

## Derin Öğrenme Tabanlı Görüntü İşleme İle Acil Durum Tespiti

### Emergency Detection With Deep Learning Based Image Processing

Mustafa GÖKSU<sup>\*1</sup> , Şafak GÖKSU<sup>1</sup> , Ahmet ALKAN<sup>2</sup> 

<sup>1</sup>Elektrik - Elektronik Teknolojisi Alanı, Adıyaman Mesleki ve Teknik Anadolu Lisesi, Adıyaman, Türkiye

<sup>2</sup>Elektrik ve Elektronik Mühendisliği Bölümü, Kahramanmaraş Sütçü İmam Üniversitesi,

Kahramanmaraş, Türkiye

(mustafagoksu02@gmail.com, safakgoksu@gmail.com, aalkan@ksu.edu.tr)

Received:Sep.08,2022

Accepted:Sep.16,2022

Published:Oct.10,2022

**Özetçe**— Günümüzde insanlar tek başlarına ev ve dış ortamlarda, spor yaparken veya günlük yaşamlarını sürdürürken çeşitli sebeplerden kaza geçirerek zor durumlarda kalabilmektedir. Ayrıca meskûn mahal dışında meydana gelen kayıp aramalarında da kaybolan kişi veya çocuğu bir an evvel bulunması çok önemlidir. Dolayısıyla bu tür acil ulaşılması ve tespit edilmesi gereken kişilere hızla ulaşılmaması durumlarında kalıcı sakatlıklar ve ölümler meydana gelmektedir. Bu çalışmada derin öğrenme yöntemlerinden olan YOLOv4 ve YOLOv4-tiny algoritmaları ile kazaya uğrayan ve kaybolan insanların tespit edilebilmesi için 2 adet yapay zekâ modeli geliştirilmiştir. Geliştirilen modülde kameradan gelen görüntüler yapay zekâ modelinden geçirilerek insanların düşme pozisyonları, ayakta durma ve oturma pozisyonları algılanmakta ve acil durum tespiti yapıldığında alarm durumuna geçilerek ilgili kişilere konum/görüntü bilgileri gönderilmektedir. Geliştirilen yapay zekâ modeline ait acil durum tespit başarımları mAP cinsinden YOLOv4 için %99,04, YOLOv4-tiny ile geliştirilen model için %97,91 olarak elde edilmiştir. Geliştirilen yapay zekâ modülünün ev ortamında kullanımı mümkün olduğu gibi İHA' larda kullanılabilmesi mümkündür. Bu çalışmada elde edilen prototipin 112 Acil Çağrı Merkezleri tarafından kullanılması ile ev veya dış ortamda meydana gelen acil durumların tespiti ve arama çalışmalarında faydalı olacağı düşünülmektedir.

**Anahtar Kelimeler** : Yapay zeka, derin öğrenme, YOLO, acil durumlar, İHA, C#

**Abstract**— Today, people can be alone in difficult situations at home and outdoors, while doing sports or continuing their daily lives, due to various reasons. In addition, it is very important to find the missing person or child as soon as possible in the searches for missing people outside the residential area. Therefore, permanent disabilities and deaths occur in cases where such emergency contacts and those who need to be identified are not reached quickly. In this study, two artificial intelligence models have been developed to detect people who have been injured and lost with YOLOv4 and YOLOv4-tiny algorithms, which are deep learning methods. In the developed module, the images coming from the camera are passed through the artificial intelligence model, and the falling positions, standing and sitting positions of the people are detected, and when an emergency is detected, the alarm status is entered and the location/image information is sent to the relevant people. The emergency detection performance values of the developed artificial intelligence model were obtained as 99.04% for YOLOv4 and 97.91% for the model developed with YOLOv4-tiny in terms of mAP. It is possible to use the developed artificial intelligence module in the house environment as well as in UAVs. The use of the prototype obtained in this study by 112 Emergency Call Centers is thought to be useful in detecting and searching emergencies occurring at house or outside.

**Keywords** : Artificial intelligence, deep learning, YOLO, emergency detection, UAV, C#

## 1. Giriş

Ülkemizde ve dünyada yaşayan insanlar ev içi ve dış ortamlarda yaşadıkları kazalara ve hastalıklara bağlı olarak fenalaşarak düşebilmektedir. Bazı durumlarda yalnız yaşayan ve yaşlı bireylerin evlerinde oturma ve ayakta kalma durumlarının bilinmesi, uzaktan ek bir personele ihtiyaç duyulmadan izlenmesi ve varsa acil durumların tespit edilmesi gerekmektedir. Yine ev dışı ortamlarda, özellikle de meskun mahal dışında kişi/çocuk kayıplarının bulunmasında da zaman çok önemli olup, İHA' ların (insansız hava araçları) bu iş için daha başarılı bir şekilde

kullanılabileceği düşünülmektedir. Bu gibi durumların erken tespiti hayati bir önem arz ettiğinden bu çalışmada hem ev gibi kapalı ortamlarda hem de İHA' lara entegre edilebilecek derin öğrenme tabanlı görüntü işleme modülü geliştirilmiştir. Böylece insanların birden fazla araç ile yapacakları aramalara göre daha hızlı ve verimli acil durum (kişi belirleme) tespiti gerçekleştirilmiş olacaktır.

Literatürde CNN ve LSTM/RNN birleşiminden meydana gelen bir çalışmada insanlara ait ani ayakta durma, yürüme, düşme, uzanma ve zıplama pozisyonlarını algılayan bir yapay zekâ modeli geliştirilmiştir. Çalışmada %90 sınıflandırma doğruluğu elde edilmiştir (Zhang ve arkadaşları, 2019).

İnsanlara ait düşme pozisyonlarının algılanmasında kullanılan derin öğrenme ağlarının yavaş çalışmasından bahseden bir çalışmada düşük donanıma sahip cihazlarda daha verimli kullanılması için MobileVGG isimli bir yaklaşım önerilmektedir (Han ve arkadaşları, 2020).

Evdeki yaşlıların ve hasta kişilerin bakımında insan düşme pozisyonu algılayan bir çalışmada derin öğrenme tekniklerinden R-CNN kullanılmıştır. Çalışmada yapay zekâ modelinde %94,44 kesinlik (hassasiyet), %94,95 geri çağırma ve %95,50 doğruluk değerleri elde edildiği görülmüştür (Min ve arkadaşları, 2018). CNN ve LSTM mimarilerini kullanarak yapılan bir çalışmada yürüme, ayakta durma ve düşme insan pozisyonlarını tespit edebilen bir yapay zekâ modeli geliştirilmiştir. Çalışmada %97,66 sınıflandırma doğruluğu elde edildiği görülmüştür (Lie ve arkadaşları, 2018).

Yaşlıların yataktan düşmelerini tespit eden bir çalışmada tehlikeli hareketlerin tespit edilme oranı %79,8 olarak elde edilirken, güvenli hareketlerin tespiti %82,4 olarak elde edildiği görülmüştür (Satoh & Shibata, 2020). Kinect sensörü kullanılarak 3 boyutlu derinlik analizi ile yaşlı bireylerin düşmelerini tespit edebildiği görülmüştür (Yang ve arkadaşları, 2016).

Yaşlı bireylerin yalnız yaşamalarında bağlı olarak evde düşmelerinin tespit edildiği bir çalışmada kameradan alınan görüntüler üzerinde destek vektörleri kullanılmış %4,8'lik hata ile doğru tespit edildiği görülmüştür (Mirmahboub ve arkadaşları, 2013).

Ev ortamında yaşlı bireyler üzerinde düşme tespiti için yapılan bir çalışmada giyilebilir bir cihazda ivme ölçer verileri üzerinde derin öğrenme mimarilerinden ConvLSTM kullanılmış sınıflandırma başarısını gösteren AUC değeri olarak 0,94 değeri elde edildiği görülmüştür (Aicha ve arkadaşları, 2018).

İHA' larda elde edilen görüntüler üzerinde kayıp insan tespiti, sınırlarda yasa dışı göçmen tespiti yapılabilmektedir. 1500 yaya görüntüsü üzerinde yapılan çalışmada R-CNN algoritması ile geliştirilen yapay zekâ modelinin %98 hassasiyet, %99 geri çağırma ve %98 F1 skoru değeri elde edildiği görülmüştür (Hung ve arkadaşları, 2020).

Daha önceden yapılan çalışmalardan anlaşılacağı üzere insanlara ait düşme ve tehlikeli pozisyonları tespit edebilen yapay zekâ modelleri geliştirilmiştir. Ancak bu çalışmada elde edilen, acil durumların ev ortamında ve dış ortamda (İHA' lar üzerinde) tespit edilebilmesine olanak sağlayan sistem, elde edilen yüksek başarı oranları (mAP değerleri %97,91 ve %99,04) oranlarıyla literatürdeki çalışmalardan ayrılmaktadır. YOLOv4, YOLOv4-tiny derin öğrenme algoritmalarının kullanıldığı bu modül sayesinde tespit edilen tehlikeli durumların, kablosuz radyo alıcı-vericiler ile 112 Acil Çağrı Merkezlerine iletilmesi hedeflenmektedir.

## 2. Materyal

Bu bölümde çalışmada kullanılan veri seti ve çalışmada kullanılan donanımlar açıklanmaktadır. Çalışmada kullanılan veri seti internette yer alan veri setleri ve internetten alınan görüntülerden oluşturulmuştur (URL 1, 2017; URL 2, 2022). Veri seti insanlara ait oturma, düşme ve ayakta durma pozisyonlarına ait toplam 952 görüntüden oluşturulmuştur. Tablo 1' de çalışmada kullanılan veri setine ait görüntü sayıları yer almaktadır.

**Tablo 1.** Veri setinde yer alan 3 sınıfa ait görüntü sayıları

Görüntü sayısı	Düşme	Oturma	Ayakta	Toplam
Eğitim seti %70	227	226	212	665
Doğrulama seti %30	98	97	92	287
<b>Toplam</b>	325	323	304	952

112 Acil Çağrı Merkezleri ile hedef kullanıcı arasında bilgi alışverişini sağlamak için E22 900T22D RF modülü kullanılmıştır. E22 900T22D uzak mesafelere düşük güç tüketimi ile şifreli olarak bilgi gönderebilen bir modüldür (URL3, 2018).

Mini bilgisayar olarak İHA' larda Jetson Nano 4 GB seçilmiştir. Jetson Nano'nun tercih edilme sebebi yapay zekâ uygulamalarında FPS (saniye başına kare) değerinin Raspberry pi 4-8 GB, Latte Panda Delta gibi mini bilgisayarlara göre yüksek olmasıdır (Göksu & Alkan, 2022). Şekil 1' de çalışmada kullanılan mini bilgisayar görülmektedir.



Şekil 1. Jetson Nano 4 GB

Çalışmada geliştirilen modüle konum bilgilerinin alınması için Grove GPS (Air530) konumlandırma modülü kullanılmıştır. Bu konumlandırma modülü çalışmada yapılan testlere göre hali hazırda bulunan GY-NEO6MV2 GPS modülüne kıyasla daha hızlı uydu bulma ve daha kararlı konumlandırma özelliklerinden dolayı tercih edilmiştir. RGB görüntülerin dış dünyadan alınması için Microsoft Lifecam HD-3000 720P usb kamera kullanılmıştır.


### 3. Metotlar

Bu bölümde çalışmada oluşturulan yapay zekâ modelleri geliştirilme süreçleri, çalışmada üretilen modül ve üretilen yazılımlar açıklanmaktadır. Yapay zekâ modellerinin üretilmesinde 2 adet derin öğrenme yöntemi olan YOLOv4 ve YOLOv4-tiny algoritmaları kullanılmıştır. YOLOv4-tiny düşük donanıma sahip cihazlarda kullanılması planlanan yapay zekâ modeli için tercih edilirken, YOLOv4 ise yüksek donanıma sahip cihazlarda kullanılacak yapay zekâ modelleri için tercih edilmektedir (Jiang ve arkadaşları, 2020).

Çalışmanın materyal bölümünde belirtilen veri seti YOLOv4 ve YOLOv4-tiny algoritmaları ile Google Colab web ortamında eğitilmiştir. Yapay zekâ modellerine ait ağırlıklar, başarımlar ve grafikler Google Colab' tan elde edilmiştir. Modellerin test edilme işlemi veri seti haricinde bırakılan görüntüler üzerinde Jetson Nano 4 GB mini bilgisayar ve Google Colab web ortamında gerçekleştirilmiştir.

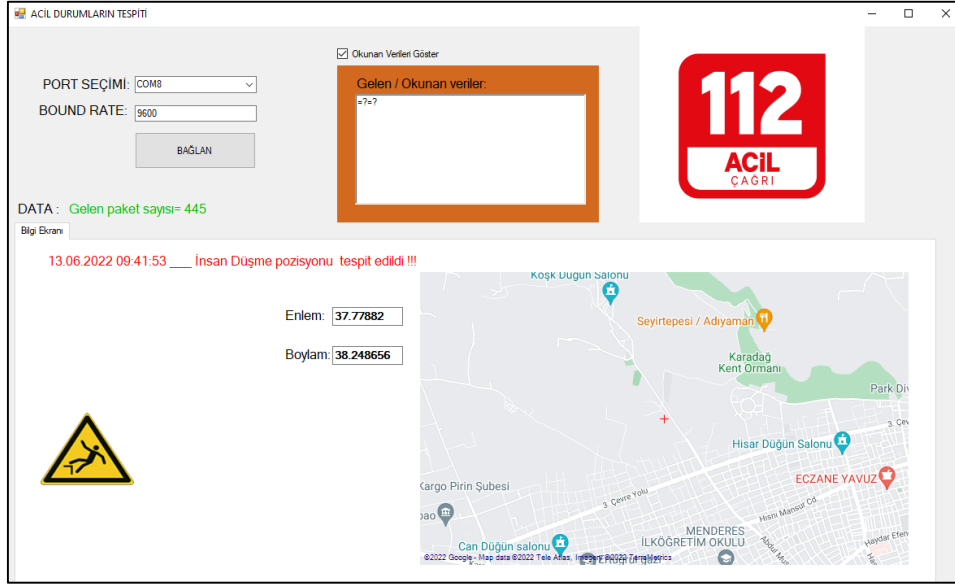
Çalışmada kullanılan veri seti üzerinde YOLOv4 algoritması ile 2000 ve 3000 iterasyon sayılarında eğitimler gerçekleştirilmiş elde edilen ortalama eğitim kayıplarının ve başarımlar metriklerinde (mAP, hassasiyet, geri çağırma, F1 skoru) 2000 iterasyon ile 3000 iterasyon arasında büyük değişimler olmadığı görülmüştür. YOLOv4-tiny algoritması ile model eğitimlerinde 6000 ve 9000 iterasyon sayılarında eğitimler gerçekleştirilmiştir. Elde edilen ortalama eğitim kayıpları ve başarımlar metriklerinde 6000 iterasyon ile 9000 iterasyon arasında büyük değişimler olmadığı görülmüştür (Ukhwah ve arkadaşları, 2022). Bu bağlamda çalışmada kullanılan veri seti için YOLOv4 algoritması ile geliştirilecek model için 2000 iterasyon yeterli olarak görülürken, YOLOv4-tiny algoritması kullanılarak geliştirilen modelde 6000 iterasyon sayısı yeterli olarak görülmüştür. Geliştirilen yapay zekâ modellerine ait ağırlıklar AlexeyAB kullanıcısı tarafından python dili ile geliştirilen yazılım ile çalışma için değiştirilerek geliştirilmiştir (AlexeyAB, 2018). Var olan yazılıma konum bilgilerini alacak kodlar, kablosuz radyo alıcı-verici için kodlar eklenmiştir.

Çalışmada doğal afet durumları ve gsm şebekelerinin kapsam alanı dışında iletişim problemi olma ihtimaline karşılık radyo frekanslı iletişim Lora E22 900T22D modülü kullanılmıştır. Ayrıca E22 900T22D modülünde tekrarlayıcı özelliği olduğu için sisteme her ekstra bir modül eklendiğinde ideal koşullarda 5 km' ye kadar mesafelere bilgi alma ve gönderme özelliğine sahiptir (URL3, 2018). Üstelik tekrarlayıcı işlemi için modül ekleme sınırı olmadığından bir ülkeyi sarabilecek bir iletişim ağı oluşturulabilir. Şekil 2 'de çalışmada kullanılan radyo frekanslı Lora E22 900T22D alıcı-verici modülü görülmektedir.



Şekil 2. E22 900T22D RF modülü

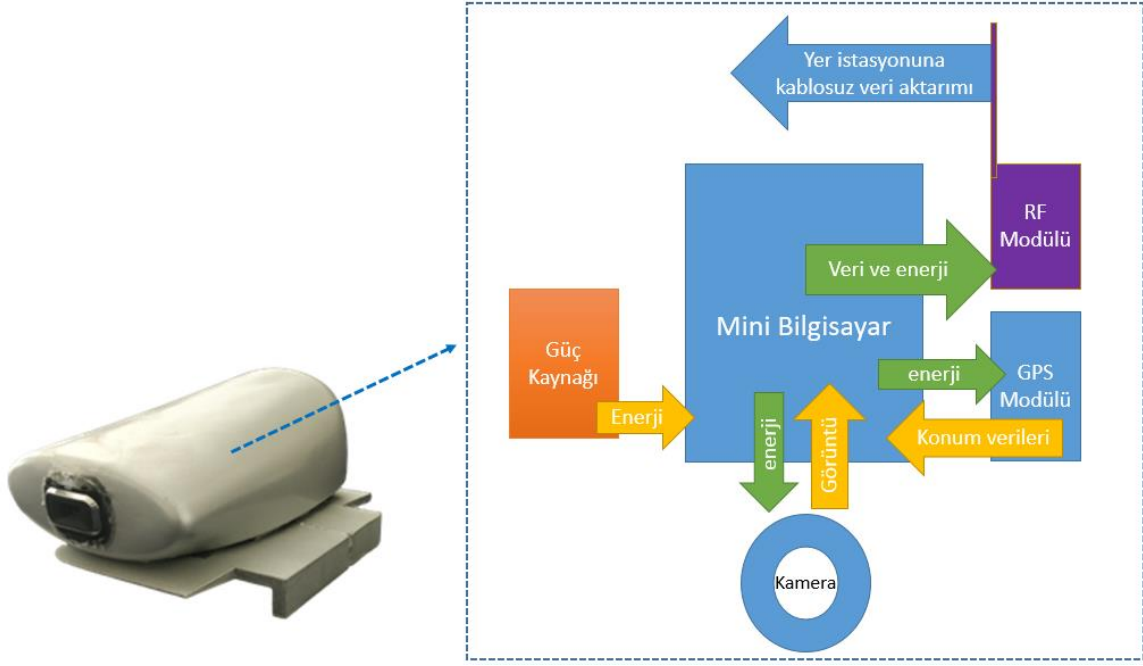
112 Acil Çağrı Merkezlerinin Şekil 2' deki alıcı modül ile bilgileri anlamlı bir bütün haline getirebilmesi için C# dilinde seri port okuma yazılımı geliştirilmiştir. Bu yazılımda 3 duruma ait (düşme, oturma, yürüme) bilgiler sisteme geldiğinde ara yüzde 3 sınıfa ait yazılımda yer alan simgeler ekranda belirirken sesli olarak yazılımın başındaki kişiler uyarılmaktadır. Ayrıca yazılımda anlık olarak konum bilgileri harita üzerinde gösterilmektedir. Şekil 3' te Visual Studio ortamında C# dilinde hazırlanan 112 Çağrı merkezi yazılımı görülmektedir.



Şekil 3. 112 Acil Çağrı Merkezi yazılımı ara yüzü

Çalışmada geliştirilen modülün dış tasarımı Blender 3 boyutlu tasarım programında yapıldıktan sonra 3 boyutlu yazıcıdan çıkarılarak sprey boya ile metalik bir görünüm verilmiştir. Modülün İHA altına montajı ve ev ortamında bir noktaya sabitlenebilmesi için montaj yerleri tasarlanarak 3d yazıcıdan çıkarılmıştır. Şekil 4' te üretilen modülün son hali ve blok diyagramı görülmektedir. Şekil 4' te kameranın takılı üst kapağın altında GPS modülü, radyo frekanslı alıcı-verici modülü, mini bilgisayar ve güç kaynağı olarak 10.000 mAh kapasiteli power bank yer almaktadır.

Modülün ön bölümünde yer alan kameradan alınan görüntüler mini bilgisayarda çalışan yapay zekâ destekli yazılım ile nesne tespitinde kullanılmaktadır. Çalışmada belirlenen sınıflara göre nesne tespiti yapılarak mini bilgisayara bağlı gps modülündeki konum bilgilerine göre RF modülü aracılığı ile 112 Çağrı Merkezine bilgi gönderilmektedir.




Şekil 4. Geliştirilen modül ve blok diyagramı

Çalışmada kullanılan mini bilgisayarda Ubuntu işletim istemi kullanılmıştır. Yapay zekâ destekli yazılımının kullanılabilmesi için YOLO darknet çerçevesi mini bilgisayara yüklenmiştir (AlexeyAB, 2018). Şekil 4' de blok diyagramda yer alan kamera, GPS modülü, RF modülü' nün enerji beslemeleri mini bilgisayar üzerinden gerçekleştirilmiştir. Mini bilgisayarın enerjisi ise powerbank üzerinden sağlanmıştır.

#### 4. Deneysel Çalışmalar


Şekil 2' de yer alan radyo frekanslı Lora E22 900T22D alıcı-verici 37,733528, 38,220177 enlem ve boylamlarında alıcı sabit tutularak vericinin bir araç içerisinde sabitlenerek hareket ettirilmesi ile açık arazide yaklaşık olarak 2.4 kbps veri aktarım hızında 2,7 km mesafede veri alışverişini kesintisiz yaptığı görülmüştür. Lora E22 900T22D modülü ideal koşullarda 5 km mesafeye kadar menzili olduğu halde testin yapıldığı alandaki sinyal gürültüleri ve arazinin engebeli olması menzil mesafesini düşürdüğü görülmüştür.

Google Colab web hizmeti üzerinde YOLOv4-tiny derin öğrenme modeli ile eğitilen yapay zekâ modelinde 6000 iterasyon sonunda elde edilen mAP değerleri ve eğitim kayıpları Şekil 5' de görülmektedir. Şekil 5' de yer alan grafikte kırmızı renk ile gösterilen mAP değerlerinin eğitimin süresince arttığı görülmüştür. Grafikte Loss olarak ifade edilen eğitim kayıpları mavi renk ile ifade edilirken eğitim boyunca iterasyon sayısının artması ile sıfır değerine yaklaştığı görülmektedir.



Şekil 5. YOLOv4-tiny ile geliştirilen modelin mAP ve eğitim kayıpları grafiği

YOLOv4 ile 2000 iterasyon sonunda geliştirilen yapay zekâ modelinin mAP değerleri kırmızı renkte eğitim kayıpları mavi renk olarak Şekil 6' da ki grafikte görülmektedir. Eğitim boyunca mAP değerleri artarken eğitim kayıplarının azaldığı görülmektedir.



Şekil 6. YOLOv4 ile geliştirilen modelin mAP ve eğitim kayıpları grafiği

Geliştirilen yapay zekâ modellerine ait başarımların değerleri Tablo 2’ de görülmektedir. Başarımların değerleri hesaplanırken modelin doğru tahmin ve yanlış tahminlerinden oluşan doğru pozitif (TP), yanlış pozitif (FP) ve yanlış negatif (FN) değerlerinden hesaplamalar yapılmaktadır.

**Tablo 2.** Geliştirilen yapay zekâ modellerine ait başarımların değerleri

Modeller	Hassasiyet (Precision)	Geri Çağırma (Recall)	F1-Skoru	Tespit Zamanı(ms)	IoU	mAP	Boyut (Mb)
YOLOv4-tiny kullanılarak 6000 iterasyon ile geliştirilen model	0,93	0,96	0,94	5,17	%76,08	%97,91	22,4
YOLOv4 kullanılarak 2000 iterasyon ile geliştirilen model	0,97	0,99	0,98	43,92	%84,12	%99,04	244,2

Tablo 2’ de çalışmada geliştirilen yapay zekâ modellerine ait başarımların değerleri görülmektedir. Tablo 2’ de yer alan IoU değerleri yapay zekâ modellerinin nesne tespiti işlemi sonrası tespit ettiği nesnelere ne kadar doğru bir çerçeve içine aldığını göstermektedir. IoU değeri hesaplanırken veri setinde referans olarak belirlenen nesneye ait çerçeve alanının yapay zekâ modeli ile tahmin edilen çerçeve alanı ile kesiminin birleşimlerine bölümü ile elde edilmektedir (Rezatofighi ve arkadaşları, 2019).

Bu çalışmada 3 sınıf olduğu için formüller 3 sınıf için alındıktan sonra ortalaması alınarak değer elde edilmiştir. Örneğin Hassasiyet değeri hesaplanırken Denklem 4.1’ den yararlanılır (Kulshreshtha ve arkadaşları, 2021; Göksu & Alkan, 2022).

Şekil 5 ve Şekil 6’ da gösterilen mAP değerleri 4.1 - 4.4 denklemleri kullanılarak belirlenen iterasyon süresince hesaplanmaktadır (Parico & Ahamed, 2021). AP değeri nesne tespiti performansının değerlendirme indeksi olarak kullanılmaktadır. Ortalama hassasiyet (AP) değeri eğitilen modelin bir sınıftaki doğruluğunu göstermektedir. Genel ortalama hassasiyet değeri (mAP) var olan tüm sınıfların doğruluğunu ifade etmektedir (Fu ve arkadaşları, 2021).

$$\text{Hassasiyet}(P) = \frac{TP}{TP+FP} \quad (\text{Denklem 4.1})$$

$$\text{Geri çağırma}(R) = \frac{TP}{TP+FN} \quad (\text{Denklem 4.2})$$

$$AP = \int_0^1 P(R)dR \quad (\text{Denklem 4.3})$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (\text{Denklem 4.4})$$

Şekil 5 ve Şekil 6’ da yer alan eğitim kayıpları belirlenen iterasyon süresince yapay zekâ modelinin tespit edebildiği tahmin çerçeve alanı ile gerçek çerçeve alanı arasında fark minimize edilerek hesaplanmaktadır (Fu ve arkadaşları, 2021). Şekil 7’ de tahmin çerçeve alanı ve gerçek çerçeve alanı görülmektedir. Şekil 7’ de mavi renk ile gösterilen çerçeve alanı veri setinde yer alan gerçek çerçeve alanını gösterirken, kırmızı renk ile gösterilen çerçeve alanı yapay zekâ modelinin tahmin sonucu oluşan çerçeve alanıdır (Zheng ve arkadaşları, 2020).






**Şekil 7.** Tahmin çerçeve alanı ve gerçek çerçeve alanı

Şekil 8’ de YOLOV4-tiny algoritması ile 9000 iterasyon sonucunda elde edilen eğitim kayıplarına ait grafikler görülmektedir. Şekil 5 ve Şekil 8 incelendiğinde 6000 iterasyondan sonra ortalama eğitim kayıp değerleri ve mAP değerleri arasındaki farklar sırasıyla 0,0094 ve %0,08 olarak elde edilmiştir. Görüldüğü gibi 6000 iterasyon sayısı ile eğitilen model ile 9000 iterasyona kadar eğitilen model arasında mAP ve ortalama eğitim kayıpları arasında modelin başarısını etkileyecek büyük değerler oluşmadığı görülmüştür. Ek olarak 9000 iterasyon ile geliştirilen modelin hassasiyet değeri 0,93, geri çağırma değeri 0,97, F1 Skoru 0,95 ve IoU değeri %76,27 olarak elde edilmiştir. 6000 ile 9000 iterasyon ile gerçekleştirilen eğitimlerde başarımleri karşılaştırıldığında hassasiyet değerlerinin aynı olduğu, geri çağırma 0,1, F1 Skoru 0,1 ve IoU değerlerinde 0,19 gibi çok küçük farklar oluştuğu görülmüştür.

YOLOv4 algoritması ile 3000 iterasyona kadar yapılan model eğitimlerinde elde edilen başarımleri değerlerinin 2000 iterasyona göre ortalama eğitim kayıpları arasındaki fark 0,0075 olarak elde edilmiştir. Başarımleri metriklerinden IoU değerlerinde %0,11 fark varken, hassasiyet değerlerinde %0,01, geri çağırma değerinde 0,1 ve F1 Skoru değerinde 0,1 fark olduğu görülmüştür. Bu çalışmada YOLOv4-tiny ile geliştirilen modeller için 3000 iterasyon, YOLOv4 ile geliştirilen modellerde 1000 iterasyon daha fazla model eğitimi yapılması modellerin başarımleri değerlerini büyük ölçüde değiştirmediği görülmüştür. Ayrıca aynı derin öğrenme algoritması ile eğitilen Şekil 5 ve Şekil 8 incelendiğinde mAP ve eğitim kayıplarının benzer sabit dalgalanmalar yaptığı görülmektedir (Ukhwah ve arkadaşları, 2022).





Şekil 8. 9000 iterasyon ile geliştirilen modelin mAP ve eğitim kayıpları grafiği

Google Colab web hizmeti üzerinde geliştirilen yapay zekâ modellerine at ağırlıklar ile veri setinde yer alan test klasöründeki görüntüler üzerinde çalışmada belirlenen 3 sınıfta nesne tespiti gerçekleştirilmiştir. Gerçekleştirilen nesne tespitine ait bazı çıktılar ve Şekil 9’ da görülmektedir.



Şekil 9. Yapay zekâ modellerine ait tahmin sonuçları

## 5. Sonuçlar

İnsanların kapalı ve açık ortamlarda herhangi bir sebepten dolayı düşmesini tespit edebilen 2 adet yapay zekâ modeli geliştirilmiştir. Yapay zekâ modellerine ait IoU ve mAP değerleri YOLOv4-tiny için %76,08, %97,91, YOLOv4 için ise %84,12, %99,04 olarak elde edilmiştir. YOLOv4-tiny derin öğrenme algoritması ile geliştirilen model düşük donanımlarda daha hızlı çalıştığı için İHA’larda kullanılması açısından daha uygundur. Çalışmada kullanılan mini bilgisayar yerine daha yüksek donanıma sahip cihazlarda YOLOv4 ile geliştirilen yapay zekâ modelinin kullanılması önerilmektedir. Tablo 2’de YOLOv4 ile geliştirilen modelin başarımlarından mAP, IoU, geri çağırma, hassasiyet ve F1 skoru açısından YOLOv4-tiny ile geliştirilen modelden daha iyi olduğu görülmektedir. Çalışmada insanların pozisyonları tespit edilerek düşme algılandığında acil durum tespiti yapılmaktadır. Ev ortamlarında düşme ile uyuma arasında farkın tespiti durumunda artık yaygın olarak kullanılabilen kişinin vücut sıcaklığı, nabız vb. fizyolojik parametrelerini ölçerek geliştirilen modüle aktaran bir bilekliğin çalışmada geliştirilen modüle entegrasyonu ile 112 Acil Çağrı merkezlerine konum ve tespit edilen durum iletilmektedir. 112 Çağrı merkezlerine kablosuz gönderilen sinyaller çağrı merkezlerinde yer alan alıcı modüller ile seri iletişim ile C# dilinde oluşturulan ara yüze sahip yazılıma aktarılmaktadır. Böylece 112 Acil

Çağrı Merkezine iletilen bilgilere göre ekiplerin acil durumdaki kişilere hızlı bir şekilde müdahalesi hedeflenmektedir. Geliştirilen modül ev ortamında bir odaya sabitlenebilecek ve dış ortamlarda İHA' lara takılacak bir donanımdır. Çalışmada üretilen modül İHA' lar üzerinde kaybolan insanları havadan tespit ederek kolayca bulunmasını sağlayacağı düşünülmektedir. Kablosuz alıcı-verici modülü menzilin artırılması için Lora markasına ait E22-900T30S modülü tercih edilirse 10 km' ye kadar bir menzil elde edilebilir. Ayrıca kablosuz modüllerinde tekrarlayıcı özelliğinin olması menzil sıkıntısı gidermede önemli bir noktadır.

## Teşekkür

Çalışmada üretilen modül, 2022 yılında Tübitak 1503 kapsamında düzenlenen Adıyaman Üniversitesi "ADYÜ Ar-Ge ve İnovasyon Proje Pazarı" Bilişim ve Sosyal Çevre kategorisinde 1.lik derecesi elde etmiştir. Desteklerinden dolayı ADYÜ İnovatif Proje Pazarı düzenleme kuruluna teşekkür ederiz.

## Kaynaklar

- Han, Q., Zhao, H., Min, W., Cui, H., Zhou, X., Zuo, K., & Liu, R. (2020). A two-stream approach to fall detection with mobilevgg. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2019.2962778>
- Hung, G. L., Sahimi, M. S. Bin, Samma, H., Almohamad, T. A., & Lahasan, B. (2020). Faster R-CNN Deep Learning Model for Pedestrian Detection from Drone Images. *SN Computer Science*, 1(2). <https://doi.org/10.1007/s42979-020-00125-y>
- Jiang, Z., Zhao, L., Li, S., Jia, Y., & Liquan, Z. (2020). Real-time object detection method for embedded devices.
- Kulshreshtha, M., Chandra, S. S., Randhawa, P., Tsaramirsis, G., Khadidos, A., & Khadidos, A. O. (2021). Oatcr: Outdoor autonomous trash-collecting robot design using yolov4-tiny. *Electronics (Switzerland)*, 10(18). <https://doi.org/10.3390/electronics10182292>
- AlexeyAB. (2018). AlexeyAB/darknet: YOLOv4 / Scaled-YOLOv4 / YOLO - Neural Networks for Object Detection (Windows and Linux version of Darknet ). <https://github.com/AlexeyAB/darknet>
- Lie, W. N., Le, A. T., & Lin, G. H. (2018). Human fall-down event detection based on 2D skeletons and deep learning approach. 2018 International Workshop on Advanced Image Technology, IWAIT 2018. <https://doi.org/10.1109/IWAIT.2018.8369778>
- Min, W., Cui, H., Rao, H., Li, Z., & Yao, L. (2018). Detection of Human Falls on Furniture Using Scene Analysis Based on Deep Learning and Activity Characteristics. *IEEE Access*, 6. <https://doi.org/10.1109/ACCESS.2018.2795239>
- Mirmahboub, B., Samavi, S., Karimi, N., & Shirani, S. (2013). Automatic monocular system for human fall detection based on variations in silhouette area. *IEEE Transactions on Biomedical Engineering*, 60(2), 427–436. <https://doi.org/10.1109/TBME.2012.2228262>
- Zheng, Z., Wang, P., Liu, W., Li, J., Ye, R., & Ren, D. (2020, April). Distance-IoU loss: Faster and better learning for bounding box regression. In *Proceedings of the AAAI conference on artificial intelligence (Vol. 34, No. 07, pp. 12993-13000)*.
- Göksu, M., & Alkan, A. (2022). Derin Öğrenme Temelli Robotik Maske Kontrol Sistemi. *Firat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 459–471. <https://doi.org/10.35234/fumbd.1060378>
- Pulido, C., & Ceron, A. (2022). Towards Real-Time Drone Detection Using Deep Neural Networks. *Smart Innovation, Systems and Technologies*, 255, 149–159. [https://doi.org/10.1007/978-981-16-4884-7\\_12/COVER](https://doi.org/10.1007/978-981-16-4884-7_12/COVER)
- Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union: A metric and a loss for bounding box regression. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2019-June, 658–666. <https://doi.org/10.1109/CVPR.2019.00075>
- Satoh, H., & Shibata, K. (2020). Improvement of a Monitoring System for Preventing Elderly Fall Down from a Bed. *Advances in Intelligent Systems and Computing*, 1026. [https://doi.org/10.1007/978-3-030-27928-8\\_108](https://doi.org/10.1007/978-3-030-27928-8_108)
- URL1. (2017). Fall detection Dataset. Last Visited. <https://falldataset.com/>
- URL2. (2022). Fall Detection Dataset|Kaggle. <https://www.kaggle.com/datasets/uttejkumarkandagatla/fall-detection-dataset>.
- URL3. (2018). E22-900T22D User Manual 868M/915M 22dBm DIP New LoRa Wireless Module.

[https://seureservercdn.net/160.153.138.180/bz0.2b1.myftpupload.com/wp-content/uploads/2021/12/E22-900T22D\\_UserManual\\_EN\\_v1.1.pdf](https://seureservercdn.net/160.153.138.180/bz0.2b1.myftpupload.com/wp-content/uploads/2021/12/E22-900T22D_UserManual_EN_v1.1.pdf)

- Yang, L., Ren, Y., & Zhang, W. (2016). 3D depth image analysis for indoor fall detection of elderly people. *Digital Communications and Networks*, 2(1), 24–34. <https://doi.org/10.1016/J.DCAN.2015.12.001>
- Zhang, X., Han, L., Dong, Y., Shi, Y., Huang, W., Han, L., González-Moreno, P., Ma, H., Ye, H., & Sobeih, T. (2019). A deep learning-based approach for automated yellow rust disease detection from high-resolution hyperspectral UAV images. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131554>
- Parico, A. I. B., & Ahamed, T. (2021). Real time pear fruit detection and counting using yolov4 models and deep sort. *Sensors*, 21(14). <https://doi.org/10.3390/s21144803>
- Ukhwah, E. N., Yuniarno, E. M., & Suprpto, Y. K. (2019). Asphalt Pavement Pothole Detection using Deep learning method based on YOLO Neural Network. *Proceedings - 2019 International Seminar on Intelligent Technology and Its Application, ISITIA 2019*, 35–40. <https://doi.org/10.1109/ISITIA.2019.8937176>
- Fu, H., Song, G. ve Wang, Y. (2021). Improved YOLOv4 Marine Target Detection Combined with CBAM. *Symmetry*, 13(4), 623. doi:10.3390/sym13040623
- Aicha, A. N., Englebienne, G., van Schooten, K. S., Pijnappels, M., & Kröse, B. (2018). Deep Learning to Predict Falls in Older Adults Based on Daily-Life Trunk Accelerometry. *Sensors* 2018, Vol. 18, Page 1654, 18(5), 1654. <https://doi.org/10.3390/S18051654>