetimi ile yangının gerçek mi yoksa yanlış alarm mı olduğunun tespit edilmesi, yangının büyüklüğü ve ilerleme yönü gibi klasik sistemlerin sağlayamayacağı verilerin analiz edilerek karar verilmesi ve önlemlerin alınması açısından önem taşımaktadır.

Lee (2010) tarafından yapılan çalışmada GRNN (General Regression Neural Network) ile oluşturulan model ile yangının karakteristiklerinin tespit edilmesinde %94.5 başarı elde edilmiştir.

Yang vd. (2019) tarafından yapılan çalışmada, güvenlik kameralarından alınan gerçek zamanlı görüntüler kullanılarak CNN ile geliştirilen model ile yangın tespit ve uyarı sistemi oluşturulmuştur. Pahalı sensörlerin kullanılması yerine mevcut kamera görüntülerinden renk spektrumlarından yangın tespiti amaçlanarak geliştirilen model ile gerçek zamanlı görüntülerde %95.4 başarı ile yangın tespiti gerçekleştirilmiştir.

2.1.6 Mesafe izleme uygulamaları

Özellikle geniş inşaat alanlarında büyük iş makineleri ve kamyonlar kullanılmaktadır. Bu iş makineleri büyük boyutları ve hareket kabiliyetleri nedeniyle hem diğer araçlar hemde işçiler için tehlike arz etmektedirler. Aynı zamanda görüş alanlarının kısıtlı olması da bu tehlikeyi artırmaktadır. Kazaların önlenmesi için gerekli iş sağlığı ve güvenliği önlemleri alınmış olsa dahi, bir anlık dikkatsizlik can ve mal kayıplarına yol

açabilmektedir. İnşaat alanında bu hareketlerin izlenmesi ve tehlikeli hareketlerin tespit edilmesi ile kazaların önüne geçilebilecektir. Makine öğrenmesi teknikleri ile inşaat alanları görüntülerinden işçi-makine ve makine-makine mesafe izlemesi ve hareket tespiti yapılarak olumsuz durumlar önceden tespit edilerek kazalar önlenmektedir.


Bang vd. (2021) tarafından yapılan çalışmada, insansız hava aracı kullanılarak alınan video görüntülerinden mask R-CNN ile nesne ayrıştırması ve LSTM ile future frame tahmini yapılarak, hem gelecek hareketlerin tahmini hem de mesafe izlemesi yapılarak tehlikelerin önceden tahmin edilmesi ve erken uyarı yapılabilmesi amaçlanmıştır. Video görüntülerinden alınan görüntülerle eğitilen modelin nesneleri %94.3 başarı ile tespit ettiği ve % 81.2 başarı ile future frame tahmini yaptığı ve önleyici güvenlik bilgisi ve uyarı için etkili bir yöntem olduğu görülmüştür.

Mesafe izlemenin son dönemde önemli sağlık sorunlarından olan Covid-19 için de iş sağlığı ve güvenliği açısından kullanıldığı çalışmalar bulunmaktadır. Hızla yayılabildiği için kalabalık işyerlerinde alınan koruyucu tedbirlerin yanı sıra korunmak için gerekli mesafenin korunduğunun izlenmesi de ihtiyaç olmuştur. Kaiser vd. (2021) tarafından yapılan çalışmada bir cep telefonu uygulaması geliştirilmiş ve telefonlarda bulunan bluetooth teknolojisi kullanılarak K-Nearest Neighbor ve K-Means teknikleri ile personelin birbirine olan mesafesi ve temasları takip edilmesine imkan sağlanmıştır. Toplanan veriler ile test sonuçları ve sağlık durumları da eklenerek etkili bir takip ve önleme sistemi oluşturulmuştur.

2.2 Derin Öğrenme

Derin öğrenme, karmaşık yapıya sahip sorunların modellenmesi ve çözülmesi için yapay sinir ağlarını (YSA) kullanır ve makine öğreniminin hızla gelişen bir alt alanıdır. YSA'lar, kendisine girdi olarak verilen bilgiyi insan beynindeki nöronların bilgiyi işleme biçimine benzer şekilde işleyen birbirine bağlı düğümlerden oluşur. Derin öğrenme, çoklu işlem katmanlarından oluşan hesaplamalı modellerin, birden çok soyutlama düzeyine sahip verilerin temsillerini öğrenmesine olanak tanır (LeCun vd.

2015). Bir derin öğrenme sinir ağı giriş, gizli ve çıkış katmanı olmaz üzere üç katmandan oluşur (Şekil 2.1).



Şekil 2.1 Genel derin öğrenme sinir ağı yapısı

Derin öğrenmenin en önemli faydalarından biri ham verilerden özellikleri otomatik olarak çıkarma yeteneğidir. Krizhevsky vd. (2012) tarafından yapılan bir araştırma, derin öğrenme algoritmalarının görüntü sınıflandırma, konuşma tanıma ve doğal dil işleme dahil olmak üzere çeşitli alanlarda son teknoloji sonuçlara ulaştığını buldu. Bu, sürücüsüz arabalar, sanal asistanlar ve kişiselleştirilmiş tıbbi teşhis gibi birçok yenilikçi uygulamanın geliştirilmesine yol açmıştır.

Derin öğrenme modellerinin eğitimi genellikle büyük miktarda etiketlenmiş veri ve güçlü bilgi işlem kaynakları gerektirir. Derin öğrenme algoritmalarının başarısı, büyük ölçüde, büyük miktarlarda etiketlenmiş verinin bulunmasına ve eğitim için güçlü işlem kaynaklarının kullanılmasına bağlıdır (Goodfellow vd. 2016). Bu zorluğun üstesinden gelebilmek için derin pekiştirmeli öğrenme, denetimsiz öğrenme ve transfer öğrenme dahil olmak üzere derin öğrenme modellerini eğitmek için birçok yeni teknik geliştirildi.

2.3 Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin işlevinden ve çalışma şeklinden ilham alan bir makine öğrenimesi algoritmasıdır. YSA'lar, girdiler ve çıktılar arasındaki ilişkilere göre


bilgileri işleyen ve ve bunlarla ilgili tahminler yapan, birbirine bağlı düğüm veya yapay nöronlardan oluşmaktadır. Yapay sinir ağlarının geliştirilmesindeki birincil motivasyon, beynin nasıl çalıştığını anlama ve bu bilgiyi akıllı makineler oluşturmak için kullanma arzusudur (Rumelhart vd. 1986).

YSA'lar, başta görüntü sınıflandırma, konuşma tanıma ve doğal dil işleme dahil olmak üzere çok çeşitli sorunların çözümünde kullanılabilir. YSA'ların en önemli güçlerinden biri, verilerden öğrenebilmesi ve zamanla tahminlerini geliştirerek iyileştirme yetenekleridir. Sinir ağlarını eğitmek için kullanılan öğrenme algoritmaları, girdi verilerinin yararlı temsillerini otomatik olarak keşfederek ağın büyük miktarda eğitim verisinden görevleri nasıl gerçekleştireceğini öğrenmesine olanak tanımaktadır (LeCun vd. 2015).

Başta ileri beslemeli ağlar, tekrarlayan ağlar ve evrişimli ağlar dahil olmak üzere birkaç çeşit yapay sinir ağı bulunmaktadır. İleri beslemeli ağlar, YSA'nın en temel türüdür ve konuşma tanıma ve görüntü sınıflandırma gibi görevlerin uygulanmasında kullanılır. Tekrarlayan ağlar, sıralı verileri işleyebildikleri ve zaman içinde bilgileri koruyabildikleri için dil modelleme ve konuşma sentezi gibi görevler için kullanılır. Özelliklerin uzamsal hiyerarşilerini otomatik olarak öğrenmek için tasarlandıklarından, evrişimli ağlar görüntü tanıma görevleri için kullanılır.

2.4 Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (CNN'ler), özellikle görüntü tanıma görevleri için çok uygun olan bir tür yapay sinir ağıdır. CNN'lerin arkasındaki ana fikir, giriş verilerinin özelliklerini otomatik olarak öğrenmek için evrişimli katmanları kullanmaktır. Bu özellikler daha sonra bir tahmin yapmak için ek katmanlardan geçirilir (Şekil 2.2).



Şekil 2.2 Genel evrişimli sinir ağı yapısı(Sasha S. 2018)

Girdi verilerini taramak ve önemli özellikleri çıkarmak için filtreler kullanan evrişimli katmanların kullanılması CNN'lerin en önemli özelliklerindendir. Bu filtreler girdi verileri boyunca ilerler ve bir görüntüdeki kenarlar ve dokular gibi yerel özellikleri ayıklamak için bir nokta çarpım işlemi uygular. Evrişimli ağlar, girdinin verilerde bulunan yapıyı tanımak için yerel işlemeyi gerektiren bir görüntü olduğu gerçeğini hesaba kattıkları için diğer derin ağlara biyolojik olarak daha makul bir alternatiftir (Krizhevsky vd. 2012).


CNN'lerin bir diğer önemli özelliği, verilerin mekansal boyutunu azaltmak için kullanılan havuzlama katmanlarının kullanılmasıdır. Bu, hesaplama maliyetini azaltır ve fazla uyumu önlemeye yardımcı olur. Havuz katmanları, ağıdaki parametre ve hesaplama miktarını azaltmak için temsilin uzamsal boyutunu kademeli olarak azaltmaya ve dolayısıyla genellemeyi kolaylaştırmaya hizmet eder (Zeiler vd. 2014).

2.5 YOLO Algoritması

YOLO (Yalnızca Bir Kez Bakarsın), nesne algılamayı gerçek zamanlı olarak gerçekleştirmek için tek bir sinir ağı kullanan bir nesne algılama algoritmasıdır. YOLO, 2016 yılında Redmon ve diğerleri tarafından tanıtılmıştır. (Redmon vd, 2016). Tek bir sinir ağı olması ve bölgesel teklif ağını (RPN) atlaması, Mask R-CNN ile YOLO çerçevesi arasındaki en önemli farktır. Bu RPN, her konumdaki nesnelerin konumlarını ve sınıflarını tahmin etmek için kullanılır. Bu nedenle Mask R-CNN, çok aşamalı bir

nesne algılama algoritmasıdır. Algoritma, bir görüntüyü bir hücre ızgarasına bölerek ve görüntüdeki nesnelerin varlığını ve konumunu tahmin etmek için her bir hücreyi kullanarak çalışır. Bu, YOLO'nun tek bir geçişte tahmin yapmasına izin vererek, tahmin yapmak için birden fazla geçiş gerektiren diğer nesne algılama algoritmalarından daha hızlı olmasını sağlar. Çok aşamalı Mask R-CNN algoritmasından farklı olarak YOLO, algılanan nesneler için sınırlayıcı kutuların hem sınıflandırılmasını hem de hesaplanmasını tek bir aşamada gerçekleştirmesi nedeniyle YOLO, Mask R-CNN gibi çok aşamalı nesne algılama ağlarından önemli ölçüde daha hızlıdır (Zhang vd., 2021).

YOLO'nun değişen boyut ve en boy oranlarındaki nesneleri algılamasını sağlamak için, giriş görüntüsü bir hücre ızgarasına bölünür. Her hücre, o hücrede ortalanmış olan nesnelerin algılanmasından sorumludur. YOLO daha sonra hücrenin konumu ve boyutuna göre sınırlayıcı kutu koordinatlarının yanı sıra o hücredeki her nesne için sınıf olasılıklarını tahmin eder. Ek olarak YOLO, tahmin edilen nesnellik olasılığının ve tahmin edilen sınırlayıcı kutunun yer gerçeği sınırlayıcı kutusuyla birleşim üzerinden kesişiminin (IoU) ürünü olan güven puanını tahmin eder. YOLO mimarisi şekil 2.3'te gösterilmiştir.



Şekil 2.3 YOLO Mimarisi (Redmon vd. 2016)

YOLO'nun ana avantajlarından biri hızıdır. Ağ üzerinden tek bir geçişte nesne algılama ve sınıflandırma gerçekleştiren YOLO, yüksek doğrulukla gerçek zamanlı nesne

algılama yeteneğine sahiptir. Ancak YOLO, küçük nesneleri veya yoğun bir şekilde paketlenmiş nesneleri algılamada sınırlamalara sahiptir. Bu sınırlamalar, birkaç kıyaslama veri setinde YOLOv5 dahil olmak üzere, algoritmada yapılan çeşitli güncellemeler ve iyileştirmelerle giderilmiştir.

YOLO'nun beşinci sürümüdür ve YOLOv4'ten bir kaç ay sonra 2020'de Ultralytics tarafından kullanıma sunulan YOLOv5, YOLO'nun önceki sürümlerine kıyasla doğruluğu ve hızı iyileştirmiştir bir versiyonudur (Jocher 2020). YOLOv5'teki önemli iyileştirmelerden bazıları, modelin sağlamlığını artıran mozaik veri büyütme ve modelin doğruluğunu artıran AutoAnchor adlı algoritmanın kullanılmasıdır.

YOLOv7 ise YOLO'nun yedinci versiyonudur ve 2022'de yayınlanmıştır (Wang vd. 2022). Wang'a (2022) göre YOLOv7, YOLOv5'e kıyasla daha iyi doğruluk ve hıza sahiptir. YOLOv7'deki önemli iyileştirmelerden bazıları, daha verimli ve daha küçük bir bellek alanına sahip olan yeni bir omurga ağının kullanımını ve modelin doğruluğunu artıran yeni bir bağlantı tasarımının kullanılmasıdır.

YOLOv8 ise önceki sürümlerin güçlü yanlarını kullanarak nesne tespitin doğruluğunu ve hızını artırmak için geliştirilmiş bir YOLO algoritmasıdır. YOLOv8'in temel geliştirmelerinden biri, özellikle daha küçük nesneler için nesne tespitin hassasiyetini artıran daha büyük ve daha derin bir sinir ağı mimarisi kullanmasıdır. Ayrıca, YOLOv8, farklı sinir ağı katmanlarından özellikleri birleştirerek nesne tespit doğruluğunu artıran yeni bir özellik birleştirme tekniği olan Path Aggregation Network (PAN) içerir.

YOLOv8'in performansını değerlendirmek için, COCO (Common Objects in Context) veri kümesi üzerinde YOLOv7 ile bir karşılaştırma yapılmıştır. COCO veri kümesi, nesne tespiti sistemleri için yaygın olarak kullanılan bir referans noktasıdır. Yapılan karşılaştırma, YOLOv8'in 47.8% ortalama hassasiyet (mAP) elde ettiğini, YOLOv7'nin ise 45.6% mAP elde ettiğini gösterdi. Ayrıca, YOLOv8'in tek bir GPU üzerinde 90 kare/saniye işleme yapabilmesiyle %20 oranında bir hız artışı gösterdiği görülmüştür. Bu sonuçlar, YOLOv8'in hem doğruluk hem de hız açısından YOLOv7'ye kıyasla

önemli bir gelişme temsil ettiğini göstermektedir. YOLOv5, v7 ve v8 algoritmalarının temel özellikleri çizelge 2.1’de gösterilmiştir.

Çizelge 2.1 YOLOv5, v7 ve v8 temel özellikleri

Versiyon	Çıkış Yılı	Anchor	Framework	Backbone	AP(%) (COCO 2017)
YOLOv5	2020	var	Pytorch	YOLOv5CSPDarknet	55.8
YOLOv7	2022	yok	Pytorch	YOLOv7Backbone	56.8
YOLOv8	2023	yok	Pytorch	YOLOv8CSPDarknet	53.9

YOLOv8'deki iyileştirmelere rağmen, bazı araştırmacılar algoritmanın hala küçük nesneleri veya karmaşık şekilleri olan nesneleri tespit etmede sınırlamaları olduğunu belirtmişlerdir. YOLOv8'in, EfficientDet ve DETR gibi diğer en son nesne tespiti sistemleriyle karşılaştırılması, YOLOv8'in küçük nesneleri ve karmaşık şekilleri olan nesneleri tespit etmede zorlandığını göstermiştir. Bu bulgular, YOLOv8'in nesne tespiti teknolojisinde önemli bir ilerleme temsil ettiği halde, küçük ve karmaşık nesnelerin tespitiyle ilgili zorlukları ele almak için daha fazla araştırmanın gerekliliğini göstermektedir.

2.6 Genetik Algoritma


Genetik algoritmalar, geniş bir uygulama alanına sahip küresel optimizasyon yöntemlerine ait bir sınıftır. Genetik algoritmalar yapay sinir ağlarının yanı sıra matematik ve bilgisayar bilimlerinde disiplinler arası yaklaşımın kullanılmasına bir örnektir. Genetik algoritmanın temeli biyolojide evrim ve doğal seçim ve sürecini temel alır. Genetik algoritma konusu ilk olarak J. D. Bagley'nin bir çalışmasında ortaya çıkmıştır (Bagley, 1967). Genetik algoritmaların asıl teorisi ve uygulanabilirliği bu alanın öncüsü olarak kabul edilebilecek olan J. H. Holland'ın çalışmalarından etkilenmiştir (Holland, 1992). Genetik algoritmanın temellerinin atıldığı zamandan günümüze bu alanda ciddi gelişmeler yaşanmış, genetik algoritmalar birçok alanda uygulanmaya başlanmıştır. Genetik algoritmanın en önemli uygulama alanı sinir ağları

öğrenimi ve bulanık bilgi tabanı üretimi olsa da genetik algoritmalar; kontrol sistemleri, robot uygulamaları, görüntü ve ses tanıma, yapay zeka uygulamaları, yol bulma problemleri, süreç kontrolü, oyun teorisi, görüntü analizi, küme analizi, sosyal planlama, ekonomi ve finans gibi çok geniş alanlarda kullanılmaktadır.

Genetik algoritmaları sinir ağlarıyla kullanmanın, ağırlık öğrenme, mimari optimizasyonu ve öğrenme prosedürü optimizasyonu olmak üzere üç yolu vardır (Sharapov, 2007).

Genetik algoritmalar, genetik yapıyı örnek alan bir yaklaşımdır. Rastgele çözümler kümesi ile aramaya başlayıp başarılı olan aday çözümler tespit edilir ve bu aday çözümler geliştirilerek daha başarılı aday çözümler üretilir. Bu nedenle optimizasyon ve arama problemlerinin çözümünde sıklıkla kullanılır.

Bir genetik algoritma seçim, çaprazlama ve mutasyon olmak üzere üç operatöre sahiptir. Seçim yeni aday çözümler geliştirmek için aday çözümlerin seçilmesidir. Çaprazlama iki aday çözümün operatörlerini birleştirilerek, bu iki çözümün iyi özelliklerini taşıyan yeni bir aday çözüm üretilmesidir. Mutasyon ise aday çözüm içerisindeki bazı değerlerin değiştirilmesidir. Böylece daha farklı aday çözümler ortaya çıkarılabilmektedir. Genetik algoritma çalışma şeklini gösteren genel akış şeması şekil 2.4'te gösterilmiştir.



Şekil 2.4 Genetik algoritma genel çalışma şeması

Genetik algoritmalar basit, etkili ancak zaman alan bir yöntemdir ve araştırma problemlerinin çözümünde yoğun olarak kullanılmaktadır. Model hiperparametrelerinin en iyi değerlerini bulmak için de giderek daha popüler hale gelen bir yöntemdir. Makine öğrenmesinde kullanılan birçok modelin birden fazla hiperparametresi olduğu düşünüldüğünde, bu yöntem yüksek boyutlu arama alanlarında verimli bir şekilde araştırma yapma kabiliyeti sayesinde tercih edilmektedir.

3. MATERYAL VE YÖNTEM

3.1 Veri Setleri

Eğitilmiş bir modelin başarılı ve doğru sonuçlar vermesinde en önemli etken doğru ve beklenen hedef ile uyumlu veri setinin oluşturulması ya da seçilmesidir. Bu nedenle veri setinin seçilmesi ve beklenen hedefe uyumlu hale getirilmesi modelin başarısı açısından büyük önem taşımaktadır.

Kişisel koruyucu ekipman tespitinde kullanılan birçok seti oluşturulmuştur. Bu veri setlerinin birbirine benzer ve farklı yanları bulunmaktadır. Bu tezde kullanılan veri setleri ve temel özellikleri çizelge 3.1’de gösterilmiştir

Çizelge 3.1 Veri setleri ve temel özellikleri

Veri Seti	Görüntü Sayısı	Nesne Sayısı	Açıklama	Görüntü Boyutu
SODA	19846	286201	İnşaat sahasında bulunan 15 nesne sınıfından oluşmaktadır.	1920*1080 ve benzer boyutlar
CHV	1330	9209	İnsan, koruyucu yelek ve 4 farklı renkte koruyucu başlık sınıfından oluşmaktadır.	608*608
GDUT-HWD	3174	18893	4 farklı renk koruyucu başlık ve insan sınıflarından oluşmaktadır.	4256×2832 ve 180×180 aralığında değişken boyutlarda
Harvard	7065	26889	Kafa ve koruyucu başlık sınıflarından oluşmaktadır.	512*X

Bu tezde veri seti tercih edilirken, insan ve çeşitli koruyucu ekipmanları içermesi ve yüksek çözünürlüklü olması ve eğitimin verimli olabilmesi için yeterince nesne içermesidir. Bu kriterler değerlendirilerek bu 4 veri seti tercih edilmiştir.

SODA(Site Object Detection dAtaset) veri seti gerçek inşaat sahasından alınan 19,846 görüntü ve bu görüntülerde bulunan 286,201 nesneden oluşmaktadır (Duan vd. 2022).

Veri setinde insan, materyal, makine ve çevresel nesnelerden oluşan 15 ayrı nesne sınıfı bulunmaktadır.


Hedeflenen veri setinde insan ve kişisel koruyucu ekipmanlar bulunması gerektiğinden kullanılan veri setinden insan, koruyucu yelek ve koruyucu başlık olan görüntüler seçilerek ve seçilen görüntülerden diğer nesnelere ait etiketler kaldırılarak hedeflenen kullanıma uygun bir veri seti oluşturulmuştur, ayrıca hedeflenen tespit için yukarıdan çekilen görüntülerin karışıklık yaratacağı değerlendirilerek havadan ve vinç üzerinden alınan görüntüler çıkarılmıştır. SODA veri seti sadeleştirilerek 10594 görüntüden oluşan bir veri seti oluşturulmuştur. SODA veri setinin etiketlenmesinde Visual Object Classes (VOC) formatı kullanılmıştır. Ancak YOLOv5 ve YOLOv7 algoritmalarında txt uzantılı dosyalardan oluşan bir YOLO etiketleme formatı kullandığı için seçilen görüntülerin etiket formatları istenilen formata dönüştürülmüştür.

CHV(Color Helmet and Vest) veri seti ise KKE (Kişisel Koruyucu Ekipman) tespiti için insanı, yeleği ve dört kask rengini tespit etmek için internetten ve açık veri setlerinden alınan 10.000 görsel arasından sadece yüksek kaliteli 1.330 tanesi seçilerek oluşturulmuştur. Görüntülerde toplam 9209 adet nesne bulunmaktadır. (Wang vd. 2021)

GDUT-HWD (GDUT Hardhat Wearing Detection) veri setinde ise KKE tespiti için insan ve 4 farklı renk koruyucu başlık sınıflarından oluşan 3174 görselde 18893 nesneden oluşmaktadır (Jixiu vd. 2019).

Harvard Hardhat veri seti ise Harvard Dataverse veri seti kütüphanesinde bulunan ve 7065 görüntüde 26889 nesneden oluşmaktadır(Xie 2019). Veri setinde koruyucu başlık ve kafa sınıfları bulunmaktadır.

Her veri seti farklı çözünürlüklerde ve iş sahalarında bulunabilecek çeşitli KKE'ları içeren, yeterli sayıda nesne ve görüntüye sahip olması nedeniyle, çeşitli YOLO modellerinin eğitilerek karşılaştırılmasında kullanılmış olup her veri setinden örnek görüntüler şekil 3.1 'de gösterilmiştir.



(a)

(b)



(c)

(d)

Şekil 3.1 Veri setleri görüntü örnekleri; (a) SODA, (b) CHV, (c) GDUT-HWD, (d) Harvard Hardhat

3.2 Modellerin Eğitilmesi

Bu tezde insan ve kişisel koruyucu ekipmanların tespit edilmesi amacıyla farklı mimarideki modellerin eğitilmesi hedeflenmiştir. Bu hedef için kullanılacak dört adet veri seti belirlenmiş, veri setleri ve etiketleri uygun hale getirilmiştir. Bu aşamadan sonra insan ve kişisel koruyucu ekipmanların tespiti için YOLO modellerinin eğitilmesi ve precision, recall, F1 and mean average precision değerlerinin hesaplanması açıklanacaktır.

Nesne tespiti için kullanılan bir çok algoritma bulunmakta ve her geçen yıl daha yüksek başarı sağlayan algoritmalar ortaya çıkmaktadır. Bu tezde son yıllarda hızlı bir gelişim gösteren ve nesne tespitinde önemli başarılar sağlayan YOLO algoritması kullanılmış,

YOLO algoritmasının son yıllarda öne çıkan versiyonları olan YOLOv5, YOLOv7 ve YOLOv8 versiyonları kullanılarak eğitilen modeller ve başarıları hesaplanmıştır.

Eğitim ortamı olarak, kullanılan görüntülerin çözünürlükleri ve sayısı değerlendirilerek Colab Pro ortamı kullanılmıştır. Colab pro ortamında Intel(R) Xeon(R) CPU @ 2.30 GHz CPU, Tesla A100 16 GB grafik işlemci, 32 GB RAM özellikleri sağlanmıştır.

Nesne tespitinde en önemli aşamalardan biri modelin eğitilmesidir. Her veri setinde bulunan görüntüler %80 eğitim %10 doğrulama ve %10 test olacak şekilde ayrılmıştır. YOLOv7 algoritması 640 piksel çözünürlük için YOLOv7, YOLOv7-X modellerinden oluşmaktadır. YOLOv5 ise 640 piksel çözünürlük için YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x modellerinde oluşmakta olup, bu çalışmada YOLOv5x, YOLOv7 ve YOLOv8x modeli kullanılmıştır.


Bundan sonraki kısımda her veri seti için eğitilen modellere ait sonuçlar ve grafikler üzerinden karşılaştırması gösterilmiştir.

3.2.1 SODA veri seti


SODA veri seti ile model eğitimlerinde elde edilen sonuçlar çizelge 3.2’de, YOLOv5x model eğitim grafiği şekil 3.2’de, YOLOv7 model eğitim grafiği şekil 3.3’te, YOLOv8x model eğitim grafiği şekil 3.4’te gösterilmiştir. SODA veri seti, kullanılan veri setleri arasında çözünürlük bakımından en yüksek çözünürlüğe sahip ve tamamı gerçek iş sahasından elde edilmiş görüntülerden oluşan veri setidir. Eğitim sonuçları değerlendirildiğinde YOLOv7’nin tüm değerlendirmelerde YOLOv5 ve YOLOv8’e göre daha başarılı sonuçlar verdiği görülmektedir.

Çizelge 3.2 SODA veri seti model eğitim sonuç değerleri


Algoritma	mAP(%)				Precision	Recall	F1	FPS
	Kişi	Başlık	Yelek	Ortalama				
YOLOv5-x	91.7	78.4	74.5	81.5	89.7	72.6	0.80	21,3
YOLOv7	94	79.7	89.6	87.4	86.5	85.4	0.86	52,2
YOLOv8-x	92.8	75.8	84.6	84.4	85.5	79.4	0.82	24,6



Şekil 3.2 YOLOv5x model eğitim grafikleri



Şekil 3.3 YOLOv7 model eğitim grafikleri




Şekil 3.4 YOLOv8x model eğitim grafikleri

3.2.2 CHV veri seti


CHV veri seti ile model eğitimlerinde elde edilen sonuçlar çizelge 3.3'te, YOLOv5x model eğitim grafiği şekil 3.5'te, YOLOv7 model eğitim grafiği şekil 3.6'da, YOLOv8x model eğitim grafiği şekil 3.7'de gösterilmiştir. CHV veri setinde elde edilen sonuçlara göre tüm modellerde birbirine çok yakın sonuçlar çıkmış olsa da YOLOv5x modelinin diğer modellerden daha iyi sonuçlar elde ettiği görülmüştür. YOLOv8x ise YOLOv5x ile çok yakın sonuçlara sahip olduğu görülmüştür.

Çizelge 3.3 CHV veri seti model eğitim sonuç değerleri


Algoritma	mAP(%)				Precision	Recall	F1	FPS
	Kişi	Başlık	Yelek	Ortalama				
YOLOv5-x	96.3	97.5	93.3	95.7	92.1	93.5	0.93	19,1
YOLOv7	94.4	93.3	92.4	93.4	91	89.1	0.90	54,6
YOLOv8-x	95.7	97.1	93	95.7	92.4	92.7	0.93	20,1



Şekil 3.5 CHV, YOLOv5x model eğitim grafikleri



Şekil 3.6 CHV, YOLOv7 model eğitim grafikleri




Şekil 3.7 CHV, YOLOv8x model eğitim grafikleri

3.2.3 GDUT-HWD veri seti


GDUT-HWD veri seti ile model eğitimlerinde elde edilen sonuçlar çizelge 3.4'te, YOLOv5x model eğitim grafiği şekil 3.8'de, YOLOv7 model eğitim grafiği şekil 3.9'da, YOLOv8x model eğitim grafiği şekil 3.10'da gösterilmiştir. GDUT-HWD veri seti ile modellerin eğitiminden elde edilen sonuçlara göre YOLOv8x ile YOLOv5x modellerinin çok yakın sonuçlara sahip olduğu görülmüştür. YOLOv8 modeli %1 altındaki değerlerle YOLOv5 modelinden daha başarılı sonuçlar göstermiştir. YOLOv7 modeli ise daha düşük ve çeşitli çözünürlüğe sahip görüntülerden oluşan bu veri setinde daha düşük başarı gösterdiği görülmüştür.

Çizelge 3.4 GDUT-HWD veri seti model eğitim sonuç değerleri


Algoritma	mAP (%)					Precision	Recall	F1	FPS
	Mavi başlık	Beyaz başlık	Sarı başlık	Kırmızı başlık	Ort.				
YOLOv5-x	71.1	91.7	87.5	73.2	81,7	86.8	75.2	0.80	12,4
YOLOv7	55.7	82.5	72.1	52.3	64.8	81.8	57.9	0.67	47,8
YOLOv8-x	72.3	90.0	85.2	78.5	81.9	86.9	75.4	0.80	15,6



Şekil 3.8 GDUT-HWD, YOLOv5x model eğitim grafikleri



Şekil 3.9 GDUT-HWD, YOLOv7 model eğitim grafikleri




Şekil 3.10 GDUT-HWD, YOLOv8x model eğitim grafikleri

3.2.4 Harvard Hardhat veri seti


Harvard Hardhat veri seti ile model eğitimlerinde elde edilen sonuçlar çizelge 3.5'te, YOLOv5x model eğitim grafiği şekil 3.11'de, YOLOv7 model eğitim grafiği şekil 3.12'de, YOLOv8x model eğitim grafiği şekil 3.13'da gösterilmiştir. Harvard Hardhat veri setinde elde edilen sonuçlara göre tüm modellerde birbirine çok yakın sonuçlar çıkmış olsa da YOLOv5x modelinin diğer modellerden daha iyi sonuçlar elde ettiği görülmüştür. YOLOv8x ise YOLOv5x ile çok yakın sonuçlara sahip olduğu görülmüştür.

Çizelge 3.5 Harvard Hardhat veri seti model eğitim sonuç değerleri


Algoritma	mAP(%)			Precision	Recall	F1	FPS
	Kafa	Başlık	Ortalama				
YOLOv5-x	97.5	98.5	98	95.3	94.4	0.95	17,9
YOLOv7	96	92.7	94.3	92.2	92.9	0.93	46,1
YOLOv8-x	96.9	98.4	97.7	94.5	95.1	0.95	21,6



Şekil 3.11 Harvard Hardhat, YOLOv5x model eğitim grafikleri



Şekil 3.12 Harvard Hardhat, YOLOv7 model eğitim grafikleri




Şekil 3.13 Harvard Hardhat, YOLOv8x model eğitim grafikleri

3.2.5 Genetik algoritma ile hiper-parametre optimizasyonu

Genetik algoritma ile hiper-parametre optimizasyonu yapılarak, ilgili veri setinde daha başarılı sonuçlar veren bir model oluşturmak mümkündür. Bu süreçte ilgili veri seti model ile değişken hiper-parametreler kullanılarak eğitilmekte ve her jenerasyon sonucunda elde edilen değerlendirmeler ile değişen hiper-parametrelerle veri setinin başarısı ölçülmekte ve daha iyi sonuçlar veren hiper-parametre değerleri tespit edilebilmektedir. Bu tezde yukarıda model eğitim sonuçları verilen CHV veri seti üzerinde YOLOv5 ve YOLOv7 algoritmaları kullanılarak, genetik algoritma ile hiper-parametre optimizasyon çalışması yapılmıştır. YOLOv8 algoritması için genetik algoritma ile hiper-parametre optimizasyonu özelliği geliştirme aşamasında olduğundan YOLOv8 için optimizasyon çalışması yapılamamıştır.

YOLOv5 algoritması ile 300 jenerasyon üzerinden yapılan eğitim sonucunda oluşan hiper-parametre optimizasyon grafiği şekil 3.14'te gösterilmiştir.



Şekil 3.14 CVH veri seti YOLOv5 genetik algoritma ile hiper-parametre optimizasyonu eğitim grafikleri

Elde edilen yeni hiper-parametreler çizelge 3.6’da gösterilmiştir.


Çizelge 3.6 YOLOv5 için ilk ve optimize edilmiş hiper-parametre değerleri

Hiper-Parametre	İlk Değer	Genetik Algoritma ile optimize edilmiş değer
lr0	0.01	0.012
lrf	0.1	0.102
momentum	0.937	0.934
weight_decay	0.0005	0.00054
warmup_epochs	3.0	2.96
warmup_momentum	0.8	0.785
warmup_bias_lr	0.1	0.105
box	0.05	0.0377
cls	0.3	0.32
cls_pw	1.0	0.981
obj	0.7	0.679
obj_pw	1.0	0.981
iou_t	0.20	0.20
anchor_t	4.0	3.67
fl_gamma	0.0	0.0
hsv_h	0.015	0.0154
hsv_s	0.7	0.656

Çizelge 3.6 YOLOv5 için ilk ve optimize edilmiş hiper-parametre değerleri (devam)

Hiper-Parametre	İlk Değer	Genetik Algoritma ile optimize edilmiş değer
hsv_v	0.4	0.408
degrees	0.0	0.0
translate	0.1	0.0833
scale	0.9	0.865
shear	0.0	0.0
perspective	0.0	0.0
flipud	0.0	0.0
fliplr	0.5	0.5
mosaic	1.0	0.966
mixup	0.1	0.0842
copy_paste	0.0	0.0
anchors	0.0	2.44

YOLOv7 algoritması ile 300 jenerasyon üzerinden yapılan eğitim sonucunda oluşan hiper-parametre optimizasyon grafiği şekil 3.15'te gösterilmiştir.



Şekil 3.15 CVH veri seti YOLOv7 genetik algoritma ile hiper-parametre optimizasyonu eğitim grafikleri

Elde edilen yeni hiper-parametreler çizelge 3.7’de gösterilmiştir.

Çizelge 3.7 YOLOv7 için ilk ve optimize edilmiş hiper-parametre değerleri

Hiper-Parametre	İlk Değer	Genetik Algoritma ile optimize edilmiş değer
lr0	0.01	0.00902
lrf	0.1	0.13
momentum	0.937	0.929
weight_decay	0.0005	0.00071
warmup_epochs	3.0	2.61
warmup_momentum	0.8	0.95
warmup_bias_lr	0.1	0.165
box	0.05	0.04
cls	0.3	0.295
cls_pw	1.0	0.801
obj	0.7	0.416
obj_pw	1.0	1.3
iou_t	0.20	0.2
anchor_t	4.0	4.44
fl_gamma	0.0	0.0
hsv_h	0.015	0.015
hsv_s	0.7	0.64

Çizelge 3.7 YOLOv7 için ilk ve optimize edilmiş hiper-parametre değerleri (devam)

Hiper-Parametre	İlk Değer	Genetik Algoritma ile optimize edilmiş değer
hsv_v	0.4	0.268
degrees	0.0	0.0
translate	0.2	0.136
scale	0.5	0.614
shear	0.0	0.0
perspective	0.0	0.0
flipud	0.0	0.0
fliplr	0.5	0.513
mosaic	1.0	1.0
mixup	0.0	0.0
copy_paste	0.0	0.0
paste_in	0.0	0.0
anchors	0.0	2.26

Hiper-parametre optimizasyonu sonucunda elde edilen yeni hiper-parametreler kullanılarak yapılan model eğitimi sonucunda oluşan yeni YOLOv5 modeli eskisine göre ortalama olarak benzer sonuçlar verse de kişi tespitinde ve Precision değerlerinde daha başarılı sonuç vermiş, YOLOv7 modeli ise eskisinden ortalama %3,34 daha başarılı sonuç vermiştir. CHV veri seti üzerinde elde edilen sonuçlara genetik algoritma ile hiper-parametre optimizasyonu yapılmış sonuçların da dahil edildiği sonuçlar çizelge 3.8’de gösterilmiştir.

Çizelge 3.8 CHV veri seti model eğitim sonuç değerleri(optimize)

Algoritma	mAP(%)				Precision	Recall	F1	FPS
	Kişi	Başlık	Yelek	Ortalama				
YOLOv5-x	96.3	97.5	93.3	95.7	92.1	93.5	0.93	19,1
YOLOv5-x (optimize)	97.4	95.2	92.3	95	92.6	92.7	0.93	21,8
YOLOv7	94.4	93.3	92.4	93.4	91	89.1	0.90	54,6
YOLOv7 (optimize)	97.5	95.9	95.4	96.3	94.5	93.4	0.94	57.3
YOLOv8-x	95.7	97.1	93	95.7	92.4	92.7	0.93	20,1

Hiper-parametre optimizasyonu yapılmış YOLOv7 modelinin başarısının diğer iki modelin üzerine çıktığı görülmektedir. Böylece genetik algoritma kullanılarak yapılan hiper-parametre optimizasyonu ile daha başarılı bir model geliştirilmiştir.

4. TARTIŞMA VE SONUÇ

4.1 Modellerin Karşılaştırılması

Bu tezde YOLO algoritmasının son yıllarda yayınlanan son üç versiyonu olan YOLOv5, YOLOv7 ve YOLOv8 modelleri kişisel koruyucu ekipman tespitinde kullanılan farklı özelliklerde dört ayrı veri seti üzerinden eğitilerek karşılaştırılmıştır.

Yapılan karşılaştırmada, YOLOv7 modelinin eğitiminin diğer modellere göre daha çok zamanda tamamlandığı ancak yüksek çözünürlüklü verilerde daha yüksek başarı sağladığı görülmüştür. YOLOv7 modelinin diğer modellerden çok daha hızlı olduğu tespit FPS değerleri tespit edilmiştir.

YOLOv5 modelinin sonuçlarının, en son yayınlanan model olan YOLOv8 ile çok yakın sonuçlar verdiği, bazı veri setlerinde küçük farklar ile de olsa daha başarılı sonuçlar verdiği görülmüştür.

YOLOv8 modelinin ise Ocak 2023 tarihinde yayınlanması nedeniyle halen geliştirmelerinin devam ettiği ve YOLOv5 modeli ile çok yakın sonuçlara sahip olduğu görülmüştür.

Genetik algoritma kullanılarak gerçekleştirilen hiper-parametre optimizasyonu ile geliştirilen YOLOv7 modelinin optimizasyon sonrasında diğer modellerden daha başarılı sonuçlar elde ettiği görülmektedir.

4.2 Sonuç

Makine öğrenmesi teknikleri tüm alanlarda olduğu gibi iş sağlığı ve güvenliği alanında da büyük değişikliklere yol açmış ve iş sağlığı ve güvenliğinin ihtiyaç duyduğu bir çok alanda kullanılmaya devam edilmektedir.

Makine öğrenmesinin bu alanda en yoğun kullanımı da görüntü işleme ve nesne tespiti yapılarak kazaların önlenmesi ve iş sağlığı ve güvenliği uygulamalarının görüntü verileri kullanılarak kontrol altında tutulmasıdır. Bu amaçla görüntülerden kişisel koruyucu ekipmanların tespiti önemli bir yere sahiptir. Bu tezde kişisel koruyucu ekipmanların tespiti alanında, nesne tespitindeki hızı ve başarısı göz önünde bulundurularak YOLO algoritmasının YOLOv5, YOLOv7 ve YOLOv8 modelleri ile dört farklı veri seti eğitilmiş, sonuçları karşılaştırılmış, ayrıca genetik algoritma kullanılarak YOLO v5 ve YOLOv7 modeli CHV veri seti üzerinde hiper-parametre optimizasyonu gerçekleştirilmiştir.

Tüm bu çalışmalar sonucunda üç modelin farklı veri setleri üzerinde farklı sonuçlar elde ettiği, çözünürlük ve veri setindeki tutarlılıklarının başarı üzerinde etkili olduğu görülmüştür.

Sonuç olarak üç modelin de birbirine yakın sonuçlar elde ettiği, yüksek çözünürlük ve hızlı tespit için YOLOv7 modelinin daha başarılı olduğu, YOLOv5 ve YOLOv8 modellerinin sonuçlarının birbirine çok yakın olduğu, hiper-parametre optimizasyonu ile YOLOv7 modelinin hem daha hızlı hem daha başarılı olduğu görülmüştür. Genetik algoritma kullanılarak YOLOv5 ve YOLOv7 mimarisinde CHV veri seti üzerinde optimize edilmiş ve YOLOv5 için standart hiper-parametrelere göre insan tespitinde mAP doğruluk değeri %96.3'ten %97.4'e, precision değeri % 92.1'den %92.6'ya ve YOLOv7 için mAP ortalama doğruluk değeri %93.4'ten %96.3'e, F1-Skor değerinin %90'dan %94'e yükseltilmiş ve tüm değerlerde ortalama %3.34 daha başarılı sonuçlar elde edilmiştir.

KAYNAKLAR

- Alli, B. O. 2008. Fundamental principles of occupational health and safety Second edition. Geneva, International Labour Organization, 15, 2008.
- Ajayi, A., Oyedele, L., Owolabi, H., Akinade, O., Bilal, M., Davila Delgado, J. M. ve Akanbi, L. 2020. Deep learning models for health and safety risk prediction in power infrastructure projects. Risk Analysis, 40(10), 2019-2039.
- Bagley, J. D. 1967. The Behavior of Adaptive Systems Which Employ Genetic and Correlative Algorithms. PhD thesis, University of Michigan, Ann Arbor.
- Bang, S., Hong, Y. ve Kim, H. 2021. Proactive proximity monitoring with instance segmentation and unmanned aerial vehicle- acquired video- frame prediction. Computer- Aided Civil and Infrastructure Engineering, 36(6), 800-816.
- Duan, R., Deng, H., Tian, M., Deng, Y. ve Lin, J. 2022. SODA: Site Object Detection dAtaset for Deep Learning in Construction. Automation in Construction. 142.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.
- Holland, J. H. 1992. Adaptation in Natural and Artificial Systems, MIT Press, ISBN 0-262-58111-6, Cambridge, MA.
- Isleyen, E., Duzgun, S. ve Carter, R. M. 2021. Interpretable deep learning for roof fall hazard detection in underground mines. Journal of Rock Mechanics and Geotechnical Engineering, 13(6), 1246-1255.
- Jixiu, W., Cai, N., Chen, W., Wang, H., ve Wang, G. 2019. Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset. Automation in Construction. 106.
- Jocher, G. 2020. YOLOv5 by Ultralytics. Web Sites: <https://github.com/ultralytics/yolov5>. Eriřim Tarihi: 23.05.2023.
- Jocher, G., Chaurasia, A., ve Qiu, J. 2023. YOLO by Ultralytics. Web Sites: <https://github.com/ultralytics/ultralytics>. Eriřim Tarihi: 23.05.2023.
- Kaiser, M. S., Mahmud, M., Noor, M. B. T., Zenia, N. Z., Al Mamun, S., Mahmud, K. A., ... ve Hussain, A. 2021. iWorkSafe: towards healthy workplaces during COVID-19 with an intelligent pHealth App for industrial settings. Ieee Access, 9, 13814-13828.
- Khan, N., Saleem, M. R., Lee, D., Park, M. W. ve Park, C. 2021. Utilizing safety rule correlation for mobile scaffolds monitoring leveraging deep convolution neural networks. Computers in Industry, 129, 103448.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. 2012. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097-1105.
- LeCun, Y., Bengio, Y., ve Hinton, G. 2015. Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y., ve Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Lee, E. W. M. 2010. Application of artificial neural network to fire safety engineering. In *Handbook on Decision Making*. 369-395.
- Mo, Y., Zhao, D., Du, J., Liu, W. ve Dhara, A. 2018. Data-driven approach to scenario determination for VR-based construction safety training. In *Proceedings of the Construction Research Congress*, 116-125.
- Moreno-Rabel, M. D. 2016. An access detection and machine cycle tracking system for machine safety. *The International Journal of Advanced Manufacturing Technology*, 87(1), 77-101.
- Nath, N. D., Behzadan, A. H. ve Paal, S. G. 2020. Deep learning for site safety: Real-time detection of personal protective equipment. *Automation in Construction*, 112, 103085.
- Papoutsakis, K., Papadopoulos, G., Maniadakis, M., Papadopoulos, T., Lourakis, M., Pateraki, M. ve Varlamis, I. 2022. Detection of Physical Strain and Fatigue in Industrial Environments Using Visual and Non-Visual Low-Cost Sensors. *Technologies*, 10(2), 42.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A. 2015. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 779–788, 2016.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. 1986. Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Sasha, S. 2018. A Comprehensive Guide to Convolutional Neural Networks. Web Sitesi: <https://saturncloud.io/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way/> Erişim Tarihi: 23.07.2023.
- Sharapov, R. 2007. Genetic Algorithms: Basic Ideas, Variants and Analysis. 10.5772/4971
- Yang, H., Jang, H., Kim, T. ve Lee, B. 2019. Non-temporal lightweight fire detection network for intelligent surveillance systems. *IEEE Access*, 7, 169257-169266.
- Yu, W. D., Liao, H. C., Hsiao, W. T., Chang, H. K., Wu, T. Y. ve Lin, C. C. 2022. Real-time Identification of Worker's Personal Safety Equipment with Hybrid

Machine Learning Techniques. International Journal of Machine Learning and Computing, 12(3).

Wang, C., Bochkovski, A., ve Liao, H.. 2022. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. 10.48550/arXiv.2207.02696.

Wang, Z., Wu, Y., Yang, L., Thirunavukarasu, A., Evison, C. ve Zhao, Y. 2021. Fast Personal Protective Equipment Detection for Real Construction Sites Using Deep Learning Approaches. Sensors. 21(10):3478.

Wu, X., Liu, C., Wang, L. ve Bilal, M. 2021. Internet of things-enabled real-time health monitoring system using deep learning. Neural Computing and Applications, 1-12.

Xie, L. Harvard Dataverse, Hardhat, 2019, V1, <https://doi.org/10.7910/DVN/7CBGOS>

Zeiler, M. D., Fergus, R. 2014. Visualizing and understanding convolutional networks. European Conference on Computer Vision (pp. 818-833). Springer, Cham.

Zhang, J., Cosma, G., and Watkins, J. 2021. Image enhanced Mask R-CNN: A deep learning pipeline with new evaluation measures for wind turbine blade defect detection and classification. Journal of Imaging, 7(3), 46.