



Makale / Research Paper

Koruyucu Gözlük Kullanımının Görüntü İşleme Yöntemiyle Tespit Edilmesi

Gülsemin BAŞARAN^{1a*}, Gültekin ÇAĞIL^{1b}

¹Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü. Sakarya/TÜRKİYE
gulsemin.basaran@ogr.sakarya.edu.tr

Received/Geliş: 30.05.2021

Accepted/Kabul: 19.11.2021

Öz: Bu çalışmada, İş Sağlığı ve Güvenliği önlemlerinden biri olan Koruyucu Gözlük kullanımının Görüntü İşleme yöntemiyle tespiti yapılmıştır. Yerleştirilen kamera aracılığı ile alınan gözlük görüntüleri, Görüntü İşleme ve Derin Öğrenme ile saptanmıştır. Çalışma gerçekleştirilirken Python Programlama Dili, Google Colab Platformu, OpenCV kütüphanesinden yararlanılmış ve nesne tanıma algoritmaları kullanılmıştır. Öncelikle, elde edilen Koruyucu Gözlük fotoğrafları bir dosyada toplanmış, MakeSense.Ai platformunda etiketleme işlemi gerçekleştirilmiştir. Her bir fotoğrafa ait tespit dokümanları alınarak koordinat bilgileri elde edilmiş, çıkan sonuçlar belli bir oranda test ve eğitim verisi olarak ikiye ayrılmış, Darknet yardımıyla Google Colab Platformu'na aktarılmıştır. Aktarılan veriler YOLOv4 Algoritması ile eğitilmiş, tüm sonuçlar Python OpenCV kütüphanesi aracılığıyla çalıştırılıp doğruluğu tespit edilmiştir. Görüntü İşleme ve Derin Öğrenme yöntemleri kullanılarak uygun sonuçlara ulaşılan bu çalışma, YOLOv4 Algoritmasının Google Colab Platformu üzerinde çalıştırılması ve bunun sonucunda, işletmelerde tam zamanlı İş Sağlığı Güvenlik önlemlerinin denetiminin kolaylaştırılması açısından yenilikçi bir bakış açısı getirmektedir.

Anahtar Kelimeler: İş Sağlığı ve Güvenliği, Koruyucu Gözlük, Derin Öğrenme, Görüntü İşleme, YOLOv4 Algoritması

Detection The Use Of Protective Glasses by Image Processing

Abstract: In this study, the use of Protective Glasses, which is one of the Occupational Health and Safety measures, was determined by Image Processing method. The glasses images taken through the placed camera were determined by Image Processing and Deep Learning. Throughout the study, Python Programming Language, Google Colab Platform, OpenCV library were used and object recognition algorithms were used. First of all, the obtained Goggles photos were collected in a file, and the labeling process was carried out on the MakeSense.Ai platform. Coordinate information was obtained by taking the detection documents of each photo, the results were divided into two as test and training data at a certain rate and transferred to the Google Colab Platform with the help of Darknet. The transferred data was trained with the YOLOv4 Algorithm, all results were run through the Python OpenCV library and their accuracy was determined. This study, which reached appropriate results by using Image Processing and Deep Learning methods, brings an innovative perspective in terms of running the YOLOv4 Algorithm on the Google Colab Platform and, as a result, facilitating the control of full-time Occupational Health and Safety measures in enterprises.

Keywords: Occupational Health and Safety, Goggles, Deep Learning, Image Processing, YOLOv4 Algorithm

1. Giriş

İş Sağlığı ve Güvenliği önlemleri birçok işletmede yerine getirilmesi zorunlu faaliyetlerdir. Uygulanmadığı takdirde kurum içerisinde çalışan kişilerin en temel haklarından biri olan yaşama hakkı ve sağlığını koruma hakkı ihlal edilmiş olunur. Alınan tedbirlerin sürekliliğini sağlamak amacıyla belli aralıklarla denetlemeler yapılarak süreç kontrol edilir fakat bu faaliyetler işletmeler

Bu makaleye atıf yapmak için

Başaran G., Çağıl, G., "Koruyucu Gözlük Kullanımının Görüntü İşleme Yöntemiyle Tespit Edilmesi" El-Cezeri Fen ve Mühendislik Dergisi 2022, 9(1); 86-95.

How to cite this article

Başaran G., Çağıl, G., "Detection The Use Of Protective Glasses by Image Processing" El-Cezeri Journal of Science and Engineering, 2022, 9(1); 86-95.

ORCID ID: *0000-0003-1720-626X; *0000-0001-8609-6178

için zaman ve iş gücü kaybına yol açar. Çalışmada denetleme faaliyetlerinin, geliştirilen sistem aracılığıyla yapılması sağlanarak, ek maliyet unsurlarının önüne geçilmesi amaçlanmıştır.

İş Sağlığı ve Güvenliği önlemlerinden biri olan Koruyucu Gözlükler, iş ortamında oluşabilecek herhangi bir likit sıçramaya, gaz, toz, erimiş metal veya yüksek sıcaklığa, UV ışınlarına, iyonize edici radyasyona ve elektrik arklarına karşı koruma sağlayarak işçilerin sağlıklı bir iş ortamında çalışmasını sağlamaktadır. İş yerlerindeki kazalar sonucu ortaya çıkan göz yaralanmaları ağırlı kornea erozyonu gibi sorunlara yol açacağı gibi işçiyi ömür boyu sakat da bırakabilir. Bu nedenle iş yerlerinde Koruyucu Gözlük kullanımı önem arz etmektedir.

Gelişen teknoloji ile birçok alanda dijital görüntü verileri artış göstermektedir. Bu nedenle verilerin işlenmesine ve yorumlamasına ihtiyaç duyulur. Görüntü İşleme tekniklerindeki amaç, ihtiyaç duyulan anlamlı bilgilerin, ham görüntülerden elde edilmesidir. Bunun yanında birçok bilgisayar, insan gözü ile algılanması istenen nesnelere tespit etmek amacıyla eğitilir. Eğitim sürecinin doğru ve eksiksiz gerçekleşebilmesi için nesne tespiti yapan Derin Öğrenme yöntemleri oldukça önem taşımaktadır. Derin Öğrenme, sistemin deneyimleyerek öğrenmesidir. Bunun yanında dünyayı kavramlar sınıflandırması açısından anlamak için eğitilen bir makine öğrenmesidir [1]. Derin Öğrenme birden çok işleme katmanından oluşur, bu sayede verilerin temsillerinin öğrenilmesine olanak tanır.

Günümüzde Görüntü İşleme faaliyetleri birçok alanda kullanılmaktadır. Görüntü İşleme faaliyetlerinin temel amacı, belirlenen bir görüntü üzerindeki bilgilerin, komutlar aracılığı ile doğru şekilde okunması ve işlenmesidir. Nesne tespiti işlemi, görüntü işleme yöntemlerinden biridir. Bu çalışmada nesne tespiti yapmak amacıyla YOLOv4 Algoritması, Python Programlama Dili ve OpenCV kütüphanesi kullanılmıştır. Darknet Sinir Ağı Çerçevesi aracılığıyla Google Colab Platformu üzerinden eğitim işlemi gerçekleştirilmiştir.

Python Programlama Dili içerisinde barındırdığı birçok kütüphaneyi destekleme ve işleme kolaylığı sağlar. Bu kütüphanelerden biri de OpenCV kütüphanesidir. OpenCV Görüntü İşleme yöntemlerini barındırarak görüntüleri düzenlemek ve sonuçları görmek için kullanılmıştır. YOLOv4 Algoritması daha hızlı bir sonuç almak amacıyla, Google Colab Platformu ise görüntülerin işlenmesi ve eğitim işlemi gerçekleştirilmesi amacıyla kullanılmıştır.

Literatür çalışmalarına bakıldığında nesne tespiti amacıyla çeşitli YOLO algoritmalarının kullanıldığı görülür. Bu çalışmanın farkı, YOLO algoritmalarının son versiyonlarından biri olan YOLOv4 Algoritmasının, İş Sağlığı ve Güvenliği önlemlerinin tespitinde kullanılmasıdır. YOLOv4 Algoritmasının Google Colab platformu üzerinde çalıştırılarak Koruyucu Gözlük Kullanımının tespit edilmesi, çalışmaya özgünlük katar. Bunun yanında çalışmanın, İş Sağlığı ve Güvenliği önlemlerinin yaygınlaştırılması ve tam zamanlı denetlenmesi amacıyla yapılmış olması, yenilikçi yaklaşımını göstermektedir.

2. Literatür Özeti

Literatürde YOLOv4 Algoritmasının kullanıldığı örnekler mevcuttur. Tian ve arkadaşları değişken aydınlatmalı, karmaşık meyve bahçelerinde farklı büyüme aşamalarında elmaları tespit etmek için geliştirilmiş bir YOLOv3 modeli önermişlerdir. Modeli eğittikten sonra, eğitilen modelin performansı bir test veri kümesinde test edilmiştir. Test sonuçları, önerilen YOLOv3-Dense modelin, orijinal YOLOv3 modelinden ve son teknoloji meyve algılama modeli olan VGG16 net modeliyle Hızlı R-CNN'den daha üstün olduğunu göstermektedir. Modelin ortalama algılama süresi, 3000×3000 çözünürlükte kare başına 0.304 saniyedir ve bu, meyve bahçelerindeki elmaların gerçek zamanlı olarak algılanmasını sağlayabilmektedir [2].

Dihua Wu ve arkadaşlarının yaptığı çalışmada doğal ortamlarda elma çiçeklerinin hızlı ve doğru bir şekilde tespit edilmesi sağlanmıştır. Çalışmada channel pruning-based YOLOv4 Derin Öğrenme algoritmasını kullanan gerçek zamanlı bir elma çiçeği algılama yöntemi önerilmiştir. Elma çiçeklerinin hızlı ve doğru bir şekilde algılanmasını sağlamak için manuel olarak etiketlenmiş toplam 2230 elma çiçeği görüntüsü kullanılmıştır. Test sonuçları, budama sonrası elma çiçeği tespit modelinin parametre sayısının %96,74, model boyutunun 231,51 MB, çıkarım süresinin %39,47 azaldığını ve mAP (mean Average Precision/Ortalama Kesinlik Değerlerinin Ortalaması)'in %97,31 olduğunu göstermiştir. Önerilen yöntemin etkinliğini doğrulamak için, beş farklı Derin Öğrenme algoritması karşılaştırılmıştır. Karşılaştırmalı sonuçlar, önerilen yöntem kullanılarak elma çiçeği saptama işleminin %97.31 olduğunu göstermiştir. Çalışma sonucunda elde edilen mAP değeri diğer beş algoritmadan sırasıyla %12.21, %15.56, %14.19, %5.67 ve %7.79 daha yüksektir ve algılama hızı gerçek zamanlı gereksinimleri karşılayabilmektedir. Sonuçlar, elma çiçeklerinin gerçek zamanlı ve doğru tespiti için önerilen yöntemin uygulanmasının mümkün olduğunu göstermiştir [3].

Çağıl ve Yıldırım tarafından yapılan çalışmada Bir Montaj Parçasının Derin Öğrenme ve Görüntü İşleme ile tespiti yapılmıştır. Oluşabilecek hatalı durumları önleyebilmek adına belirlenen aksesuar parçası, YOLOv4 Algoritması ile etiketlenip ilgili parça tespit ve test edilmiştir. Uygulama sonunda kamera ile 25 deneme yapılmış ve 21 denemede sistem görüntü üzerinde bulunan parçaları tam olarak tanımıştır. Bu bilgiler ışığında çalışmanın %84 oranda doğru çalıştığı görülmüştür [4].

Aktaş ve arkadaşları tarafından nesne tespiti için kullanılan YOLOv3 modeli DenseNet modeli ile birleştirilerek bir çalışma yapılmıştır. YOLOv3-Dense modeli oluşturulması ardından YOLOv3-Dense modelinin diğer modellerden daha iyi olduğu gözlemlenmiştir [5].

İş Sağlığı ve Güvenliği önlemlerinin alınması amacıyla yapılan ilk çalışmalardan biri Fang ve arkadaşlarının bir inşaat senaryosunda işçilerin baret kullanmadıklarını tespit etmek için Hızlı R-CNN sinir ağı sistemini kullandıkları çalışmadır [6]. Ayrıca Bo ve arkadaşları geliştirdikleri algılama modeli ile inşaat alanlarında baret takılıp takılmadığını algılamak amacıyla YOLOv3 modeli ile nesne tespiti yapmışlardır [7].

Torres ve arkadaşlarının yaptıkları çalışma ile Kişisel Koruyucu Ekipman (KKD)'lerin çalışan işçiler tarafından kullanımının tespiti amacıyla derin öğrenmeye dayalı iki farklı yaklaşım geliştirilmiştir. Çalışmada iki tür KKD'ye (baret ve koruyucu gözlük) odaklanılmasına rağmen, sonuçlarına göre bu tespit için herhangi bir sayıda ekipmana uygulanabileceği tespit edilmiştir. Yaklaşım I için, tek aşamada uygulanan YOLOv4'e dayalı bir model oluşturulmuştur. Yaklaşım II ise tanımlama ve doğrulama aşamalarını kapsar ve iki aşamalıdır. İlk olarak, YOLOv4'e dayalı bir model kullanarak görüntülerden sınırlayıcı kutuları tespit edilir. Daha sonra, KKD uyumluluğunun doğrulanması için evrişimli bir sinir ağı uygulanır. Geliştirilen iki yaklaşım sonunda, Yaklaşım I KKD'leri tespit etme konusunda daha başarılı bir mAP sonucu verir. (% 80,19) Yaklaşım I, yalnızca mAP açısından değil, aynı zamanda işlem süresi açısından da daha verimli olduğu için, yaklaşım II'ye kıyasla 11 kata kadar daha hızlı (80 FPS) değere ulaşır [8].

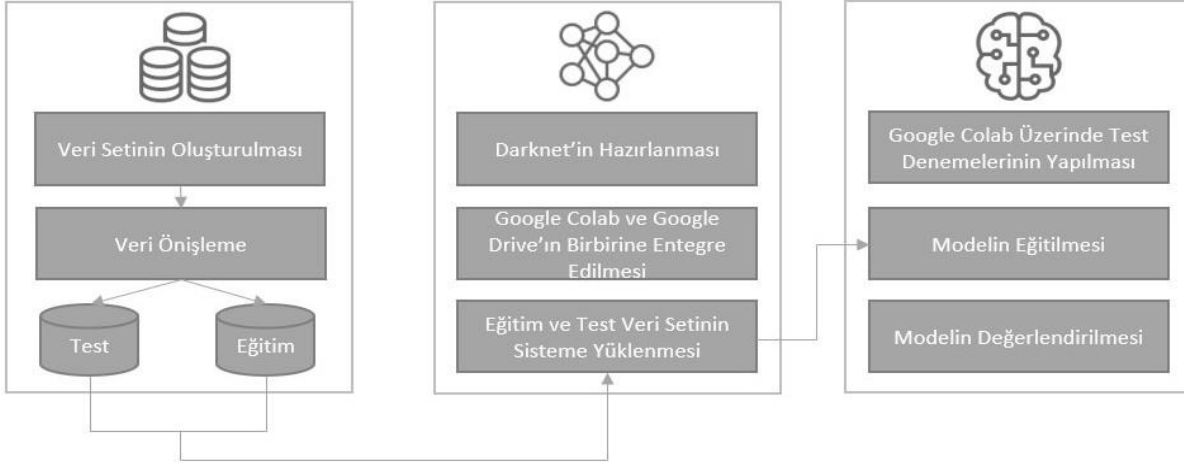
Yapılan literatür taraması sonucunda, İş Sağlığı ve Güvenliği önlemlerinin YOLOv4 Algoritması ile tam zamanlı şekilde tespit edildiği bir çalışmaya rastlanılmamıştır. Koruyucu Gözlük Kullanımının denetlenmesinde, YOLOv4 Algoritmasının Google Colab Platformu üzerinde kullanılması ile çalışmaya özgünlük katılmıştır. İş Sağlığı ve Güvenliği önlemlerinin kolayca ve sürekli bir şekilde kontrolünün tasarlandığı bu çalışma, literatüre farklı bir yaklaşım ve üzerinde çalışılması gereken özel bir alan sunmaktadır.

3. Materyal ve Metot

Yapılan çalışmada, İş Sağlığı ve Güvenliği önlemlerinden biri olan Koruyucu Gözlük tespiti gerçekleştirilmiştir. Nesne tespiti algoritmaları sayesinde Koruyucu Gözlük kullanımı saptanmış ve

tam zamanlı bir sistem ile işletmeler içerisindeki İş Sağlığı ve Güvenliği önlemleri alınması zorunlu alanlarda, koruyucu önlemler kolayca denetlenmiştir. Çalışmada Görüntü İşleme ve Derin Öğrenme yöntemlerinden faydalanılmış ve tam zamanlı İş Sağlığı ve Güvenliği yaklaşımı geliştirilmiştir.

Gerçekleştirilen çalışma Şekil 1’de görüldüğü gibi temel olarak 3 adımda oluşturulmuştur. Birinci adımda veri setinin hazırlanması, ikinci adımda derin öğrenme yaklaşımı için gerekli alt yapının kurulması, üçüncü adımda ise sistemin eğitilmesi ve test edilmesi işlemleri gerçekleştirilmiştir.



Şekil 1. Sistem Mimarisi

3.1. Veri Seti

Çalışma gerçekleştirilirken birçok farklı koşullarda çekilmiş 800 adet fotoğraf, veri setine eklenmiştir. Veri setinin içerisine Koruyucu Gözlük kullanılmayan fotoğraflar da dahil edilmiş, veri setinin çeşitliliği sağlanmıştır. Bunun nedeni, nesne tespitinin yapılacağı ortamdan kaynaklanan yetersiz koşulları göz önünde bulundurarak programın en yüksek saptama oranıyla çalışmasını sağlamaktır.

Veri Seti oluşturulduktan sonra elde edilen görüntülerin YOLO formatına uygun şekilde etiketlenmesi gerekir. Bu aşamada ücretsiz ve kolay bir online yazılım olan MakeSenseAI yazılımından yararlanılmıştır. Etiketleme işlemi, tespiti yapılacak nesnenin köşe noktalarının seçilip birleştirilmesiyle gerçekleştirilmiştir. Bu işlem sonunda oluşan YOLO formatına uygun metin dosyaları, eğitim işleminde kullanılmak üzere dosyalanmıştır.



Şekil 2. Etiketlenen Veri Örnekleri

YOLOv4 Algoritması ile eğiteceğimiz görüntüleri veri setinde topladıktan sonra bu veri setinin, eğitim ve test veri seti olarak ikiye ayrılması gerekmektedir. Eğitim veri seti, görüntüleri eğitme işlemi gerçekleştirirken test veri seti, gerçekleştirilen modeli değerlendirir. Eğitim veri seti büyüdükçe model daha iyi eğitilecek, test veri seti büyüdükçe ise daha sıkı güven aralıkları oluşacaktır. Bu nedenle görüntülerin yüzde 80'i eğitim, yüzde 20'si ise test için kullanılmıştır.

3.2. Derin Öğrenme

Derin Öğrenme, makine öğrenmesi alanının alt konularından biri olup aynı zamanda en güncel konusudur. İnsan beyninin yapısından esinlenerek oluşturulan yapay sinir ağı algoritmaları, Derin Öğrenme yöntemlerinde kullanılmaktadır.

Derin Öğrenme, göreve özgü algoritmaların aksine, öğrenme veri temsillerine dayalı daha geniş bir makine öğrenimi yöntemleri ailesinin bir parçasıdır. Derin Öğrenme, makine öğrenimi alanında yapılan çalışmalarla beraber Yapay Zeka kapsamının genişlemesine de öncülük etmiştir. Yüzeysel öğrenme ile karşılaştırıldığında Derin Öğrenme kavramı daha soyut bilgilere ulaşmak için derin katmanlar inşa etme avantajına sahiptir [9].


Derin Öğrenme tabanlı yöntemler, birçok alanda başarıyla kullanılmaktadır. Bunlardan biri de otomatik nesne tespittir. Bu çalışmada, Derin Öğrenme tabanlı nesne algılama yöntemi You Only Look Once (YOLO) algoritmasının bir versiyonu olan YOLOv4 ile Koruyucu Gözlük kullanımının tespiti yapılmıştır.

3.3 Konvolüsyonel Sinir Ağları (CNN)

Sinir ağları olarak da bilinen evrimsel ağlar veya CNN'ler, ızgara biçimli bir yapıya sahip verileri işlemek için kullanılan özel bir sinir ağı türüdür [1]. Konvolüsyonel Sinir Ağları (CNN) Derin Öğrenme mimarilerindedir ve tamamen birbiriyle bağlantılı bir dizi ardışık katmanlardan oluşur. Lecun tarafından önerilen evrimsel sinir ağları, görüntü tespit etmede en başarılı yöntemlerden biridir [10].

3.4. YOLO Algoritması

YOLO, Joseph Redmon tarafından geliştirilmiş, Derin Öğrenmeye dayalı bir nesne tanıma algoritmasıdır. YOLO sınırlayıcı kutuları ile birlikte sınıf olasılıklarını tahmin etmek için tek bir sinir ağı kullanarak nesne tespiti işlemini gerçekleştirir. YOLO' nun mimarisi konvolüsyonel sinir ağı tabanlı olup hızlı bir yapıya sahiptir.




Şekil 3. YOLO Modelinin Evrimsel Sinir Ağı [11]

YOLO, tek bir sinir ağı kullanarak nesne algılamayı sadece bir regresyon problemi olacak şekilde ele alır. Bunun yanında YOLO, sınırlayıcı kutuları ve sınıf olasılıklarının tahmininde de tek bir sinir ağı çerçevesi kullanır. Tespit işlemi gerçekleştirilirken YOLO algoritması, ilgili fotoğrafı SxS'lik ızgaralara bölerek fotoğraftaki tüm nesnelerin sınıfını ve koordinatlarını tahmin eder. Böylelikle nesne tespitini tek bir regresyon problemi şeklinde ele almış olur. YOLO, konum koordinatlarını ve nesnelerin sınıflandırılmasını aracısız bir şekilde doğrudan hesaplayabilir. Görüntüleri saniyede 45 kare hızında işler böylece kullanıcılara gerçek zamanlı bir nesne tespiti yapma imkânı sunar [12]. Bu sayede diğer yöntemlerden daha hızlı bir tahmin gücüne sahiptir. YOLO' nun açılımı, "You Only Look Once" "Sadece Bir Kez Bak" demektir. Bu nesne tespiti yapılacak alanda, algılaması gereken nesneyi sadece bir kez ağ içinden geçirip tespit işlemini tamamladığı anlamına gelir. Literatüre bakıldığında en hızlı genel amaçlı nesne tespiti yöntemidir.

Bu çalışmada YOLO mimarilerinin diğer yaklaşımlarına göre daha yüksek doğruluğa sahip bir yaklaşımı olan YOLOv4 modeli kullanılmıştır ve çalışmanın performansları ölçülmüştür.

YOLOv4 Algoritmasının katman sayısı: 162; ağırlık (MiB): 245.7'dir. YOLOv4 Algoritmasının bir önceki sürümü olan YOLOv3'ten tek farkı omurgasıdır. YOLOv3, Darknet53 omurgasına sahipken YOLOv4 CSPDarknet53 omurgasına sahiptir. Ayrıca, YOLOv4 mimarisinde omurga aşamasında Mish isimli farklı bir aktivasyon fonksiyonunun tercih edilmiştir. Boyun bölgesinde ise YOLOv4'de SPP (Spatial Pyramid Pooling) bloğu mimariye dahil edilmiştir [13].

Doğrusal olmayan sinir ağlarında kullanılan aktivasyon fonksiyonları, ağı eğitimi ve performans değerlendirmesinde büyük rol oynar. ReLU, Swish, Tanh ve Mish fonksiyonları en bilinen aktivasyon fonksiyonlarına örnek olarak verilir. YOLOv4 mimarisinde de kullanılan Mish aktivasyon fonksiyonu, diğer fonksiyonlarla kıyaslandığında yeni ve monoton olmayan bir yaklaşım ortaya koyar. Deneyler Mish'in zorlu veri kümelerinde birçok derin ağda diğer standart etkinleştirme işlevleriyle birlikte hem ReLU'dan hem de Swish'ten daha iyi çalışma eğiliminde olduğunu gösterir [14]. Mish, 1 numaralı denklemde tanımlanmıştır ve Mish grafiği Şekil 4'te gösterilmiştir.



Şekil 4. Mish Aktivasyon Fonksiyonu

$$f(x) = x \cdot \tanh(\zeta(x)) \quad (1)$$

3.5 Google Colab Platformu

Google Colaboratory daha yaygın olarak "Google Colab" veya kısaca "Colab", GPU'lar ve TPU'lar gibi güçlü donanım seçeneklerinde, makine öğrenimi modellerinin prototipini oluşturmaya yönelik bir araştırma projesidir. Google Colaboratory, sunucusuz bir Jupyter dizüstü bilgisayar ortamı sağlayarak kullanıcılara etkileşimli geliştirme imkânı verir [7]. Böylece Google Colab Platformu,

gerekli donanımlara sahip olmayan bir bilgisayar aracılığıyla online bir başka bilgisayara bağlanarak eğitim işlemini gerçekleştirebilme olanağı sağlar.

4. Bulgular ve Tartışma

Koruyucu gözlük tespiti için oluşturulan veriler, test ve eğitim veri setlerine ayrılmıştır. Ardından Darknet yardımıyla Google Colab Platformu'na aktarılmıştır. Aktarılan veriler YOLOv4 Algoritması ile eğitilmiştir. Eğitim işlemini test etmek için veri setlerinin içinde bulunmayan 50 görüntü kullanılmıştır. Yapılan tespit işlemi bulguları ile model birçok yönden değerlendirilmiş, Koruyucu Gözlük veri seti test sonuçları için Karışıklık matrisi göz önüne alınmıştır.

Tablo 1.Karışıklık Matrisi (Confussion Matrix).

	Positive	Negative
Positive	True Positive (TP)	False Negative (FN)
Negative	False Positive (FP)	True Negative (TN)

Karışıklık Matrisi, sınıflandırma modelinin gerçek değerlerin bilindiği bir dizi test verisi üzerindeki performansını açıklamak için kullanılan bir tablodur.

Karışıklık Matrisinin çalışmamıza uyarlanması halinde elde edilen sonuçlar Tablo 2’de verilmiştir.

Tablo 2. Karışıklık Matrisi Açıklaması.

Terimler	Sonuçlar
True Positive (TP)	Koruyucu Gözlük taktığını tahmin ettiniz ve bu doğru
True Negative (TN)	Koruyucu Gözlük takmadığını tahmin ettiniz ve bu doğru
False Positive (FP)	Koruyucu Gözlük taktığını tahmin ettiniz ve bu yanlış
False Negative (FN)	Koruyucu Gözlük takmadığını tahmin ettiniz ve bu yanlış

Kesinlik Oranı (Precision) nesne algılama faaliyetlerinde kullanılan değerlendirme yöntemlerinden biridir. Doğru şekilde tahmin edilen nesnelere, hem doğru hem de yanlış olarak tahmin edilen tüm nesnelere oranıdır. Model tarafından değerlendirilen tüm pozitif vakalar için sayı TP + FP şeklinde gösterilir. Gerçek vakaların sayısının, tüm pozitif vakaların sayısına oranı (Kesinlik Oranı - Precision) 2 numaralı denklemde verilmiştir.

Hatırlama Oranı (Recall) modelin test setindeki gerçek durumları algılama yeteneğini ölçmek için kullanılır. Test setindeki tüm pozitif örnekler için (TP + FN) sayı olarak ele alınır. Gerçek vakaların sayısının, test setindeki tüm pozitif örnek sayılarına oranı, Hatırlama Oranı (Recall) olarak 3 numaralı denklemde verilmiştir.

F1 değeri 4 numaralı denklemde gösterilen şekilde daha önce bulunan değerler sayesinde hesaplanır. F1 değeri ne kadar yüksekse modelin test işlemi de o kadar etkili olacaktır [15].

$$Precision = \frac{P}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$


$$F1 = \frac{2 \times Precision \times Recall}{Precision+Recall} \quad (4)$$

Nesne algılama modellerinde kullanılan mAP değeri, doğruluk tespiti için ortak bir parametreyi ifade eder ve her bir nesne sınıfı için ortalama hassasiyetin (AP) ortalamasını gösterir [16].

IoU (Intersection over Union/Kesiştirilmiş Bölgeler) değeri ise nesne algılama sistemlerini değerlendirmek için kullanılan bir metrik sistemdir. Tipik olarak, IoU 0,5'e eşit veya daha büyük olduğunda, tahminin doğru olduğu kabul edilir. Bu çalışmada IoU eşiği 0,5 olarak alınmıştır.

YOLO modelindeki sınırlayıcı kutular, modelin içerisinde bulunan hücreler tarafından üretilmektedir. YOLO mimarisinde, TP durumlara bakılarak IoU değeri en yüksek olan kutular seçilir. Bu seçim sonucu yitim değerleri hesaplanır. YOLO yitim değerlerini hesaplamak için her bir tespitin doğru yere yerleştirilmesi amacıyla koşullu sınıf olasılıklarının kare hatasını hesaplayan sınıflandırma yitimi, çizilen sınır çerçevelerinin konumunun ve boyutunun hatalarını hesaplayan yerini saptama yitimi ve son olarak nesne tespit edildiği zaman tespit eden kutunun güven değerini hesaplayan güven yitimi değerlerini kullanır. [17].

Çalışma sonunda elde edilen yitim fonksiyonu grafiği Şekil 5'te verilmiştir.



Şekil 5. Yitim Fonksiyonu Grafiği

Uygulama adımlarının ardından modelin IoU, TP, FP ve FN değerlerine bakılmış, modelin hassasiyeti (Precision) hesaplanmış ve ardından mAP ve IoU değerleri tespit edilmiştir. Geliştirilen model değerlendirildiğinde varılan sonuçlar, Tablo3'te gösterilmiştir.

Tablo 3. Değerlendirme Sonuçları.

Değerlendirme Faktörleri	Sonuçlar
TP	118
FP	8
FN	1
Average IoU	74.31 %
Precision	94 %
Recall	99 %
F1-score	96 %
mAP	98.80 %
IoU	54 %

Model sonuçlarına bakıldığında, F1-score değeri 96 %, IoU değerinin 54 % , mAP değerinin 98.80 % olarak çıktığı görülmektedir. 96 % değerindeki F1-score, bizlere modelin test işleminin etkili olduğunu kanıtlar. IoU'nun 0.5'ten büyük olduğu durumlar TP sayılmakta, IoU'nun 0.5'in altında olduğu durumlar ise FP sayılmaktadır. Bu durumda IoU değerinin 54 % olarak hesaplanması

oluşturulan modelin TP olduğunu ortaya koyar. mAP sonucuna bakıldığında ise 98.80 % oranla her bir nesne sınıfı için ortalama hassasiyetin yeterli bir değerlerde olduğu saptanır.

5. Sonuçlar

İş Sağlığı ve Güvenliği önlemlerinden biri olan Koruyucu Gözlük kullanımı, işletmelerde yetkin kişiler tarafından belirli aralıklarla denetlenir. Bu denetleme işi, fazladan iş gücü gerektirdiğinden işletmelere ek maliyet olarak yansır.

Bu çalışmada Koruyucu Gözlük kullanımını denetleyen bir sistem tasarlanmıştır. Nesne tespiti yapmak için gerekli 800 adet görüntü toplanmış ve bu görüntülerin %80'i eğitim, %20'si test veri olarak ayrılmıştır. Ardından nesnelerin etiketlenmesi için MakeSenseAI Resim Etiketleme Programı, eğitim işlemi için Google Colab Platformu ve Darknet Sinir Ağı Çerçevesi, sonuçların tespit edilmesi için Python Programlama Dili, Görüntü İşleme algoritmaları için OpenCV kütüphanesi kullanılmıştır. Görüntülerdeki nesneler yazılan Python kodları ve YOLOv4 Algoritması ile tespit edilmiştir. Çalışmanın sonunda 50 görüntü sisteme yüklenmiş ve deneme yapılmıştır. Yapılan deneme sonucu çıkan tahminlerin 48'i doğrudur. Bu sonuca göre sistem %96 oranında doğru çalışmaktadır. Çalışmanın performans değerleri ölçülmüş, mAP değeri 0.989; IoU değeri 0,545 olarak bulunmuştur.

Sistemin iş yerlerinde uygulanması durumunda Koruyucu Gözlük denetleme işlemi, iş yükünün hafiflemesine neden olacak, denetleme işleminin yol açtığı maliyetleri ortadan kaldıracak, denetlemenin aksatılmasının önüne geçilecek, çalışanları tam zamanlı denetlendiklerini bilmeleri bu konuya verilen önemi arttıracaktır ve böylece daha verimli ve sağlıklı bir iş ortamı oluşturulacaktır.

Yazarların Katkıları

GB makaledeki analiz ve deney çalışmalarını GÇ danışmanlığında yürüttü. GB makale yazımını yaptı. Her iki yazar da makalenin son halini okudu ve onayladı.

Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

Kaynaklar

- [1]. Kim, K. G., "Deep learning", Healthcare informatics research, 2016, 22(4): 351-354.
- [2]. Tian, Y., Yang, G., Wang, Z., Wang, H., Li, E., & Liang, Z., "Apple detection during different growth stages in orchards using the improved YOLO-V3 model", Computers and electronics in agriculture, , 2019, 157, 417-426.
- [3]. Wu, D., Lv, S., Jiang, M., & Song, H., "Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments", Computers and Electronics in Agriculture, 2020, 178, 105742.
- [4]. Çağrı, G., Yıldırım, B., "Bir Montaj Parçasının Derin Öğrenme ve Görüntü İşleme ile Tespiti", Zeki Sistemler Teori ve Uygulamaları Dergisi, 2020, 3(2): 31-37.
- [5]. Aktaş, A., Doğan, B., & Demir, Ö., "Tactile paving surface detection with deep learning methods" , Journal of the Faculty of Engineering and Architecture of Gazi University, 2020,35(3): 1685-1700.
- [6]. Fang, Q., Li, H., Luo, X., Ding, L., Luo, H., Rose, T. M., & An, W., "Detecting non-hardhat-use by a deep learning method from far-field surveillance videos", Automation in Construction, 2018, 85, 1-9.

- [7]. Bo, Y., Huan, Q., Huan, X., Rong, Z., Hongbin, L., Kebin, M., ... & Lei, Z., "Helmet Detection Under The Power Construction Scene Based On Image Analysis", In 2019 IEEE 7th international conference on computer science and network technology (ICCSNT), Dalian, China, 67-71, (2019)
- [8]. Lopes, H. C. V., "A Robust Real-time Component For Personal Protective Equipment Detection In An Industrial Setting", PhD Thesis, PUC-Rio ,(2021).
- [9]. Coşkun, M., YILDIRIM, Ö., Ayşegül, U. Ç. A. R., & Demir, Y., "An overview of popular deep learning methods", European Journal of Technique, 2017, 7(2): 165-176.
- [10]. Altuntaş, Y., Cömert, Z., & Kocamaz, A. F. "Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach", Computers and Electronics in Agriculture, 2019,163, 104874.
- [11]. Jiang, R., Lin, Q., & Qu, S. "Let Blind People See: Real-Time Visual Recognition With Results Converted to 3D Audio",Report No. 218, Standord University, Stanford, USA, (2016).
- [12]. Redmon, J., & Farhadi, A., "YOLO9000: better, faster, stronger.", In Proceedings of the IEEE conference on computer vision and pattern recognition, 7263-7271, (2017).
- [13]. Rezaei, M., & Azarmi, M., "Deepsocial: Social distancing monitoring and infection risk assessment in covid-19 pandemic". Applied Sciences, 2020, 10(21): 7514.
- [14]. Misra, D., "Mish: A Self Regularized Non-monotonic Activation Function", arXiv preprint arXiv:1908.08681, (2019).
- [15]. Yu, J., & Zhang, W., "Face mask wearing detection algorithm based on improved YOLO-v4. Sensors", 2021, 21(9): 3263.
- [16]. Guo, F., Qian, Y., & Shi, Y., "Real-time railroad track components inspection based on the improved YOLOv4 framework", Automation in Construction, 2021, 125, 103596.
- [17]. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. "You only look once: Unified, real-time object detection". In Proceedings of the IEEE conference on computer vision and pattern recognition,779-788,(2016).