

**EĞİTİM KURUMLARI ÇEVRESİNDEKİ ŞÜPHELİ İNSAN DAVRANIŞLARININ
DERİN ÖĞRENME YARDIMI İLE ANLIK TESPİTİ**

Can ATILA (Orcid ID: 0000-0003-3671-2387)

Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
Bölümü, Kütahya

Dr. Öğr. Üyesi Arif BASGUMUS (Orcid ID: 0000-0002-0611-3220)

Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü,
Bursa.

Doç. Dr. Mustafa NAMDAR (Orcid ID: 0000-0002-3522-4608)

Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
Bölümü, Kütahya

ÖZET

Bu çalışmada, eğitim kurumlarında oluşması muhtemel güvenlik zafiyetlerinin derin öğrenme çözümlerini kullanarak en aza indirgenmesi hedeflenmektedir. Oluşturulan sistem eğitim kurumlarının iç ve dış mekânlarında bulunan insan davranışlarını tehlikeli, şüpheli ve normal olarak ayırt etmek için kesici ve delici alet tespiti yapmaktadır. Tespit edilen davranışlar sayesinde kurum içerisindeki öğrencilerin daha güvenli bir eğitim modeline ulaşması sağlanmaktadır. Öğrencilerin güvenli eğitim ortamına ulaşmasının sağlandığı bu projede Derin Öğrenme Sınır Ağ Modeli eğitilerek, kamera yardımıyla elde edilen görüntüler yoluyla insan davranışları kategorize edilmektedir. %90 üzerinde başarılı tahminler ile ateşli silahlar ve kesici aletler tespit edilebilmektedir.

**A SYSTEM FOR DETECTING DANGEROUS AND SUSPICIOUS HUMAN
BEHAVIOR FOR EDUCATIONAL INSTITUTIONS****ABSTRACT**

This study aims to minimize the security vulnerabilities that may occur in educational institutions by using deep learning solutions. The designed system detects cutting and piercing tools to distinguish between dangerous, suspicious, and normal human behaviors in indoor and outdoor spaces of educational institutions. Thanks to the detected behaviors, it is ensured that the students in the institution reach a safer education model. In this project, where students are provided with safety education, Deep Learning Neural Network Model is trained and human behaviors are categorized with the images obtained with the help of the camera. Pistols and knives can be detected with over 90% of successful predictions.

GİRİŞ

Eğitim kurumları için güvenlik kavramı çok boyutlu ve hassas bir konudur. Okul güvenliği araştırmaları okullarda, öğrenci ve okul çalışanlarının fiziksel, sözel ve psikolojik güvenliği gibi temel konularda problem yaratabilecek, suç ve şiddet olaylarının (psikolojik şiddet, hırsızlık, örgütlenme, okula silah, bıçak vb. gibi kesici aletler getirilmesi...) yaşanabileceğini bize göstermektedir. Ayrıca okulda ve çevresinde yaşanan bu suç olaylarının okulun bulunduğu konuma, okul binasının bulunduğu yerde yaşayan insanlara, okul güvenliğine, öğrencilerin ve okul personelinin bireysel özelliklerine hasar verdiği ve etkilediği gözlemlenmektedir [1]. Bu sorunlara yönelik olarak güvenlik sistemleri geliştirilmektedir.

Güvenlik sistemleri iç ve dış mekânlar için geniş uygulama alanlarına sahiptir. Özellikle güvenlik kameraları temel korumanın ayrılmaz bir parçasıdır. Bu kameralar insanları güvenlik amacıyla kayıt altına almaktadır. Kayıt altına alınan veriler incelenerek problem tespit edilmektedir. Güvenlik kamerasına yansıyan bütün olayların insanlar tarafından manuel olarak incelenmesi mümkün değildir. Bu problem sistemin verimini büyük ölçüde azaltmaktadır. Çünkü uzun süreli video verileri incelemek müdahaleyi geciktirmekte ve zaman kaybına yol açmaktadır. Günümüzde yapay zekâ, makine öğrenmesi ve derin öğrenme sistemlerine sahip teknolojiler insan gücünün ulaşamayacağı hızda çözümler üretmektedir. Video gözetim sistemleri ile bu teknolojilerin kombinasyonu öngörülemeyen güvenlik açıklarını yüksek hızlarda tespit edebilmektedir. Derin öğrenme yaklaşımı kullanılarak insan davranışları incelenebilmekte ve bu davranışların şüpheli ya da normal olup olmadığı tahmin edilebilmektedir [2]. Derin öğrenme yaklaşımının avantajları, etkili izleme, daha az insan kaynağına ihtiyaç duyulması, uygun maliyet, hızlı şüpheli aktivite tespiti, yeni güvenlik eğilimlerini benimsenmesi, öngörülemeyen suç oranının azaltılması şeklinde sıralanabilir.

Literatürde nesne tanıma ile ilgili yapılan çalışmalar incelendiğinde; [3]'te SSD MobileNet V2 algoritması kullanılarak, istenmeyen tehdit unsuru nesnelerin eğitildiği ve bu nesnelerin tespitinin sağlandığı görülmektedir. Bu çalışmada nesnelerin tespiti hususunda %91 oranında başarı sağlanmıştır. [4]'te ise tarım ürünleri, nesne tanıma yöntemleri kullanılarak tespit edilmiş ve bu ürünlerin toplanması için robot kol tasarlanmıştır. Nesne tanıma yöntemleri kullanarak farklı alanlarda iş faaliyetlerinin de gerçekleştirilebileceği bu bildiride görülebilmektedir.

Bu çalışma ile eğitim kurumlarında oluşan güvenlik zafiyetlerinin YoloV5 yapay zekâ modeli üzerinde, eğitilen silah ve bıçak verilerinin tespiti ile en aza indirgenmesi sağlanmaktadır. Oluşturulan sistem eğitim kurumlarının iç ve dış mekânlarında bulunan insan davranışlarını

tehlikeli, şüpheli ve normal olarak ayırt edip etiketlemektedir. Etiketleme sistemi kesici aletlerin varlığının olup olmaması ile çalışmaktadır. Etiketlenen davranışlar sayesinde kurum içerisindeki öğrencilerin daha güvenli bir eğitim modeline ulaşması sağlanmaktadır.


Bölüm 2’de sistem modeli aktarılmakta ve çalışmadaki hazırlık ve süreç aşamalarından bahsedilmektedir. Nesne tespiti için gerekli eğitim, test ve doğrulama verileri sunulmaktadır. Eğitim yapılacak olan algoritmanın tercihi ve çalışma mekanizması verilmektedir. Eğitim sonuçları ve bu sonuçlardan elde edilen çıkarımlar yine aynı bölümde aktarılmaktadır. Bölüm 3’te genel olarak çalışmanın sonuçları ve literatüre olan katkısından bahsedilmektedir.

SİSTEM MODELİ

Bu çalışmanın temelini eğitilmiş derin öğrenme modeli oluşturmaktadır. Etiketlenen veriler sayesinde, ateşli silahları ve kesici aletleri yüksek doğrulukla tespit eden model eğitilmiştir.


Veri Seti

Bu çalışmada veri seti olarak iki farklı sınıf etiketlenmiştir. Bunlardan ilki bıçak diğeri ise silah sınıfıdır. Veriler etiketlenirken bu sınıflar görseller üzerinde fark edildikten sonra sınırlayıcı kutucuklarla işaretlenmiştir. Etiketleme yapılırken *Roboflow* web uygulaması ve *Labellmg* programları kullanılmıştır [5]. Şekil 1’ de *Roboflow* uygulaması üzerinden etiketlenmiş veriler görülmektedir.




Şekil 1: Roboflow üzerinden etiketlenmiş veriler

Veri seti olarak açık kaynaklı etiketli veriler ve internet ortamında bulunan fotoğraflar etiketlenerek kullanılmıştır. Toplamda 4093 adet veri etiketlenmiştir. Bunlardan 1041 tanesi bıçak, 3052 tanesi silah görüntüsünü içermektedir. Bu veriler modele aktarılmadan önce veri ön işleme yapılmıştır. Veri ön işlemede görüntüler 416x416 piksel oranlarına getirilerek standart bir format elde edilmiştir. Ardından veri artırma yöntemlerinden parlaklık ayarı uygulanmıştır. Bu ayar ile veriler %25 oranında parlatılmış ve parlaklığı kısılmıştır. Son olarak verilere %5 piksele kadar gürültü eklenerek yeni sentetik veriler üretilmiştir. Şekil 2’de gürültü eklenmiş veri görülmektedir. Üretilen bu ilave veriler veri setine eklenmiştir.



Şekil 2: Gürültü eklenmiş sentetik veri


Eklenen veriler ile yeni veri seti 6295 adet imge sayısına ulaşmıştır. Bu verilerden 5339 adeti silah, 1637 adeti ise bıçak verisini temsil etmektedir. 6295 veride 6976 adet etiketleme yapılmıştır ve görüntüler ortalama 0.17mp çözünürlüğü sahiptir. Veri ve etiket dağılımı Şekil 3’te görülmektedir. Veriler istenen formata getirildikten ve artırıldıktan sonra %70 eğitim, %20 doğrulama ve %10 test olmak üzere üçe ayrılmıştır. Eğitim setiyle model eğitilmiş, test ve doğrulama setiyle tahminlerin başarısı kontrol edilmiştir. Veriler modele aktarılmadan önce model YoloV5 modeli olacağı için etiket formatı için uygun format olan *txt* formatına çevrilmiştir.



Şekil 3: Veri ve etiket dağılım tabloları


YOLOv5 Algoritması

YOLO (You only look once) bir obje tespit algoritmasıdır. Bu ismin verilmesindeki temel neden YOLO'nun görüntüleri ızgara sistemi ile bölmesinden gelir. Izgaraadaki her bölüm, o hücrede bulunan nesneleri tespit etmekten sorumludur. YOLO hızı ve doğru tespit etmesiyle en popüler nesne tespit algoritmalarından biridir. YOLO mimarisi, Şekil 4'te görüldüğü gibi, uçtan uca türevlenebilir bir ağ yapısına ve sınırlayıcı kutucuk etiket sınıflarını tahminleme yeteneğine sahiptir [6].



Şekil 4: YOLOv5 mimarisi [6]

Bu nedenle bu çalışmada YOLO'nun Pytorch çerçevesini kullanan 18 Mayıs 2020'de paylaşılan YOLOv5 versiyonu tercih edilmiştir. YOLOv5 için 4 farklı model bulunmaktadır. Bunların karşılaştırılması incelendiğinde YOLOv5x modelinin daha fazla GPU desteğine ihtiyaç duyduğu ama çok daha yüksek doğruluk verdiği gözlemlenmiştir. Şekil 5'te YOLOv5 modellerinin karşılaştırılması görülmektedir [7].




Şekil 5: YOLOv5 modelleri performans karşılaştırması [7]

Deney

Bu çalışmada hazırlanan özel veri setinin YOLOv5x modeli ile eğitilmesi için COCO veri setinin ağırlıklarından öğrenim aktarımı kullanılmıştır. Bu sayede sıfırdan ağırlık üretmek yerine daha önce hazırlanmış ağırlıklar bu çalışmanın modeline uyarlanmıştır. Eğitim yapılırken eğitim tur sayısı (epoch) 160 olarak belirlenmiştir. Eğitim tur sayısı kadar model eğitiminde veri kümesi parçalar halinde modele aktarılmış olur. Eğitim tur sayısının ilk adımlarında öğrenme kabiliyeti düşük seviyede olmaktadır. Veri seti modelden geçtikçe ağırlıklar belirlenir ve modelin öğrenme kabiliyeti artar. Bu değer belirlendikten sonra batch değeri 16 olarak belirlenmiştir. Batch değeri ile verinin parçalar halinde modele girmesi sağlanır. Buradaki amaç, modelin tek parça ile yavaş ilerlemesi yerine, belirlenen batch değeri ile orantılı veri bloğunun tek seferde işlenmesinin sağlanmasıdır. Batch sayısı arttıkça model eğitim tur süresi de doğru orantılı şekilde artmaktadır. Bunun yanı sıra batch boyutu arttıkça tahminleme süresinin düştüğü Şekil 6'da görülmektedir [8].

Batch boyutu modele uygun olarak belirlendikten sonra eğitim başlatılmış ve 3 saatin sonunda eğitim başarı ile tamamlanmıştır. Tablo 1’de eğitimin sonunda elde edilen doğruluk değerleri verilmiştir.




Şekil 6: YOLOv5 modelleri batch size ile tahminleme süresinin karşılaştırması [8]

Sınıflar	Doğruluk (mAP@.5)
Silah	%85,3
Bıçak	%90,9
Toplam	%88,1

Tablo 1: Eğitim doğruluk değerleri

Tabloda görüldüğü gibi model yüksek doğruluk değerleri vermektedir. Bunun yanı sıra doğruluk (mAP) değeri kullanılarak hata matrisi oluşturulmaktadır. Hata matrisinde 4 adet değer bulunmaktadır [9]. Bu değerler; Doğruya doğru denmesi (True Positive – TP) doğru, yanlışla yanlış denmesi (True Negative – TN) doğru, doğruya yanlış denmesi (False Positive – FP) yanlış, yanlışla doğru denmesi (False Negative – FN) yanlış şeklinde değerlendirilmektedir. Model eğitim sırasında oluşan hata matrisi Şekil 7’de görülmektedir.



Şekil 7:Eğitimin hata matrisi

Bu hata matrisi ile birlikte 3 farklı model ölçüm metriği elde edilmektedir. Bunlardan ilki, hassasiyet (precision) olarak adlandırılmaktadır. Hassasiyet, elde edilen başarılı tahminlerin tüm tahminlere oranlanması ile bulunmaktadır. Hassasiyet (1) ile ifade edilmektedir. Duyarlılık (Recall) ise modelin doğru olarak tahmin etmesi gereken adımların kaç tanesini doğru olarak tahmin ettiğini gösteren bir ölçümdür. Duyarlılık denklem 2’de verilmektedir. Son olarak F1 skor metriği, hassasiyet ve duyarlılık değerlerinin harmonik ortalamasıyla bulunmakta ve (3) ile ifade edilmektedir. Tablo 2’de bu metriklerin eğitim sonucunda oluşan karşılıkları görülmektedir.

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad (1)$$


$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (2)$$

$$F1 = \frac{2 * \text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (3)$$

Sınıflar	Hassasiyet (Precision)	Duyarlılık (Recall)
Silah	%90.2	%77,4
Bıçak	%96.3	%85,4
Toplam	%93.3	%81,4

Tablo 2: Eğitim hassasiyet ve duyarlılık değerleri

Bu değerlerin eğitim boyunca alınan harmonik ortalaması ile oluşturulan F1 eğrisi Şekil 8’de görülmektedir.




Şekil 8:Eğitimin F1 eğrisi

Model başarısının ölçülmesi için doğrulama kümesi eğitilmiş modelden geçirilmiştir. Oluşan sonuçlar, Şekil 9’da aktarılmaktadır.

SONUÇLAR

Bu çalışmada tasarlanan yapay zekâ modeli ile eğitim kurumlarının güvenliği tek bir sistem ile kontrol edilebilecek, şüpheli kişilerin kesici ve delici alet kullandığı saniyeler içinde %90 doğrulukla tespit edilebilecek ve tehlikeli olayların kötü sonuçlarından maksimum seviyede korunmuş olunacaktır. Bu sayede az maliyet ve düşük insan gücüyle eğitim kurumları güvenli bir ortam haline getirilecektir. Çalışmanın UNESCO’nun 2030 sürdürülebilir kalkınma hedeflerinden herkes için eğitim projesine [10] hizmet etmesi amaçlanmaktadır. Bu sayede *kapsayıcı ve eşit kalitede eğitim almayı ve herkes için hayat boyu öğrenme fırsatlarını teşvik etmek* maddesine katkı sağlanması öngörülmektedir. Öte yandan eğitilen modelden alınan sonuçlar ile sınıflandırıcı model uç uca eklenerek erken tespit ve alarm sistemi çalışmanın bir sonraki fazının içeriğini oluşturulacaktır.



Şekil 9: Modelin doğrulama kümesi sonuçları

TEŞEKKÜR

Bu çalışma 1919b012101749 başvurusu numarası ile tübitak 2209-a üniversite öğrencileri araştırma projeleri destekleme programı kapsamında desteklenmiştir.

KAYNAKLAR

- [1] M. Turhan and M. Turan, "Ortaöğretim Kurumlarında Güvenlik", Kuram ve Uygulamada Eğitim Yönetimi, vol. 1, no. 1, pp. 121-142, Feb. 2012
- [2] Amrutha C.V, C. Jyotsna, Amudha J, Deep Learning Approach for Suspicious Activity Detection from Surveillance Video, ICIMIA 2020
- [3] E. Bayhan, Z. Ozkan, M. Namdar, and A. Basgumus, "Deep Learning Based Object Detection and Recognition of Unmanned Aerial Vehicles," IEEE HORA 2021, Turkey, Jun. 2021.
- [4] Y. E. Kar, A. Basgumus, and M. Namdar, "Machine Learning Assisted Autonomous Vehicle Design and Control," IEEE 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (IEEE ISMSIT 2021), pp. 462-466, Ankara, Turkey, Oct. 2021.
- [5] Roboflow: Give your software the power to see objects in images and video. (n.d.). Retrieved July 13, 2022, from <https://roboflow.com/>
- [6] Jocher, G. (n.d.). GitHub - ultralytics/yolov5: YOLOv5 in PyTorch > ONNX > CoreML > TFLite. GitHub. (2022), <https://github.com/ultralytics/yolov5>
- [7] Jocher, G. (2022, August 17). ultralytics/yolov5: v6.2 - YOLOv5 Classification Models, Apple M1, Reproducibility, ClearML and Deci.ai integrations. Zenodo. Retrieved June 03, 2022, from <https://zenodo.org/record/7002879>
- [8] Jocher, G. (2022a, February 16). *YOLOv5 Study: Batch-Size vs Speed*. Ultralytics Community. (2022), from <https://community.ultralytics.com/t/yolov5-study-batch-size-vs-speed/31>
- [9] Şirin, E. (2020, August 26). Hata Matrisini (Confusion Matrix) Yorumlama. *Veri Bilimi Okulu*. (2022), from <https://www.veribilimiokulu.com/hata-matrisini-confusion-matrix-yorumlama/>
- [10] UNESCO Türkiye Millî Komisyonu. (n.d.). Retrieved March 19, 2022, from <https://www.unesco.org.tr/Pages/48/10/E%C4%9Fitim>