

## İş Sağlığı ve Güvenliğinde Derin Öğrenme Tabanlı Risk Tespit ve Analizi

In Occupational Health and Safety Deep Learning Based Risk Detection and Analysis

### Öz

İş sağlığı ve güvenliği alanında, risk analizi ve değerlendirilmesi zorunlu ve yoğun emek gerektiren bir süreçtir. Risk analizi ve değerlendirilmesi bir kere yapıldıktan sonra yenilenmesi yıllar sonrasını bulabilir. Bu durum bazı risklerin fark edilmesinin gecikmesine ve iş kazalarının oluşmasına sebebiyet verebilir. Bu çalışmada, risk tespit ve analiz sürecinde geleneksel yöntemlere alternatif olarak derin öğrenme tekniklerinin kullanılması önerilmektedir. Kişisel koruyucu donanım (KKD) kullanımının zorunlu olduğu ve yetkisiz personel tarafından erişilmesi halinde iş kazasına neden olabilecek bir makine veya bölgeye çalışanların güvensiz erişimi tehlikesi analizi örneği üzerinden derin öğrenme tabanlı risk tespit ve analiz eğitim modeli uygulanmıştır. Risk tespit ve analiz eğitim modeli YOLOv5 mimarisi kullanılarak, yetkili ve yetkisiz çalışanların KKD kullanıp kullanmama davranışlarını içeren bir veri kümesiyle eğitilmiştir. Eğitim sonuçları, modelin risk tespiti ve analizi için uygulanabilir olduğunu ve %90'ın üzerinde doğruluk elde ettiğini göstermiştir. Çalışmanın sonuçları, bu yaklaşımın geliştirilmesi durumunda, geleneksel yaklaşıma alternatif olabileceğini göstermektedir.

### Abstract

Risk analysis and assessment are mandatory and labor-intensive processes in the field of occupational health and safety. Once risk analysis and assessment have been conducted, it may take years before it is renewed. This may lead to the delayed recognition of risks and occupational accidents. This study proposes the use of deep learning techniques as alternatives to traditional methods for risk identification and analysis. A deep learning-based risk detection and analysis training model was applied to analyze the risk of unsafe access by employees to a machine or area where the use of personal protective equipment (PPE) is mandatory, which may cause an occupational accident if accessed by unauthorized personnel. The risk detection and analysis training model was trained using the YOLOv5 architecture with a dataset that includes the behavior of authorized and unauthorized employees regarding whether they use PPE. The training results showed that the model was applicable for risk detection and analysis, achieving an accuracy exceeding 90%. The results of this study show that if this approach is developed, it can be an alternative to the traditional approach.

### Giriş

Derin öğrenme makine öğreniminin bir alt alanı olup özellikle insan beyninin yapısından esinlenerek modellenmiş üst düzey bir makine öğrenim tekniğidir (Bingöl vd., 2020:2201). Durum ve nesne algılama, doğal dil işleme, ses tanıma gibi çeşitli görevleri başarı ile gerçekleştirir (Shinde, P. P., & Shah, S., 2018:4). Derin öğrenme modellerinde hesaplama mimarisi olarak genellikle bilgi işleme ve veri temsillerini öğrenme yeteneğine sahip birbirine bağlı düğümlerden oluşan yapay sinir ağları (YSA'lar) kullanılır. Düğüm türleri, düğümler arasındaki bağlantılar, bağlantıların ağırlıklandırılması ve ağ üzerinden bilgi akışı birden fazla katmanla gerçekleşebilir. Bir sinir ağının her katmanı, girdi verilerini sonraki katmanlarda daha karmaşık temsillerin öğrenilmesini kolaylaştıracak şekilde dönüştürmek üzere tasarlanmıştır. Böylece katman sayısı arttıkça karmaşık

### Tarık Aslan

Doktora Öğrencisi, İstanbul Gedik Üniversitesi, İstanbul, Türkiye,  
tarikaslan@ktu.edu.tr  
Orcid No: <https://orcid.org/0000-0002-6548-5294>

### Mustafa Yağimli

Dr. Öğretim Üyesi, İstanbul Gedik Üniversitesi, İstanbul, Türkiye  
mustafa.yaginli@gedik.edu.tr  
Orcid No: <https://orcid.org/0000-0003-4113-8308>

### Makale Türü / Article Type

Research Article / Araştırma Makalesi

### Anahtar Kelimeler

Derin Öğrenme, İş Sağlığı ve Güvenliği, Risk Analizi

### Keywords

Deep Learning, Occupational Health and Safety, Risk Analysis

JEL Codes: E69, E60, E65


Submitted: 27 / 04 / 2023

Accepted: 14 / 06 / 2023

örüntüleri öğrenebilmektedir. Bu da yapay sinir ağları ile oluşan derinliği oluşturur ve bu yönetime adını verir (LeCun vd., 2015:436). Bununla birlikte, sinir ağı modellerindeki katman sayısının artırılması karmaşıklığı, hesap sayısını ve eğitim süresini artırmakta ve eğitim sırasında zorluklara yol açarak daha yüksek eğitim hatalarına neden olmaktadır (He vd., 2015:770). Ayrıca, katman sayısı fazla bir model ile sınırlı miktarda veri kullanılarak eğitim gerçekleştiriliyorsa modelin eğitim verilerine aşırı uyum sağlama ve genelleme yeteneğini kaybetme riski vardır. Bu durum, modelin eğitim verilerinde yüksek performans sergilemesine rağmen, gerçek dünyadaki yeni verilere karşı düşük performans gösterme durumunu ifade eden aşırı uyum (overfitting) olarak bilinir (Hilton vd., 2012:1).

Derin öğrenme modelleri genellikle en az üç katman blogundan oluşur. Ham verileri alan giriş katmanı, veri özellikleri veya öznitelikleri çıkarmak için tasarlanmış olan gizli katman ve ağın nihai çıktısını üreten çıkış katmanıdır (Chowdhury vd., 2019:1). Bu katmanların her biri kendi içinde de özelleşmiş katmanlar bulundurabilir. Eğitim sırasında ağın ağırlıkları, ağın tahminleri ile gerçek çıktı arasındaki farkı ölçen bir kayıp fonksiyonunu en aza indirecek şekilde ayarlanır (Xu vd., 2018:5502). Böylece yüksek performansa sahip bir eğitim modeli oluşturulur. Bu eğitim modeli ile yeni, ağın hiç karşılaşmadığı verilerden çıkarım elde edilebilir.

Yapay sinir ağları (YSA), çeşitli türlere ayrılan genel bir terimdir. Derin sinir ağları (DSN), YSA türlerinden biri olup çeşitli mimarilere ayrılmıştır. Bunlar, konvolüsyonel sinir ağları (KSA), tekrarlayan sinir ağları (TSA), enkoder-dekoder ve otomatik enkoder modeller ve çekişmeli üretken ağları (ÇÜA) olup aralarında en yaygın kullanılanı KSA'dır (Minaee vd., 2022:3524). Şekil 1'de KSA'ların temel mimari yapısı gösterilmiştir. Tipik bir KSA mimarisi, giriş ve çıkış katmanlarının yanı sıra gizli katmanlar olarak konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlardan oluşur (Gu vd., 2018:355).



**Şekil 1. Konvolüsyonel Sinir Ağı Temel Mimari Yapısı**

KSA, ses, görüntü, fotoğraf ve video verilerini işleyerek karmaşık durumları ve nesnelere tespit etmek ve sınıflandırmak için kullanılabilir. Bu amaçla, özelleştirilmiş birçok algoritma geliştirilmiştir. Bunlar arasında en fazla tercih edilen; YOLO (You Only Look Once), SSD (Single Shot MultiBox Detector) ve Faster R-CNN (Faster Region-based Convolutional Neural Network) algoritmalarıdır. Bu algoritmaların doğruluk ve hız konusunda daha gelişmiş olan 3 versiyonun karşılaştırılması Tablo 1'de verilmiştir.

**Tablo 1. Durum ve Nesne Tespitinde Kullanılan En Yaygın Algoritmaların Karşılaştırması**

Algoritma	Yapısı	Özellikleri
SSD MobileNetv2	Tek bir ağ yapısında durum ve nesne algılama ve sınıflandırma yapabilen bir algoritmadır.	En hızlı çıkarım gerçekleştirme süresine sahip (Neftali vd., 2022:9).
YOLOv5	Durum ve nesne algılama ve sınıflandırma işlemini tek seferde gerçekleştirir.	Doğruluk ve hız konusunda en iyi denge (Neftali vd., 2022:9) (Mahendrakar vd., 2022:9).
Faster R-CNN	İki aşamalı bir ağ yapısına sahiptir. Önceden tanımlanmış referans (bağlantı) noktaları (anchors) kullanarak ilgi bölgeleri (region of interest - ROI) oluşturulmak için bir bölge öneri ağı (Region Proposal Network - RPN) kullanır.	Doğruluk performansı en yüksek (Mahendrakar vd., 2022:9).

Derin öğrenme, özellikle durum ve nesne tespiti teknolojisi, birçok endüstri ve hizmet, eğitim, sağlık gibi farklı alanlarda kullanılmaktadır (Doğan vd., 2018:412). Bu çalışma için özellikle güvenlik ve tehlike ile ilgili uygulamalar taranmıştır ve görülmüştür ki; derin öğrenme ile insanların güvenlik kurallarına uymadığını tespit edebilir ve kısıtlı alanlara izinsiz girişler belirlenebilir (Mei vd., 2023:04022142-13). Casusluk gibi davranışlar tespit edilebilir (Çalışkan ve Demir, 2022:40). Ayrıca silahlı saldırı veya terörizm gibi olayların erken tespitinin gerçekleşmesi sağlanabilir (Uddin vd., 2020:14). Derin öğrenme, kırmızı ışıkta geçme gibi trafik ihlallerini de tespit edebilir (Nguyen Van vd., 2022:226). Bu tür tehlikeler İş Sağlığı ve Güvenliği (İSG) alanındaki tehlikelere benzemektedir ve derin öğrenmenin risk analiz ve değerlendirme çalışmalarına da uygulanabileceğini göstermektedir.

Bunun için risk analiz ve değerlendirme çalışmalarına biraz daha yakından bakmak gerekir. Günümüzde risk analiz ve değerlendirme faaliyetleri, emek yoğun bir çalışma olup, planlı ve kısıtlı bir süre aralığında, işletmenin içinde ve dışındaki faktörlerin detaylı bir şekilde incelenmesi, işyerinde meydana gelecek risklerin belirlenmesi, önceliklendirilmesi şeklinde gerçekleşir. Bir kere yapıldıktan sonra da uzunca bir süre geçerliliği kabul edilerek uygulamada tutulur.

Günümüzde risk analiz ve değerlendirme çalışmalarının uzun aralıklarla yapılmasının gerekçeleri şunlardır:

- Risk faktörlerinde kayda değer, önemli bir değişiklik olmadıkça risklerde de önemli bir değişiklik olmayacağı görüşü,
- Risk analiz ve değerlendirme çalışmaları yoğun emeğe dayandığı için sık aralıklarla yapılmasının maliyetli olması,
- Risk analiz çalışmasından sonra önlemlere odaklanması ve önlemlerin risk analiz ve değerlendirme çalışmasına göre daha yavaş ilerlemesi ve daha uzun bir süreyi kapsamasıdır.

Risk analizinin yenilenmesi belli koşullara ve durumlara bağlı olup bu koşullar ve durumlar gerçekleşmediği sürece zamanla değişen tehlikeler ve risklerin tespitinde gecikmelere neden olması gelenekleşmiş risk analiz ve değerlendirme yaklaşımlarının zayıflığıdır. İşletmelerde mevzuatın tanımladığı süre aralıklarında, taşınma, üretim araçlarının veya yöntemlerinin değiştirilmesi ve yeni bir proses sistemine geçilmesi gibi önemli bir değişiklik olduğunda veya iş kazası gerçekleşmesi durumunda yenilenir (RG, 29 Aralık 2012, 28512). Risk analiz ve değerlendirmesinin tamamen ya da kısmen yenilenmesinin sağlanması risk analiz ve değerlendirme faaliyetlerinin proaktif bir yaklaşım olarak uygulamaya alınmasına rağmen zamanla reaktif bir yaklaşıma dönüşmesini sağlar. Uzun aralıklarla yenilenen risk analiz çalışmaları fark edilmeden ya da zamanla oluşan risklerin fark edilmesini geciktirecektir. Ancak iş sağlığı ve güvenliği açısından istenilmeyen bir durum gerçekleştiğinde yeniden değerlendirmeye alınabilecektir.

Oysa uzun aralıklar yerine kısa aralıklarla, mümkünse sürekli olacak şekilde risk analiz ve değerlendirme çalışmasının yapılması habersizce gelişen tehlike ve risklerin iş kazasına dönüşmeden fark edilmelerini sağlayacak ve gerekli önlemlerin bir an önce alınmasına imkan verecektir.

Risk analiz ve değerlendirme çalışmasının en küçük yapı taşı risktir. Risk, çalışana zarar verme potansiyeline sahip bir tehlikenin gerçekleşme olasılığı ile gerçekleşmesi durumunda çalışanın sağlığını etkileme şiddetinin büyüklüğünün birleşimi olarak tanımlanır (Özkılıç, 2005:60). Bu durumda risk analiz ve değerlendirme çalışmalarında tehlikenin, tehlikenin iş kazasına dönüşme olasılığının ve iş kazası olması durumunda oluşacak şiddet büyüklüğünün belirlenmesi oldukça önemlidir.

Derin öğrenme ile tehlikeler belirlenip, tehlikenin bulunduğu durum ve koşullara göre şiddet ve olasılık büyüklükleri otomatik olarak sağlanabilirse, riskin olduğu an tespit edilebilir, otonom ve proaktif risk analiz ve değerlendirme faaliyetleri uygulanabilir ve geçerlilik kazanabilir.

## 1. Materyal ve Yöntem

### 1.1. Risk Analiz Yönteminin Oluşturulması

Bu çalışmada, elektrik panolarına, tehlikeli kapalı alanlara, biyolojik veya kimyasal risk taşıyan laboratuvarlara ve benzeri yetkisiz kişilerin erişimin risk yaratacağı tehlikeli alanlara veya bir

işbirlikçi mobil robotun yetkili çalışanlarla birlikte görevlerini yerine getirdiği alanda uygulanabilecek derin öğrenmeye dayalı yeni bir risk tespit ve analizi yaklaşımı modellenmiş ve derin öğrenme çıkarıma göre risk seviyesinin belirlenmesi amaçlanmıştır. Belirtilen alanda bir iş kazası olması durumunda çalışanı kazanın şiddetinden koruyan KKD kullanılma durumu şiddet derecesi ile; yetkisiz bir çalışanın iş kazası geçirmeye daha yatkın olmasından dolayı çalışanın yetkili olma durumu olasılık derecesi ile ilişkilendirilmiştir.

Derin öğrenme elde edilen çıktının risk analizi açısından ne anlama geldiğinin belirlenmesi için Tablo 2’de gösterilen şiddet ve olasılık büyüklükleri tanımlanmıştır. Şiddet büyüklüğü, iki seviye olarak derecelendirilmiştir. KKD kullanımı ‘şiddet derecesi seviye 1: düşük’, KKD kullanılmaması ise ‘şiddet derecesi seviye 2: yüksek’; olasılık büyüklüğü yine iki seviye olarak derecelendirilmiş, ‘olasılık derecesi seviye 1: Nadiren’ ve ‘olasılık derecesi seviye 2: muhtemelen’ şeklinde tanımlanmıştır. Risk derecesi ise şiddet ve olasılığın çarpımıdır.

**Tablo 2. Şiddet ve Olasılık Derecelendirme Tablosu**

Şiddet Büyüklüğü			Olasılık Büyüklüğü		
KKD Kullanımı	Şiddet derecesi	Dilsel ifadesi	Yetki Durumu	Olasılık derecesi	Dilsel ifadesi
Kullanıyor	1	Düşük	Yetkili	1	Nadiren
Kullanmıyor	2	Yüksek	Yetkili	1	Nadiren
Kullanıyor	1	Düşük	Yetkili değil	2	Muhtemelen
Kullanmıyor	2	Yüksek	Yetkili değil	2	Muhtemelen

Olasılık ve şiddet seviyelerinin birleşimi ile oluşturulan risk boyutu, L tipi matris şeklinde düzenlenmiş ve Tablo 3’te gösterilmiştir.

**Tablo 3. L Tipi Risk Analiz Matris Tablosu**

Risk Analizi	Şiddet Seviyesi	
	1	2
Olasılık Seviyeleri	1	2
	2	4

Oluşan risk derecesine göre, riskin dilsel ifadesi ve alınması gereken önlemler ise Tablo 4’de yer almaktadır.

**Tablo 4. Risk Derecelendirme Tablosu**

Dilsel ifade	Risk derecelendirme	Önlem
Düşük	1	Kabul edilebilir risk, önlem alınmasına gerek yok. Mevcut durumun korunması ve iyileştirilmesi, İSG eğitimlerin eğitim planına uygun şekilde verilmeye devam edilmesi. KKD’lerin zimmet formu ile teslim edildiğinin ve tehlikeli alanlar ve durumlar için talimatların ve uyarı levhaların görünür şekilde asıldığı kontrol edilmesi. Eksikler varsa tamamlanması.
Orta	2	Yetkili personele KKD konusunda en kısa sürede eğitim verilmesi (Eğitim planının revizyon edilmesi). KKD’lerin zimmet formu ile teslim edildiğinin ve tehlikeli alanlar ve durumlar için talimatların ve uyarı levhaların görünür şekilde asıldığı kontrol edilmesi. Eksikler varsa tamamlanması.
Yüksek	4	İşveren, işveren vekili ve tüm çalışanlara genel İSG, KKD kullanımı, tehlikeli alanlar erişimle ilgili en kısa sürede ve risk azalana kadar sık aralıklarla eğitim verilmesi (Eğitim planının revizyon edilmesi). Riskleri kontrol etmek için çalışanlara yönelik caydırıcı ceza uygulama prosedürünün devreye alınması. KKD’lerin zimmet formu ile teslim edildiğinin ve tehlikeli alanlar ve durumlar için talimatların ve uyarı levhaların görünür şekilde asıldığı kontrol edilmesi. Eksikler varsa tamamlanması.

Risk analiz ve değerlendirme prosedürünün tamamlanmasıyla birlikte derin öğrenme ile tespit edilmesi istenilen durumlar ve bu durumların oluşturduğu risk seviyeleri belirlenmiştir.

## 1.2. Derin Öğrenme

Derin öğrenme modellemesinde şiddet boyutu KKD kullanımı ile, olasılık boyutu ise yetkili çalışanı temsil eden omuzları şeritli yelek ile ilgilidir. Risk tespiti ve analizi derecelendirmesi Şekil 2’de yer alan görseller üzerinden gösterilmiştir. Şekil 2 incelendiğinde, a görseli düşük seviye risk derecesini, b ve c görseli orta derece risk seviyesini ve d görseli ise yüksek seviye risk derecesini göstermektedir. Bu görseller aynı zamanda derin öğrenmede kullanılacak sınıfları da belirtmektedir.



**Şekil 2. a: Baret (KKD) Kullanan Yetkili, b: Baret (KKD) Kullanmayan Yetkili, c: Baret (KKD) Kullanan Yetkili Olmayan, d: Baret (KKD) Kullanmayan Yetkili Olmayan**

Eğitim çalışması yapılırken kullanılacak algoritma mimarisi, çalışmanın amacına ve hedefine uygun olarak belirlenir. Bu çalışmada riskin, risk oluştuğu anda ve doğru şekilde tespit edilmesi önemli olduğundan, hız ve doğruluk dengesi gösteren bir algoritma olan YOLOv5 tercih edilmiştir. YOLO'nun nesne tespiti için birçok versiyonu bulunmakla birlikte hızlı ve yüksek doğrulukla çalışabilen versiyonu YOLOv5'tir (Neftali vd., 2022:8).

### 1.2.1. Veri Setinin Oluşturulması

Çalışma kapsamında, sınıfların temsilini sağlamak için farklı insan yüzleri, kıyafetler, baret renkleri, ışık ortamları ve açılardan toplamda 840 adet veriyi içeren veri seti oluşturuldu. Bu veri setinin 600 adeti eğitim, 120 adeti doğrulama ve 120 adeti ise test veri seti olarak, tüm sınıfları eşit temsil edecek şekilde rastgele dağıtıldı. Çalışmada yer alan veri seti adeti ve dağılımı Tablo 5’te yer almaktadır.

**Tablo 5. Veri Seti Adedi ve Dağılımı**

Sınıf	Sınıf tanımı	Eğitim veri seti	Doğrulama veri seti	Test veri seti	Toplam veri seti
0	KKD kullanan yetkili	150	30	30	210
1	KKD kullanan yetkili olmayan	150	30	30	210
2	KKD kullanmayan yetkili	150	30	30	210
3	KKD kullanmayan yetkili olmayan	150	30	30	210
Toplam		600	120	120	840

### 1.2.2. Görüntü Ölçekleme

Derin öğrenme yapay sinir ağlarının eğitim işlemlerini kolaylaştırmak ve daha istikrarlı hale getirmek, eğitim ve doğrulama verilerini standart bir ölçek ile eğitim için hazır hale getirmek için kullanılır. Böylece eğitimin daha hızlı ve daha verimli olması sağlanır. Eğitim verilerinin etiketlenmesi sırasında koordinat sisteminin daha anlaşılır olması için de bu işlem gereklidir (Sun vd., 2020:5875). Bu çalışmada da eğitime başlamadan önce görsel verilerin düzenlenmesi ve belli bir boyut ile sınırlandırılması sağlanmıştır. YOLO için standart bir ölçü boyutu yoktur. Buna karşın 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 oluştuğu an tespit edileceğinden çıkarım hızı oldukça önemlidir ve boyut olarak 416x416 piksel büyüklüğü seçilmiştir. Şekil 3’te normalizasyonu tamamlanmış veri setinden örnekler yer almaktadır.





Şekil 3. Veri Setinde Yer Alan Örnek Görseller

### 1.2.3. Etiketleme (Labeling)

Etiketleme, tespit edilmek istenen nesne veya durumların sınırlama kutusu içine alınması ve görsel veri ile aynı ismi taşıyan “\*.txt” uzantılı bir dosyada koordinatlarının ve sınıf bilgilerinin kaydedilmesi işlemidir. Etiketleme işlemi farklı uygulamalar veya programlar kullanılarak ancak manuel yapılan bir işlemdir. Tercih edilen uygulama veya program eğitimin verimliliğini veya işleyişini etkilemez. Eğitimin başarılı bir şekilde tamamlanması için etiketleme işlemi dikkatli yapılmalı, istenilen durum veya nesne doğru bir şekilde sınırlama kutusunun içine alınmalıdır. Etiketleme işlemi tamamlandığında veri seti eğitimin denetimli, hızlı ve verimli şekilde gerçekleşmesi için hazır hale gelmiş olur. Ayrıca etiketleme, veri setinin yönetimi ve analizi için de gereklidir.

Şekil 4’te etiketleme işleminin oluşturulması ve oluşturulan etiketleme ile elde edilen txt uzantılı dosyanın içerik bilgileri yer almaktadır.



Şekil 4. a: Etiketleme İşlemi, b: Etiketleme İle Oluşan txt Uzantılı Dosya İçeriği


#### 1.2.4. Eğitim

Eğitim, Nvidia RTX A4000 ekran kartı bulunan bir bilgisayarda PyCharm IDE'si ve 'ultralytics' kütüphanesi kullanılarak ve ayrıca 60 epoch süresince grafik işlemci birimi (GPU) kullanılması ile gerçekleştirilmiştir.

## 2. Bulgular ve Tartışma

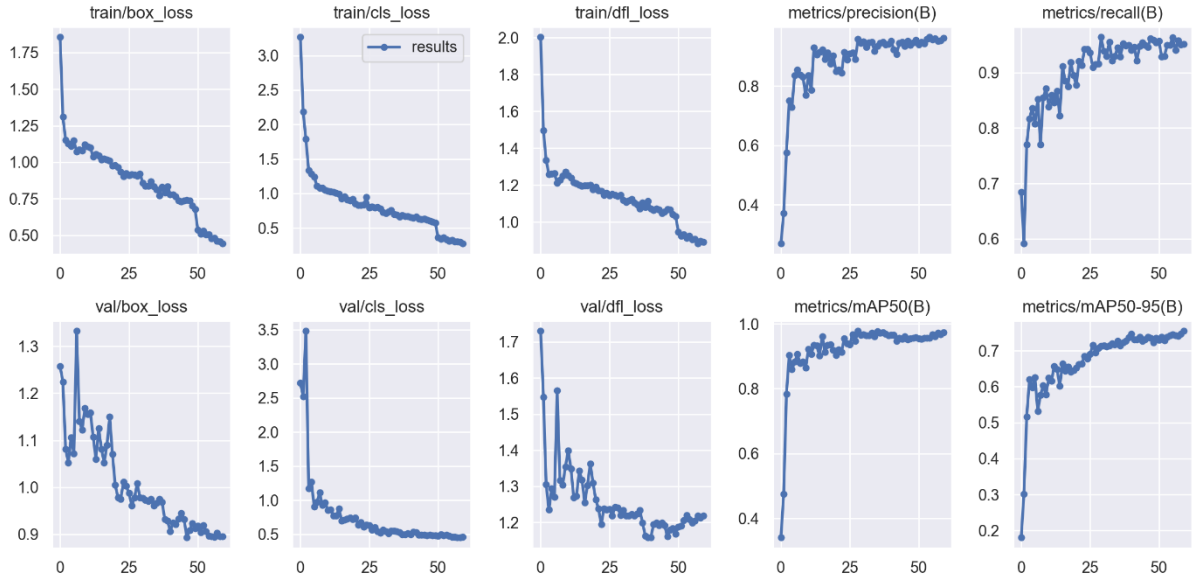
YoloV5 algoritması kullanılarak eğitim gerçekleştirilmiş ve risk oluştuğu an tespit ve analiz etmek üzere modellenmiştir. Bu modelin geçerliliğinin ve doğruluğunun sağlanması ve performansının ölçülmesi için doğrulama veri setleri kullanılmıştır. Ultralytics kütüphanesi kullanılarak eğitimin gerçekleşmesi sağlanmış ve doğrulama verileri kullanarak eğitim modelinin performans çıktıları da oluşturulmuştur.

Şekil 5'te karmaşıklık matrisi bulunmaktadır. Bu matris, modelin gerçekleştirmiş olduğu tahminin (Prediction) ne kadarının doğru (True) tahmin olduğunu gösterir. Baret kullanan yetkili tespiti %98, baret kullanan yetkili olmayan tespiti %91, baret kullanmayan yetkili tespiti %94 ve baret kullanmayan yetkili olmayan tespiti ise %97'lik bir oranla doğru tahmin edildiği görülmektedir. Model, örnek veriden herhangi bir tespit gerçekleştiremez ise veriyi arka plan (background) olarak kabul eder. Bunun nedeni modelin ifade edebileceği tek durumun arka plan olmasıdır.



Şekil 5. Karışıklık Matrisi

Şekil 6, hem eğitim hem de doğrulama veri kümeleri için eğitim performansı çıktılarını göstermektedir. Grafik değerleri epoch artışına bağlı olarak değişmektedir. Bu değerleri tek tek inceleyecek olursak;



Şekil 6. Eğitim Modelinin Performans Çıktıları

**Sınırlama kutusu kaybı (Bounding Box Loss (box\_loss)):** Eğitim modeli görüntülerdeki durumları ve nesnelere tespit ettiğinde, tespit edilen nesnenin güven eşikini, konumunu ve boyutunu belirleyen çıktı değerleri üretir. Konum ve boyut değerleriyle sınırlama kutusunu




oluşturur. Eğitim sırasında, modelin oluşturduğu sınırlama kutularıyla etiketleme sırasında, eğitimde kullanılmak üzere manuel olarak oluşturulan sınırlama kutuları her epoch sırasında karşılaştırılır. Karşılaştırmada oluşan hata, sınırlama kutusu kaybıdır. Böylece eğitim sürecinde hatalar düzeltilir. Model, doğru sınırlama kutuları oluşturmayı öğrenir ve kaybı en aza indirecek şekilde doğru sınırlama kutusu oluşturmaya mümkün olduğunca yaklaşır. Eğitim bittiğinde oluşan model ilk defa karşılaşacağı yeni bir veride tespit ettiği durum ve nesneyi sınırlama kutusu içine aldığı anda ne oranda hata yapma potansiyeli bulunduğu hakkında genel bir fikir oluşur. Sınırlama kutusu kaybı eğitim verileri ile karşılaştırıldığında, epoch sayısı arttıkça kaybın 0.5'in altına düştüğü, ancak, doğrulama verileri ile karşılaştırıldığında 0.9 değerinde kaldığı görülmektedir.

**Sınıflandırma Kaybı (Classification Loss (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 eşleştiğiyle ilgilidir. Düşük bir sınıflandırma kaybı, modelin tahminlerinin doğru olduğunu ve kaybın az olduğunu, yüksek bir sınıflandırma kaybı ise modelin tahminlerinin yanlış olduğunu ve kaybın yüksek olduğunu gösterir. Bu çalışmada sınıflandırma kaybı hem eğitim verilerinde hem de doğrulama verilerinde 0.5 değerinin altında kadar düştüğü görülmektedir.

**Dağılım Odak Kaybı (Distribution Focal Loss (dfl\_loss)):** Dengesiz sınıflandırma durumunu ele alan bir kayıp fonksiyonudur. Modelin sınırlama kutusunun sürekli konumları etrafındaki değerlere odaklanmasını hedefler. Eğer odaklanma zorlaşıyorsa dengesiz bir sınıflandırma olduğu anlaşılır. Veri kümesinin tamamı sınıflar arasında dengeli dağıtılmış olsalar dahi, bir sınıfı temsil eden durum ve nesnenin farklı biçimleri arasında dengesizlik olabilir. Örneğin çalışan tespitinde yüzlerinin karşı cepheden elde edilen görüntüleri yan cepheden elde edilen görüntülerinden fazla olması, modelin eğitim sırasında odağını kaybetmesine ve zorlanmasına neden olabilir. Veya buna benzer başka nedenlerde odak kaybına sebebiyet verebilir. Bu durum genellikle yüksek hacimli veri kümeleriyle eğitim yapılırken daha fazla ortaya çıkar ve odaklanma daha etkin olur. Bu çalışmada eğitim verileriyle yapılan ölçümlerde dağılım odak kaybı 1'in altına düşmüş olduğu ancak doğrulama veri kümeleriyle yapılan ölçümlerde 1'in biraz üzerinde kaldığı görülmüştür.

Kayıplar dışındaki diğer performans değerleri olan; duyarlılık (recall), kesinlik (precision) ve mAP metriklerinin hesaplanması için doğru pozitif (true positive (TP)), yanlış pozitif (false positive (FP)) ve yanlış negatif (false negative (FN)) ölçümleri saptanır.

Model istenen durumu veya nesneyi doğru tespit ettiğinde TP; başka bir sınıftan bir durumu veya nesneyi doğruymuş gibi yanlış tespit ettiğinde FP, istenen durumu veya nesneyi tespit edemediğinde FN oluşur. Baret kullanan yetkili sınıfı için Şekil 7'de örnek bir ölçme gösterilmektedir. Şekil 7 incelendiğinde, a görselinde baret kullanan yetkili tespiti doğru tespit edildiğinden doğru pozitif (TP), b görselinde ise baret kullanmayan yetkili, baret kullanan yetkili şeklinde tespit edildiğinden yanlış pozitif (FP), c görselinde baret kullanan yetkili, baret kullanan yetkisiz olarak tespit edildiğinden yanlış negatif (FN) olarak ölçülür.



Şekil 7. Baret Kullanan Yetkili Sınıfı İçin a: Doğru Pozitif (TP), b: Yanlış Pozitif (FP), c: Yanlış Negatif (FN)

Doğru pozitif eğitim modelimizin performansını artıran sonuçtur. Yanlış negatif ve yanlış pozitif ise performansı düşüren sonuçlardır. Bu durum. Denklem 1 ve Denklem 2’de kesinlik ve doğruluk hesaplama formülü verilmiştir.

$$\text{Kesinlik (p)} = \frac{\text{Doğru pozitif örnekler}}{\text{Modelin pozitif olarak tahmin ettiği tüm örnekler}} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$\text{Duyarlılık (r)} = \frac{\text{Doğru pozitif örnekler}}{\text{Pozitif olarak etiketlenen tüm örnekler}} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

Kesinlik ve duyarlılık 0 ile 1 arasında bir değer alır. 1’e ne kadar yakınsa model başarılı o derece yüksektir. Şekil 7’de epoch değeri arttıkça kesinlik metrik değerlerinin 0.9’ yaklaştığı, duyarlılık metrik değerlerinin ise 0.9’un üzerine çıktığı ve 1’e yaklaştığı görülür.

mAP: ‘genel ortalama hassasiyet’ anlamına gelen "mean Average Precision" teriminin kısaltmasıdır. mAP hesaplamak için öncelikle ortalama hassasiyet (Average Precision (AP)) hesaplanmalıdır. AP Denklem 3’de formüle edildiği şekilde her sınıf için oluşturulan kesinlik-doğruluk eğrisinde eğrinin altında kalan pozitif alanın toplamıdır. mAP ise Denklem 4’de formüle edildiği şekilde modeldeki her sınıf için hesaplanan AP değerlerinin aritmetik ortalamasıdır.

$$\text{Ortalama Hassasiyet (AP)} = \int_0^1 p(r)dr \cong \sum_{k=1}^n p(k) \cdot \Delta r(k) \quad (3)$$

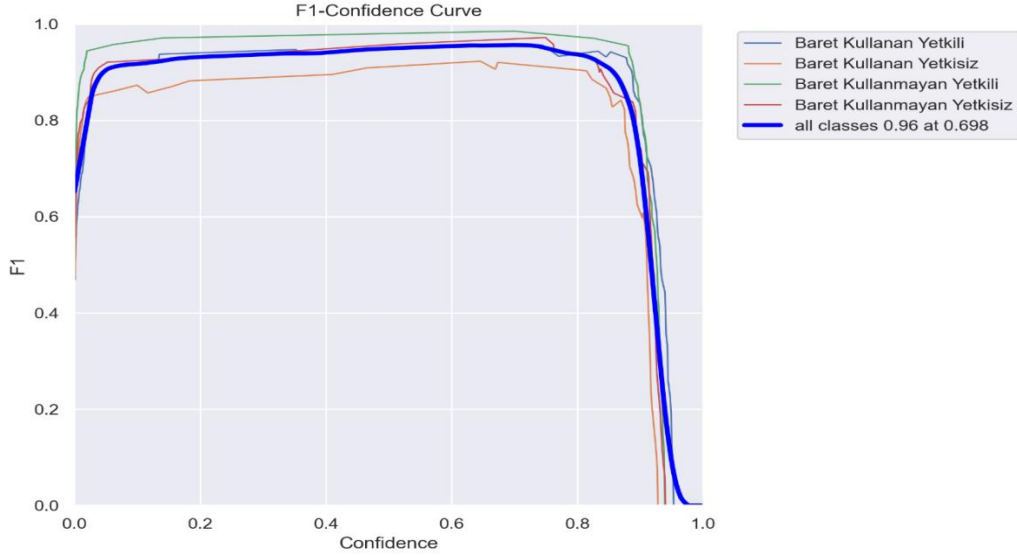
$$\text{Genel Ortalama Hassasiyet (mAP)} = \frac{\sum \text{AP}}{\text{Sınıf sayısı}} \quad (4)$$

mAP kısaltmasının yanındaki sayı, performans ölçümü için kullanılan güven eşik değerini gösterir. 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. Şekil 7’deki mAP grafikleri incelendiğinde, mAP50 metrik değerlerinin, epoch değeri arttıkça, %90’ın üstüne, mAP50-95 metrik değerlerinin ise %80’e kadar yükseldiği görülmektedir.

Şekil 8’de yer alan grafik her bir sınıfın (ince çizgi halinde) ve tüm sınıfların (kalın çizgi) güven eşik değeri ile F1 skoru arasındaki ilişkiyi gösterir. F1 skoru da modelinin doğruluğunu ölçmek için kullanılan başka bir metriktir. Kesinlik ve duyarlılık ölçümlerinin harmonik ortalaması olup hesaplama yöntemi Denklem 5’de yer almaktadır.

$$\text{F1 Skoru} = 2 * \frac{(\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} = 2 * \frac{(p * r)}{(p + r)} \quad (5)$$

Şekil 8’e bakıldığında modelin F1 skor değerinin oldukça yüksek olduğu görünür. Güven eşik değerinin çok küçük veya çok yüksek olduğu durumlarda tespit (tahmin) performansı düşmektedir. Bunun nedeni düşük eşik değerinde sistemin yeteri kadar seçici olmaması, çok düşük güven eşiğinde bile doğru olmayan durum ve nesnelere tespit edilmek istenilen durum veya nesne olarak algılanmasından, yüksek güven eşiğinde ise sistemin aşırı seçici olup aslında %90 oranında doğru olan bir durum veya nesnenin güven eşiğini aşmadığı için reddedilmesinden kaynaklanır. Diğer bir ifade ile düşük güven eşiği aşırı kabul, yüksek güven eşiği ise aşırı ret anlamına gelmektedir. Bu da iki durum için grafik üzerinde dramatik bir düşüş meydana getirir. Bu grafik en iyi performans değerinin hangi eşik değeri ile elde edilebileceği konusunda bir analiz sunmakta ve sonucu ayrıca tüm sınıfların ortalamasını alarak hesaplamaktadır. Grafik incelendiğinde 0.698 güven eşik değerinde modelin 0.96, yüzdelik ifade ile %96 performansa sahip F1 skor değerine ulaştığı görülmektedir.



Şekil 8. F1 Skoru Güven Eşiği Eğrisi

Eğitim aşamasında aşırı uyum ve benzer durumlar ortaya çıkmış ve yanıltıcı performans değerlerine yol açmış olabilir. Eğitim sonrası modülün, eğitim aşamasında kullanılmamış taze ve yeni veriler ile değerlendirilmesi gerekir.

Bu çalışmada da eğitim aşamasında kullanılmamış 120 adet taze ve yeni test veri seti ile eğitim sonrası modül değerlendirilmiştir. Değerlendirme sonucunda 0.5 güven eşik değerinde tüm sınıflar için modülün 0,92'lik bir F1 skoru elde ettiği görülmüştür. Bu sonuç eğitim performansı ile elde edilen değere yakındır ve modelin yeni verilere iyi genelleme yapabildiğini göstermektedir. Ayrıca TP, FP, FN, keskinlik ve duyarlılık metrik sonuçları Şekil 9'da yer almaktadır.

Sınıf	TP	FP	FN	Keskinlik	Duyarlılık	F1 Skoru
Baret Kullanan Yetkili	30	3	0	0.909091	1	0.952381
Baret Kullanan Yetkisiz	27	0	3	1	0.9	0.947368
Baret Kullanmayan Yetkili	28	1	6	0.965517	0.823529	0.888889
Baret Kullanmayan Yetkili	27	3	3	0.9	0.9	0.9
Arkaplan (Background)	0	5	0	0	nan	nan

Şekil 9. Güven Eşik Değeri 0.5 Alınarak Test Verisi ile Elde Edilen Metrik Değerler

### Sonuç ve Değerlendirme

Bu çalışmada yetki durumu ve KKD kullanımına göre sınırlandırılmış yapay zekaya dayalı gerçek zamanlı otonom risk analizi geçerliliği değerlendirilmiş ve elde edilen bulgular incelendiğinde F1 skorunun %96'ya ulaştığı, mAP50 metrik değerinde ise %90'ı aştığı görülmüştür. Eğitim sonrası yapılan değerlendirme de F1 skorunun %92 olduğu görülmüştür. Bu durum, geleneksel risk analiz ve değerlendirme yaklaşımını kökten değiştirebilecek yeni bir yaklaşımın geçerli olabileceğini göstermektedir.

Bu çalışma risk analiz ve değerlendirme sürecinin bir modelini sunsa da bu yöntemin daha da geliştirilmesi onu gerçek hayattaki uygulamalarda kullanılan karmaşık ve kapsamlı risk analiz ve

değerlendirme süreçlerine yaklaştırabilir. Bunun için araştırma ve geliştirme faaliyetlerine gerekli önem verilmeli, özel sektör ve devlet desteği sağlanmalıdır.

Ayrıca yapay zeka temelli gelişmiş bir risk analiz modülünün oluşturulabilmesi için iş sağlığı ve güvenliği için özelleştirilmiş ve internet üzerinden erişilebilir hazır veri setlerinin bulunduğu havuz veya platformlar oluşturulmalıdır. Bu veri setleri KKD, makine korumaların kaldırılması, ekranlı araçlarla çalışma davranışları, güvensiz alanlara izinsiz girilmesi, elektrik panolarında kaçak akım rölesi ve pano altında yalıtkanlı paspasın bulunmama durumu, malzemelerin düzensiz yerleştirilmesi vb. onlarca tehlikenin yapay zekaya dayalı risk analiz ve değerlendirme modeli ile tespit edilmesini sağlayacaktır.

İşyerine özgü tehlikelerin tespiti için ise verilerin çalışma alanından elde edilmesini gerekmektedir. Bu süreç başlangıç aşamasında geleneksel yöntemlerle tehlikeleri tespit etme sürecinden daha zorlu ve maliyetli olsa da, uzun bir zaman için daha ekonomik ve güvenlidir.

Ayrıca, derin öğrenmeye dayalı risk analiz ve değerlendirme modeline sensör kullanımı ile gürültü, titreşim, sıcaklık, aydınlatma, radyasyon, basınç, toz, hava kalitesi, yanıcı gazların tespiti ve giyilebilir sensörlerle çalışanların güvenli takibi ve buna benzer diğer teknolojik gelişmeler entegre edilerek daha kapsamlı ve gelişmiş modeller geliştirilebilir.

Böylece risk analiz sürecinde, insana ait emek yoğun faktörü büyük bir oranda ortadan kalkar, işyerindeki tehlikeler hızla tespit edilerek risk seviyeleri belirlenebilir, alınan önlemlerin etkinliği hakkında hızlı geri bildirim sağlanabilir. Bu da geleneksel risk analizi yaklaşımlarına olan gereksimi hızla ortadan kaldırır ve bu yeni yaklaşımın yaygınlaşmasına neden olabilir.

Kısacası bu yaklaşım geliştirilirse, kendi kendine öğrenen, otonom, karmaşık tehlikeleri oluşturduğu anda fark eden, uzmanlaşmış risk analiz sistemleri geliştirilebilir. Böylece işyerleri daha güvenli hale getirilebilir, iş kazaları azaltılabilir ve çalışanların daha güvenli çalışma ortamlarında, daha sağlıklı bir şekilde çalışmalarını sağlanabilir.

Teşekkür:

Bu çalışma İstanbul Gedik Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje numarası "GDK202207-09"

### Kaynakça

- Bingöl, K., Aslı, E. R., Örmecioğlu, H. T., & Arzu, E. R. (2020). Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(4), 2197-2210.
- Shinde, P. P., & Shah, S. (2018, August). A review of machine learning and deep learning applications. In 2018 Fourth international conference on computing communication control and automation (ICCCUBEA) (pp. 1-6). IEEE.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- Chowdhury, T. T., Hossain, A., Fattah, S. A., & Shahnaz, C. (2019, May). Seizure and non-seizure EEG signals detection using 1-D convolutional neural network architecture of deep learning algorithm. In 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT) (pp. 1-4). IEEE.
- Xu, J., Zhang, Z., Friedman, T., Liang, Y., & Broeck, G. (2018, July). A semantic loss function for deep learning with symbolic knowledge. In *International conference on machine learning* (pp. 5502-5511). PMLR.



- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523-3542.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Naftali, M. G., Sulistyawan, J. S., & Julian, K. (2022). Comparison of Object Detection Algorithms for Street-level Objects. *arXiv preprint arXiv:2208.11315*
- Mahendrakar, T., Ekblad, A., Fischer, N., White, R., Wilde, M., Kish, B., & Silver, I. (2022, March). Performance Study of YOLOv5 and Faster R-CNN for Autonomous Navigation around Non-Cooperative Targets. In *2022 IEEE Aerospace Conference (AERO)* (pp. 1-12). IEEE.
- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Çalışkan, D. & Demir, Ö. (2022). Derin Öğrenme Yöntemleri İle Şüpheli Davranış Tespiti . *International Periodical of Recent Technologies in Applied Engineering* , 3 (1) , 28-43 . Retrieved from <https://dergipark.org.tr/tr/pub/porta/issue/69017/1057149>
- Uddin, M. I., Zada, N., Aziz, F., Saeed, Y., Zeb, A., Ali Shah, S. A., ... & Mahmoud, M. (2020). Prediction of future terrorist activities using deep neural networks. *Complexity*, 2020.
- Nguyen Van, N., Le Thi, H., Phan Nhat, M., & Lai Ngoc Thang, L. (2022, June). Red-Light Running Violation Detection of Vehicles in Video Using Deep Learning Methods. In *Industrial Networks and Intelligent Systems: 8th EAI International Conference, INISCOM 2022, Virtual Event, April 21-22, 2022, Proceedings* (pp. 214-227). Cham: Springer International Publishing.
- Resmi Gazete (2012). 28512 Sayılı İş Sağlığı ve Güvenliği Risk Değerlendirmesi Yönetmeliği
- Özkılıç, Ö. (2005). İş Sağlığı ve Güvenliği Yönetim Sistemleri ve Risk Değerlendirme Metodolojileri (3. Baskı). Ankara, TİSK Yayını, No: 246.
- Sun, J., Cao, X., Liang, H., Huang, W., Chen, Z., & Li, Z. (2020, April). New interpretations of normalization methods in deep learning. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 34, No. 04, pp. 5875-5882).

### Extended Abstract

#### Aim and Scope

Deep learning is a widely used technology with applications in various sectors. In the field of occupational health and safety, this can help prevent occupational diseases and reduce accidents. Risk analysis and assessment are crucial activities that apply to all the workplaces. In the traditional approach, risk analysis and assessment activities are renewed at intervals of years for use over a long period. However, this approach can delay the recognition of risks and can cause accidents.

This study aims to identify and analyze risks in workplaces as soon as they occur and to reduce accidents in workplaces by taking advantage of the advantages of deep learning. By verifying that a risk can be detected and analyzed with deep learning through an example risk, it is argued that other risks can be detected using the same technique, so that this approach can be used effectively and comprehensively for risk analysis and assessment. The risk exemplified in the study is developed for a scenario where personal protective equipment (PPE) is mandatory and only authorized persons are allowed access and can be applied to all workplaces. This case study was intended as a resource for identifying similar risks. Similar studies can be conducted for other hazards using this model.

#### Methods

Due to the extensive and detailed nature of risk analysis and assessment work, a study was conducted to develop and validate a deep learning-based risk analysis and assessment model for a single hazard. The probability of occurrence of the hazard and the magnitude of the damage it could cause to employees if it occurred were calculated, and a sample risk analysis was created to cover probability and severity. The following steps were then taken to use the deep learning method to detect risks in the risk analysis:



**Data Collection:** A total of 840 datasets were collected for the deep learning training model. The data was gathered by examining potential hazards in areas or situations that are only accessible to authorized personnel using personal protective equipment (PPE).

**Data Preparation:** The collected data was converted into 416x416 pixel images and labeled for four classes after extensive and laborious work.

**Deep Learning Model Training:** The Yolov5 algorithm was used to train the deep learning model.

The trained model was evaluated using validation and test datasets. The validation dataset was used to evaluate metrics such as the loss functions, precision, recall, mean Average Precision (mAP), and F1 score at different training stages of the model. The test dataset was used to re-evaluate the model with new data not used in the training and to compare it with the training performance values.

### **Findings**

As a result of the training obtained using the deep learning method, it was found that 98% of authorized personnel using PPE, 91% of unauthorized personnel using PPE, 94% of unauthorized personnel using PPE, and 97% of unauthorized personnel not using PPE were correctly predicted.

In addition, training losses were close to zero, precision metric values were close to 90%, and sensitivity metric values exceeded 90%.

The mAP50 metric values were above 90%, and the mAP50-95 metric values were up to 80%.

The F1 metric value reached 96% with a confidence threshold of 0.698.

In the evaluation using the test dataset, the F1 metric value reached 92% with a confidence threshold of 0.5.

### **Conclusion**

In conclusion, deep learning-based risk analysis method proposed in this study achieved an F1 score of 96% in the object detection training model and exceeded 90% in the mAP50 metric value. When evaluated using the test data, an F1 score of 92% was achieved. Both evaluations show that the model can be a strong alternative to traditional risk analysis and assessment applications owing to its high accuracy.