

SAVUNMA, GÜVENLİK VE AFET YÖNETİMİNDE YAPAY ZEKÂ TABANLI UYGULAMALAR



EDİTÖRLER:

DR. ÖĞR. ÜYESİ SEMA SERVİ

ÖĞR. GÖR. DR. ABDULLAH CEM AĞAÇAYAK

ÖĞR. GÖR. HAVVA HAZEL ARAS

SAVUNMA, GÜVENLİK VE AFET YÖNETİMİNDE YAPAY ZEKÂ TABANLI UYGULAMALAR

EDİTÖRLER:

DR. ÖĞR. ÜYESİ SEMA SERVİ
ÖĞR. GÖR. DR. ABDULLAH CEM AĞAÇAYAK
ÖĞR. GÖR. HAVVA HAZEL ARAS

EĞİTİM
yayınevi

SAVUNMA, GÜVENLİK VE AFET YÖNETİMİNDE YAPAY ZEKÂ TABANLI UYGULAMALAR

Editörler: Dr. Öğr. Üyesi Sema Servi, Öğr. Gör. Dr. Abdullah Cem Ağaçayak, Öğr. Gör. Havva Hazel Aras

Yayınevi Grubu Genel Başkanı: Yusuf Ziya Aydoğan (yza@egitimyayinevi.com)

Genel Yayın Yönetmeni: Yusuf Yavuz (yusufyavuz@egitimyayinevi.com)

Sayfa Tasarımı: Kübra Konca Nam

Kapak Tasarımı: Eğitim Yayınevi Tasarım Birimi

T.C. Kültür ve Turizm Bakanlığı

Yayıncı Sertifika No: 76780

E-ISBN: 978-625-385-736-3

1. Baskı, Aralık 2025

Kütüphane Kimlik Kartı

SAVUNMA, GÜVENLİK VE AFET YÖNETİMİNDE YAPAY ZEKÂ TABANLI UYGULAMALAR

Editörler: Dr. Öğr. Üyesi Sema Servi, Öğr. Gör. Dr. Abdullah Cem Ağaçayak, Öğr. Gör. Havva Hazel Aras

V+120 s., 160x240 mm

Kaynakça var, izin yok.

E-ISBN: 978-625-385-736-3

Copyright © Bu kitabın Türkiye'deki her türlü yayın hakkı Eğitim Yayınevi'ne aittir. Bütün hakları saklıdır. Kitabın tamamı veya bir kısmı 5846 sayılı yasanın hükümlerine göre kitabı yayımlayan firmanın ve yazarlarının önceden izni olmadan elektronik/mechanik yolla, fotokopi yoluyla ya da herhangi bir kayıt sistemi ile çoğaltılamaz, yayımlanamaz.

EĞİTİM
yayınevi

Yayınevi Türkiye Ofis: İstanbul: Eğitim Yayınevi Tic. Ltd. Şti., Atakent mah. Yasemen sok. No: 4/B, Ümraniye, İstanbul, Türkiye

Konya: Eğitim Yayınevi Tic. Ltd. Şti., Fevzi Çakmak Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye
+90 332 351 92 85, +90 533 151 50 42
bilgi@egitimyayinevi.com

Yayınevi Amerika Ofis: New York: Egitim Publishing Group, Inc.
P.O. Box 768/Armonk, New York, 10504-0768, United States of America
americaoffice@egitimyayinevi.com

Lojistik ve Sevkiyat Merkezi: Kitapmatik Lojistik ve Sevkiyat Merkezi, Fevzi Çakmak Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye
sevkiyat@egitimyayinevi.com

Kitabevi Şubesi: Eğitim Kitabevi, Şükran mah. Rampalı 121, Meram, Konya, Türkiye
+90 332 499 90 00
bilgi@egitimkitabevi.com

İnternet Satış: www.kitapmatik.com.tr
bilgi@kitapmatik.com.tr

EĞİTİM YAYINEVİ
GRUBU

EĞİTİM
yayınevi

SALON
yayıncıları

Kitapmatik
yayıncıları

kitapmatik
İnternetteki kitaplarınız

EĞİTİM
kitabevi

İÇİNDEKİLER

ÖNSÖZ.....	v
------------	---

BÖLÜM 1

ASKERİ KARA ARAÇLARINDA YAPAY ZEKÂ TABANLI SÜRÜCÜ UYKULULUK TESPİTİ	1
--	---

Beyza AKKOÇ, Musa DOĞAN

BÖLÜM 2

DERİN ÖĞRENME TABANLI HASAR TESPİTİ ENTEGRELİ AFET SONRASI GÜVENLİ ROTA BELİRLEME SİSTEMİ	16
--	----

Süleyman YILDIZ, Sema SERVİ

BÖLÜM 3

ANALOG SINIFIN DİJİTALLEŞTİRİLMESİ: YAPILANDIRILMAMIŞ EĞİTİM VERİLERİNDE ÇOK MODLU RAG ANALİZİ	29
--	----

Yiğit Eren ÖZTAŞ, Sema SERVİ

BÖLÜM 4

KURUM İÇİ TEHDİT TESPİTİ İÇİN YAPAY ZEKÂ TABANLI ÇÖZÜMLER.....	41
---	----

Muhammet Furkan BULUT, Havva Hazel ARAS

BÖLÜM 5

YOLOV8, YOLOV9 VE YOLOV11 İLE GÖRÜNTÜ TABANLI DRONE TESPİTİ: KAGGLE DRONE-DETECTION ÜZERİNDE KARŞILAŞTIRMALI BİR ÇALIŞMA	54
--	----

Buse DAYI, Havva Hazel ARAS

BÖLÜM 6

YAPAY ZEKÂ DESTEKLİ AKILLI HASTA İZLEME VE UYARI SİSTEMİ	68
---	----

Hakan Terzioğlu, Eda COŞAR, Abdullah Cem AĞAÇAYAK

BÖLÜM 7

YOLO ALGORİTMALARI.....	85
-------------------------	-----------

Beyzanur ÖZÜTEMİZ

ÖNSÖZ

Yapay zekâ, makine öğrenmesi ve derin öğrenme uygulamaları, son yıllarda savunma teknolojileri, afet yönetimi, kurumsal güvenlik ve otonom sistemler gibi kritik alanlarda veri odaklı karar verme süreçlerinin temel belirleyicilerinden biri haline gelmiştir. Artan hesaplama kapasitesi, yüksek hacimli veri setlerine erişim ve gelişmiş modelleme yaklaşımları, geleneksel yöntemlerle çözümlenmesi güç olan karmaşık problemlerin yapay zekâ tabanlı algoritmalar aracılığıyla daha yüksek doğrulukla ele alınmasını mümkün kılmaktadır. Bu bağlamda, tespit, sınıflandırma, optimizasyon ve durum farkındalığına ilişkin süreçlerin bilimsel niteliği önemli ölçüde gelişmiştir.

Bu kitapta yer alan bölümler, yapay zekâ temelli tespit ve analiz sistemlerinin farklı problem kategorilerindeki uygulamalarını bilimsel bir bakış açısıyla ele almaktadır. Askerî kara araçlarında sürücü uykululuğunun görüntü işleme ve derin öğrenme teknikleri ile tespiti, afet sonrası güvenli rota belirlemede hasar analizi modellerinin kullanımı, analog veri kaynaklarının çok modlu yapay zekâ yaklaşımlarıyla dijitalleştirilmesi, kurumsal güvenlik tehditlerinin makine öğrenimi yöntemleri ile analiz edilmesi ve modern drone tespit problemlerinin YOLO mimarileri üzerinden karşılaştırmalı değerlendirilmesi gibi konular, veri bilimi ile uygulamalı mühendislik arasındaki etkileşimin somut örneklerini oluşturmaktadır.

Kitabın amacı, yapay zekânın farklı uygulama alanlarında nasıl konumlandığını, yöntemsel çeşitliliğini, algoritmik performansını ve modelleme süreçlerinin teknik ayrıntılarını

sistematik bir çerçevede sunmaktır. Her bölüm, problem tanımı, literatür arka planı, yöntemsel yaklaşım, veri seti özellikleri, deneysel kurulum, performans değerlendirme metrikleri ve sonuçların bilimsel yorumunu içerecek şekilde yapılandırılmıştır. Bu kapsam, kitabın hem araştırmacılar hem de uygulayıcılar için kapsamlı bir bilimsel referans kaynağı olmasını amaçlamaktadır.

Bu eserin hazırlanmasında katkı sunan araştırmacılara ve derleme sürecinde destek veren yazarlara teşekkür eder; kitabın yapay zekâ tabanlı tespit sistemleri literatürüne değerli katkılar sağlayacağına inanıyoruz.

Editörler:

Dr. Öğr. Üyesi Sema SERVİ
Öğr. Gör. Dr. Abdullah Cem AĞAÇAYAK
Öğr. Gör. Havva Hazel ARAS

BÖLÜM 1

ASKERİ KARA ARAÇLARINDA YAPAY ZEKÂ TABANLI SÜRÜCÜ UYKULULUK TESPİTİ

Beyza AKKOÇ**, Musa DOĞAN ***

GİRİŞ

Sürücü yorgunluğu ve dikkat kaybı, yalnızca sivil trafikte değil, aynı zamanda askerî operasyonlarda da önemli güvenlik riskleri oluşturmaktadır. Uzun süreli devriyeler, gece görevleri ve yüksek stresli operasyonel ortamlar, sürücülerin dikkat seviyelerini düşürerek kazalara ve görev başarısızlıklarına yol açabilmektedir (Akagündüz & Aydılek, 2021). Bu nedenle, sürücü davranışlarının gerçek zamanlı olarak izlenmesi ve uyku hâlinin erken belirtilerinin tespit edilmesi kritik bir gereklilik hâline gelmiştir (Çubukçu vd., 2015).

Askerî operasyonlarda sürücü yorgunluğu, operasyonel başarıyı tehdit eden en önemli unsurlardan biridir. Modern savaş doktrinlerinde, yapay zekâ kontrollü sistemlerin kullanımı sadece otonom araçlarla sınırlı kalmayıp, mevcut platformların akıllı savunma sistemlerine dönüştürülmesini de kapsamaktadır. Bu dönüşüm süreci, insansız savaşlara doğru giden yolda yapay zekâ kontrollü mekanizmaların ne denli kritik bir role sahip olduğunu göstermektedir (Güntürkün, 2022). Sürücü uykululuk tespit sistemleri de bu otonomlaşma ve güvenlik

** Lisans Öğrencisi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, ORCID: orcid.org/0009-0006-5725-8995

*** Dr. Öğr. Üyesi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, ORCID: orcid.org/0000-0001-8757-2869

hierarchy'sınin temel bir parçası olarak kabul edilmektedir (Güntürkün, 2022, s. 125). Askerî operasyonlarda uzun süreli devriyeler ve yüksek stresli ortamlar, sürücülerin dikkat seviyelerini düşürerek kazalara yol açabilmektedir. Bu riskleri minimize etmek amacıyla geliştirilen sürücü izleme sistemlerinde, davranışsal göstergelerin analizi kritik bir rol oynamaktadır. Günümüzde bu analizlerin temelini oluşturan derin öğrenme (deep learning) teknikleri, bilgisayar bilimleri ve mühendisliği alanında devrim niteliğinde çözümler sunmaktadır. Derin öğrenme mekanizmaları, verilerin çok katmanlı yapılar aracılığıyla işlenmesini sağlayarak uykululuk tespiti gibi karmaşık görevlerde yüksek başarı sağlamaktadır (Civcik & Kholdorov, 2024).

Sistemin başarısı, sürücünün yüzündeki mikro ifadelerin doğru bir şekilde tanımlanmasına dayanır. Bu süreçte kullanılan matematiksel yapıya dayalı örüntü tanıma yöntemleri, görsel verilerin sayısal olarak anlamlandırılması ve sınıflandırılması için gerekli teorik çerçeveyi oluşturmaktadır (Civcik, 2024). Ayrıca, bu tür yapay sinir ağlarının gerçek zamanlı çalışabilmesi için hesaplama hızını artıran algoritmalara ihtiyaç duyulmaktadır (Allahverdi vd., 1994). Yapay sinir ağlarında FFT tipli algoritmaların gerçekleştirilmesi, özellikle yüksek çözünürlüklü görüntülerin işlendiği askerî platformlarda işlem performansını optimize eden önemli bir yaklaşımdır (Allahverdi vd., 1994).

Bu çalışmada, askerî kara araçlarında sürüş güvenliğini artırmak amacıyla Yapay Zekâ Tabanlı Sürücü Uykululuk Tespit Sistemi geliştirilmiştir. Bilgisayarla görü ve derin öğrenme tekniklerindeki hızlı gelişmeler sayesinde, göz kapanma süresi, yüz ifadeleri ve baş pozisyonu gibi davranışsal göstergelerin yüksek doğrulukla analiz edilmesi mümkün hâle gelmiştir (Erdem & Koç, 2020). Özellikle YOLO tabanlı nesne tespit algoritmaları, gerçek zamanlı işlem kabiliyeti ve yüksek tespit performansı sayesinde bu tür uygulamalarda yaygın olarak kullanılmaktadır (European New Car Assessment Programme [Euro NCAP], 2023).

Bu algoritmaların hızlı ve güvenilir şekilde çalışabilmesi, askerî platformlarda anlık durum değerlendirmesi gerektiren uygulamalar için önemli bir avantaj sağlamaktadır.

Mevcut literatür, yüz ve göz hareketlerinin izlenmesinin sürücünün dikkat seviyesini belirlemede oldukça etkili olduğunu göstermektedir

(Küçüköksel & Kaplan, 2023). Ayrıca otomotiv sektöründe kullanılan gelişmiş sürücü izleme sistemleri, dikkat kaybı tespit edildiğinde araç içi uyarılar oluşturarak kazaların önlenmesine katkı sağlamaktadır (National Highway Traffic Safety Administration [NHTSA], 2020). IEEE standartlarına göre, uyarı mekanizmalarının etkili ve rahatsız edici olmayan ikazlar sunabilmesi için insan–makine arayüzü gereksinimlerine uygun olması gerekmektedir (IEEE, 2021).

Sistemin donanım altyapısı Raspberry Pi üzerine kurulmuştur. Düşük güç tüketimi, esnek GPIO yapısı ve kamera uyumluluğu sayesinde Raspberry Pi, bilgisayarla görü tabanlı uygulamalarda yaygın olarak kullanılmaktadır (Raspberry Pi Foundation, 2022). Ayrıca, yüz tespiti, kare işleme ve veri yorumlama işlemlerinin verimli bir şekilde gerçekleştirilebilmesi için görüntü analizi aşamasında OpenCV kütüphanesinden yararlanılmıştır (Kocamaz, 2020). Nesne takibi, tanıma ve görüntü işleme alanlarında yapılan önceki çalışmalar da sistem tasarımına rehberlik etmiştir (Tekin & Seyit, 2022; Zhao vd., 2021). Derin öğrenme algoritmalarının sağladığı yüksek tespit performansı, sadece sürücü izleme sistemlerinde değil, aynı zamanda tarımsal ürünlerin Agtron tabanlı sınıflandırılması gibi farklı endüstriyel alanlarda da açıklanabilir yapay zekâ (XAI) çerçeveleriyle başarıyla uygulanmaktadır (Aras vd., 2025). Görüntü işleme tabanlı bu tür hibrit yapılar, karmaşık uykululuk analizlerinin yanı sıra tıbbi teşhis sistemlerinde, özellikle DenseNet121 ve Grad-CAM kullanılarak gerçekleştirilen cilt kanseri tespiti çalışmalarında da kritik bir öneme sahiptir (Aras, 2025).

Sonuç olarak, yapay zekâ tabanlı sürücü uykululuk tespit sistemleri, askerî kara araçlarında hem güvenliği hem de operasyonel verimliliği önemli ölçüde artırma potansiyeline sahiptir. Modern derin öğrenme teknikleri ve bilgisayarla görü yöntemlerinden faydalanan bu çalışma, askerî personelin operasyonel performansını ve güvenliğini destekleyen etkili bir çözüm sunmayı amaçlamaktadır.

MATERYAL VE METOD

Bu projede kullanılan materyal ve yöntemler; sürücü uykululuk hâlinin gerçek zamanlı, güvenilir ve düşük maliyetli bir şekilde tespit edilmesini amaçlayan yapay zekâ, görüntü işleme ve derin öğrenme tekniklerine dayanmaktadır. Sistem tasarımında kullanılan bileşenlerin

birbiriyle uyumluluğu, yüz ifadelerinin doğru biçimde analiz edilmesi ve gecikme olmaksızın uyarı verilmesi açısından kritik öneme sahiptir.

Sistemde kullanılan derin öğrenme modelleri, karmaşık verilerin işlenmesinde kullanılan ileri sinir ağı mimarilerine dayanmaktadır. Özellikle geri beslemeli sinir ağları (recurrent neural networks), zamansal verilerin analizinde ve harmonik tespitler gibi hassas ölçümlerde yüksek performans sergilemektedir (Temurtas vd., 2004). Bu tür ağ yapılarının doğrusal olmayan sistemlerdeki başarısı, sürücü davranışlarındaki anlık değişimlerin izlenmesi için gereken matematiksel altyapıyı destekler.

Ayrıca, sistemin karar verme mekanizmalarında kullanılan yapay zekâ teknikleri, tıp ve kontrol mühendisliği gibi hata payının sıfıra yakın olması gereken alanlarda da rüştünü ispatlamıştır. Örneğin, anestezi gaz kontrolü gibi kritik süreçlerde kullanılan nöro-bulanık (neuro-fuzzy) sistemler, karmaşık verilerden güvenilir sonuçlar çıkarma yeteneğine sahiptir (Tosun & Güntürk, 2010). Benzer şekilde, Elman'ın geri beslemeli sinir ağlarının esnek geri yayılım algoritmalarıyla tıbbi dozaj belirlemede kullanımı, sinir ağlarının ne kadar hassas sınıflandırmalar yapabildiğini kanıtlamaktadır (Güntürk, 2010). Bu yöntemlerin uykululuk tespitine uyarlanması, sistemin yanlış alarm oranlarını minimize ederek doğruluğunu artırmaktadır.

Projede YOLOv8, OpenCV, Python programlama dili, Raspberry Pi, bir kamera modülü ve buna ek olarak LSTM tabanlı zaman serisi analizi birlikte kullanılmıştır.

YOLOv8 modeli, sürücünün yüzündeki mikro ifadelerin gerçek zamanlı olarak tespit edilmesini sağlayan temel bileşen olarak kullanılmış; göz kapanma süresi, göz kırpma sıklığı ve esneme gibi yorgunluk göstergelerinin belirlenmesine olanak tanımıştır. Görüntüler ilk olarak OpenCV kütüphanesi kullanılarak işlenmiş; yüz, göz ve ağız bölgeleri tespit edilerek karelerden anlamlı özellikler çıkarılmıştır.


Python, YOLOv8, OpenCV, LSTM modeli ve tüm donanım bileşenlerini entegre eden merkezi yazılım altyapısı olarak görev yapmıştır.

Raspberry Pi, sistemin gömülü donanım platformu olarak kullanılmıştır. Düşük maliyeti, taşınabilirliği ve yeterli işlem kapasitesi

sayesinde hem görüntü işleme işlemlerini hem de derin öğrenme modellerini çalıştırabilecek niteliktedir. Bu cihaza bağlı USB kamera veya Pi Kamera Modülü, sürücünün yüzünü sürekli olarak izlemekte ve analiz için gerekli video akışını sağlamaktadır. Kameranin düşük ışık koşullarında dahi net görüntü alabilme yeteneği, modelin doğruluğunu artırmaktadır.


Bu çalışmada, sürücü uykululuk hâlinin tespiti için YOLOv8 ve LSTM modellerini içeren hibrit bir yapı kullanılmıştır. Görüntü işleme aşamasında, özellikle nesne tespiti ve sınıflandırma görevlerinde üstün başarı sergileyen evrişimli sinir ağları (CNN) temel alınmıştır. Literatürde evrişimli sinir ağları kullanılarak gerçekleştirilen sigara içenlerin tespiti gibi çalışmalar, bu ağların sürücü kabini içerisindeki spesifik insan davranışlarını ve nesneleri tanımadaki yetkinliğini kanıtlamaktadır (Civcik, 2022). Bu projede kullanılan yöntem, yalnızca anlık kare analizleriyle sınırlı değildir; aynı zamanda sürücünün zamana bağlı davranış değişimlerini değerlendirmek amacıyla LSTM (Long Short-Term Memory) tabanlı bir yaklaşımı da içermektedir. LSTM modelleri, ardışık zamansal verilerdeki uzun dönemli bağımlılıkları başarılı bir şekilde yakalayabilmektedir. Bu nedenle, YOLOv8 tarafından tespit edilen göz açıklığı, kapanma süresi, esneme hareketleri ve yüz kası dinamikleri gibi parametreler zaman serisi girdileri olarak LSTM modeline aktarılmıştır. Böylece uykululuk durumu yalnızca tek bir kareye dayanarak değil, belirli bir zaman aralığındaki davranış eğilimlerine göre de tespit edilebilmektedir. LSTM modelinin sağladığı zamansal analiz yeteneği, yanlış pozitiflerin azaltılmasına ve daha kararlı bir uyarı mekanizmasının oluşturulmasına katkı sağlamaktadır.

Görüntü işleme, nesne tespiti ve zamansal davranış analizinin birlikte desteklediği bu yapı, sürücünün dikkat seviyesini daha sağlam bir şekilde değerlendirmektedir. Toplanan veriler sınıflandırılmakta ve dikkat azalmasına ilişkin belirtiler tespit edildiğinde uyarı sistemi devreye girmektedir. Uyarı sisteminin genel yapısı Şekil 1’de gösterilmektedir.



Şekil 1. Uyarı Sistemi Şeması

Uyarı mekanizmasının tasarımı, sürücünün dikkatini rahatsızlık vermeden çekmeyi amaçlamaktadır. Sistemin düşük maliyetli donanım üzerinde çalışabilmesi ve enerji verimliliği sağlaması, onu geniş bir kullanıcı kitlesi için pratik ve erişilebilir hâle getirmektedir. Projenin çalışma prensibini gösteren akış diyagramı Şekil 2’de sunulmuştur. Bu diyagramlar aracılığıyla süreç hem teorik hem de görsel olarak desteklenmiştir.



Şekil 2. Proje Akış Şeması

Elektronik Bileşenler

Raspberry Pi5

Raspberry Pi 5, düşük maliyetli, taşınabilir ve enerji verimli bir mini bilgisayardır. Tüm yapay zekâ sistemini, LSTM tabanlı modeli ve tüm görüntü işleme işlemlerini çalıştırabilecek yeterli kapasiteye sahiptir ve araç içerisine kolaylıkla monte edilebilmektedir. Bu cihaz sayesinde

sistem, hem bireysel kullanıcılar hem de ticari araç filoları için erişilebilir hâle gelmektedir.

USB Kamera

Sistem, sürücünün yüzünü sürekli olarak izleyerek gerçek zamanlı görüntü girdisi sağlayacak bir kamera modülüne ihtiyaç duymaktadır. Raspberry Pi'ye bağlı olarak çalışan bu kameranın, düşük ışık koşullarında dahi yüksek kaliteli görüntü yakalayabilecek şekilde seçilmesi gerekmektedir. Gerçek zamanlı video akışı, modelin doğru ve güvenilir analizler gerçekleştirebilmesi için temel veri kaynağı olarak kullanılmaktadır.

LED Uyarı Modülü

Sistemde, sürücü uykululuğu veya dikkat dağınıklığı tespit edildiğinde görsel bir uyarı oluşturmak amacıyla bir LED modülü kullanılmaktadır. Raspberry Pi 5 tarafından kontrol edilen bu LED, sürücüde anında farkındalık oluşturacak ve riskli durumlarda hızlı tepki vermesini teşvik edecek şekilde tasarlanmıştır.


Buzzer

Buzzer, kritik bir durum tespit edildiğinde sistemin işitsel bir uyarı vermesini sağlar. Özellikle sürücünün derin uykululuk belirtileri gösterdiği durumlarda, görsel uyarıya ek olarak işitsel bir ikazın verilmesi güvenlik açısından büyük önem taşımaktadır. Raspberry Pi 5'in GPIO pinleri üzerinden kontrol edilen buzzer, gerekli durumlarda yüksek sesli bir alarm üretebilmektedir.

Breadboard ve Bağlantı Elemanları

Breadboard, LED, buzzer ve diğer elektronik bileşenlerin lehimleme gerektirmeden Raspberry Pi 5'e bağlanmasını sağlar. Geliştirme sürecinde hızlı devre prototiplemesine imkân tanır ve sistemi modüller ile kolayca değiştirilebilir hâle getirir. Jumper kablolar ve breadboard aracılığıyla tüm uyarı sistemi Raspberry Pi ile entegre edilmiştir.

Sistem içerisinde kullanılan Raspberry Pi, kamera modülü, LED göstergesi, buzzer ve breadboard bağlantıları dâhil olmak üzere tüm elektronik bileşenler Şekil 3'te ayrıntılı olarak gösterilmiştir. Bu görsel sunum, sürücü izleme sisteminde kullanılan donanım yerleşimini ve modüller arasındaki bağlantıları açık ve anlaşılır bir şekilde ortaya koymaktadır.



Şekil 3. Uyarı Bildirim Devresi

Yazılım Bileşenleri

YOLOv8

YOLOv8, gerçek zamanlı nesne tespiti için kullanılan bir derin öğrenme algoritmasıdır. Bu projede, sürücünün yüz bölgesindeki göz kapanması ve esneme gibi mikro ifadeler anlık olarak analiz edilmektedir. YOLOv8, bu görsel girdilerden yüksek doğrulukla özellikler çıkarmakta ve yorgunluk ile dikkat azalmasına işaret eden belirtilerin tespit edilmesinde kullanılmaktadır.

OpenCV

OpenCV, görüntü işleme için kullanılan standart bir kütüphanedir ve Python ile tam uyumludur. Bu projede, kamera karelerinin işlenmesi, yüz tespiti ile göz ve ağız bölgelerinin belirlenmesi gibi ön işleme görevlerinde kullanılmaktadır. Ayrıca, görüntüler üzerinde

gerçekleştirilen analizlerin görselleştirilmesini de desteklemektedir.

Python Programlama Dili

Python, yapay zekâ, veri bilimi ve görüntü işleme alanlarında yaygın olarak kullanılan güçlü ve esnek bir programlama dilidir. YOLOv8, OpenCV, GPIO işlemleri ve diğer tüm modüller dâhil olmak üzere sistemin tüm bileşenleri Python aracılığıyla entegre edilmekte ve böylece sistemin tüm işlevleri tek bir çatı altında yönetilebilmektedir. Ayrıca Python'un sade sözdizimi, geliştirme sürecini önemli ölçüde hızlandırmaktadır.

LSTM (Long Short-Term Memory) Model

LSTM, zaman serisi verilerinin analizinde kullanılan gelişmiş bir derin öğrenme modelidir. Geleneksel sinir ağlarından farklı olarak, uzun dönemli bağımlılıkları yakalama konusunda oldukça etkilidir. Bu projede LSTM, sürücünün yüz ifadelerinden elde edilen göz açıklığı, göz kapanma süresi ve esneme sıklığı gibi ardışık özellikleri zaman içerisinde değerlendirerek analiz etmektedir.

YOLOv8 tarafından kare bazında çıkarılan özellikler LSTM modeline girdi olarak aktarılmakta; böylece sistem yalnızca sürücünün tek bir andaki durumunu değil, belirli bir zaman aralığındaki davranış eğilimlerini de analiz edebilmektedir. Bu zamansal analiz yaklaşımı, yanlış pozitiflerin azaltılmasına yardımcı olmakta ve sürücü yorgunluğunun daha güvenilir bir şekilde değerlendirilmesini sağlamaktadır. LSTM'nin bu yeteneği, sürücü uyarı mekanizmasının doğruluğunu ve etkinliğini önemli ölçüde artırmaktadır.


SONUÇLAR VE TARTIŞMALAR

Bu çalışmada geliştirilen sürücü uyku tutululuk tespit ve uyarı sistemi, sürücünün yüz hareketlerini gerçek zamanlı olarak analiz ederek yorgunluk belirtilerini başarıyla tespit etmiştir. Raspberry Pi üzerinde çalışan YOLOv8 tabanlı model, farklı aydınlatma koşulları ve sürücü pozisyonları altında yüz, göz ve ağız hareketlerini yüksek doğrulukla

algılamıştır. Göz kapanma süresi ve esneme sıklığı gibi temel göstergeler etkin bir şekilde değerlendirilmiş ve anlık uykululuk belirtilerinin güvenilir biçimde tespit edilmesi sağlanmıştır.

Buna ek olarak, sürücünün davranışlarını yalnızca tekil kareler üzerinden değil, zamansal örüntüler üzerinden de değerlendirebilmek amacıyla sisteme LSTM tabanlı bir zaman serisi analizi entegre edilmiştir. LSTM modeli; YOLOv8’den elde edilen göz açıklığı, göz kapanma süresi ve esneme dinamikleri gibi ardışık verileri işleyerek uzun dönemli bağımlılıkları başarıyla yakalamıştır. Bu zamansal modelleme yaklaşımı, sistemin kararlılığını artırmış ve kısa süreli yüz ifadelerinden kaynaklanabilecek yanlış pozitiflerin azaltılmasına katkı sağlamıştır.

Sonuç olarak, görsel analiz için YOLOv8 ve zamansal değerlendirme için LSTM’yi bir arada kullanan hibrit yapı, sürücü uykululuğunun tespitinde yüksek performans sergilemiş ve etkili bir uyarı mekanizması sunmuştur. Sistemin düşük maliyetli donanım üzerinde çalışabilmesi ve gerçek zamanlı yanıt verebilmesi, onu hem bireysel sürücüler hem de ticari araç filoları için pratik ve ölçeklenebilir bir çözüm hâline getirmektedir.




Şekil 4. Eğitimli modelin karışıklık matrisi tablosu

Şekil 4’te sunulan normalize edilmiş karmaşıklık (confusion) matrisi, modelin “göz açık”, “göz kapalı”, “ağız”, “yüz” ve “arka plan” sınıflarını ayırt etme performansını göstermektedir. Matrisin

incelenmesi, modelin temel yüz bileşenlerini tespit etmede yüksek doğruluk sağladığını ortaya koymaktadır. Özellikle model; “göz açık” sınıfı için %96, “göz kapalı” sınıfı için %91, “ağız” sınıfı için %97 ve “yüz” sınıfı için %100 doğruluk oranına ulaşmıştır. Bu sonuçlar, modelin sürücünün yüzündeki kritik bölgeleri güvenilir bir şekilde tanımlayabildiğini göstermektedir.

Bununla birlikte, bazı sınıflar arasında sınırlı düzeyde yanlış sınıflandırmalar da gözlemlenmiştir. Örneğin, “göz açık” sınıfının zaman zaman “göz kapalı” sınıfı ile karıştırıldığı ve “arka plan” kategorisinde düşük seviyede yanlış pozitiflerin olduğu görülmektedir. Özellikle “arka plan” sınıfındaki yanlış sınıflandırma oranlarının %25’e kadar ulaşması, modelin karmaşık sahnelerde veya düşük görüntü kalitesi koşullarında nesne sınırlarını ayırt etmekte zaman zaman zorlandığını göstermektedir. Genel olarak model, yüzle ilişkili sınıflarda yüksek doğrulukla çalışmakta ve sürücü yorgunluğunun tespitinde kritik rol oynayan göz ve ağız hareketleri gibi temel özellikleri başarıyla yakalamaktadır. Bununla birlikte, sınıflar arasındaki bu kısmi karışıklıklar, özellikle gerçek zamanlı ve güvenlik açısından kritik uygulamalar için daha ileri düzey optimizasyonlara ihtiyaç duyulduğunu ortaya koymaktadır. Bu tür iyileştirmeler, sistemin kararlılığını, güvenilirliğini ve yüksek riskli durumlarda doğru uyarılar verme yeteneğini daha da artıracaktır.



Şekil 5. Performans ölçümlerini ve kayıpları gösteren sonuç tablosu

Şekil 5. YOLOv8 modelinin eğitim süreci boyunca elde edilen performans metriklerini göstermektedir. Eğitim kaybı grafiklerinde (train/box_loss, train/cls_loss, train/dfl_loss) başlangıçta yüksek olan

kayıp değerlerinin epoch'lar ilerledikçe kademeli olarak azaldığı görülmektedir. Bu durum, modelin etkili bir şekilde öğrenme gerçekleştirdiğini ve parametrelerini başarılı biçimde optimize ettiğini göstermektedir. Benzer şekilde, doğrulama kaybı eğrilerinde (val/box_loss, val/cls_loss, val/df1_loss) gözlemlenen düşüş eğilimi, modelin görülmemiş veriler üzerinde de iyi genelleme yaptığını ve aşırı öğrenme (overfitting) problemi yaşamadığını ortaya koymaktadır.

Precision, recall, mAP50 ve mAP50-95 gibi performans metrikleri de eğitim süreci boyunca belirgin bir iyileşme göstermiştir. Precision ve recall değerleri düzenli olarak artarak 0.90 seviyesinin üzerine çıkmış; bu da modelin ilgili yüz özelliklerini doğru bir şekilde tespit edebildiğini ve farklı sınıfları yüksek güvenilirlikle ayırt edebildiğini göstermektedir. mAP50 ve mAP50-95 metrikleri de tutarlı bir artış sergileyerek rekabetçi performans seviyelerine ulaşmış ve modelin farklı IoU eşiklerinde başarılı bir performans ortaya koyduğunu doğrulamıştır. Genel olarak tüm metrikler birlikte değerlendirildiğinde, YOLOv8 modelinin kararlı ve başarılı bir eğitim sürecinden geçtiği, yüksek doğruluk ve sağlam bir tespit performansı elde ettiği sonucuna varılmaktadır.

Sistem, %90'ın üzerinde bir yorgunluk tespit doğruluğuna ulaşmış; uzun süreli göz kapanması ve esneme gibi uykululuk göstergelerini güvenilir bir şekilde tanıyabildiğini doğrulamıştır. Uygulanan işitsel ve görsel uyarı mekanizmalarının, sürücünün dikkatini hızlı ve etkili biçimde çektiği ve olası risk durumlarında zamanında müdahaleye olanak sağladığı gözlemlenmiştir.



Şekil 6. Proje test sürecinin görsel temsili

Buna ek olarak, Raspberry Pi ve basit bir kamera modülü gibi düşük maliyetli donanım bileşenlerinin kullanılması, sistemin farklı araç türlerine kolayca uyarlanabilmesini mümkün kılmaktadır. Bu

pratik yapı hem bireysel hem de ticari taşımacılıkta yaygın kullanım potansiyelini önemli ölçüde artırmaktadır. Genel olarak test sonuçları, önerilen sistemin gerçek dünya senaryolarında verimli bir şekilde çalıştığını, yorgunlukla ilişkili davranışları doğru biçimde tespit ettiğini ve yol güvenliğini artırmak amacıyla zamanında uyarılar sunduğunu doğrulamaktadır.

Şekil 6’da gösterilen görsellerde, sürücüde uykululuk durumu tespit edildiğinde LED’in yandığı ve ekranda “DROWSY!” uyarısının görüntülendiği görülmektedir. Aynı anda buzzer da işitsel bir uyarı vererek sürücünün dikkatini çekmektedir. Yan tarafta yer alan diğer görselde ise sistem Normal durumu algıladığında herhangi bir uyarının verilmediği gözlemlenmektedir.

Bununla birlikte, sistemin bazı sınırlılıkları da tespit edilmiştir. Örneğin, çok karanlık ortamlar veya doğrudan güneş ışığı gibi aşırı aydınlatma koşullarında yüz tespiti zorlaşmakta ve bu durum doğruluk oranını bir miktar düşürmektedir. Ayrıca sürücünün ani ve hızlı baş hareketleri yapması ya da kameradan uzaklaşması, modelin performansını olumsuz yönde etkileyebilmektedir. Bu sınırlılıklar; gelecekte kızılötesi (IR) kameraların kullanılması, kalp atış hızı veya direksiyon tutuş sensörleri gibi ek sensör entegrasyonları ve gelişmiş görüntü işleme tekniklerinin uygulanmasıyla azaltılabilir. Bu sayede sistemin farklı sürüş koşulları ve çevresel değişkenler altındaki güvenilirliği artırılabilir.

Sistem tarafından sağlanan işitsel ve görsel uyarı mekanizmaları, sürücünün dikkatini kaybetmeden etkili bir şekilde tepki verebilmesi açısından önemlidir. Ancak uyarıların aşırı kullanımı, sürücüde alarm yorgunluğuna yol açabileceğinden, bu mekanizmaların kişiselleştirilmesi örneğin uyarıların şiddetinin ve türünün kullanıcıya göre uyarlanması genel kullanıcı deneyimini iyileştirecektir. Bu yaklaşım, sistemin daha geniş kabul görmesini ve daha etkin bir şekilde kullanılmasını destekleyecektir.

KAYNAKÇA

- Akagündüz, E., & Aydılek, İ. B. (2021). Gerçek zamanlı nesne takibi için düşük hata konum ve hız değerlerine sahip bir sistemin önerilmesi. *Afyon Kocatepe Üniversitesi Bilim ve Mühendislik Dergisi*, 6(2), 56–71.
- Allahverdi, N., Kahramanlı, Ş., & Cıvcık, L. (1994, Nisan). Yapay sinir ağlarında HYPERCUBE FFT tipli algoritmaların gerçekleştirilmesi [Sözlü bildiri]. 2. *Sinyal İşleme ve Uygulamaları Kurultayı*, Türkiye, 339–343.
- Aras, H. H. (2025). Explainable deep learning for skin cancer detection using DenseNet121 and Grad-CAM. N. Doğan (Ed.), *Innovative approaches in applied engineering fields* (1. baskı, s. 328). Selçuk Üniversitesi Mühendislik Bilim ve Teknoloji Dergisi.
- Aras, H. H., Eryeşil, Y., & Köklü, M. (2025, Mayıs). An explainable deep learning framework for Agtron-based coffee roast classification using Grad-CAM [Tam metin bildiri]. *3rd International Conference on Intelligent Systems and New Applications (ICISNA '25)*.
- Cıvcık, L. (2022). Evrişimli sinir ağları kullanarak sigara içenlerin tespiti. L. Cıvcık (Ed.), *Mühendislik alanında uluslararası araştırmalar VI* (1. baskı, s. 158). Eğitim Yayınevi.
- Cıvcık, L. (2024). Matematiksel yapıya dayalı örüntü tanıma yöntemleri. L. Cıvcık (Ed.), *Elektrik-elektronik ve haberleşme mühendisliği alanında uluslararası araştırmalar I* (1. baskı, s. 47). Eğitim Yayınevi.
- Cıvcık, L., & Kholdorov, D. (2024). Derin öğrenme (Deep learning). L. Cıvcık (Ed.), *Bilgisayar bilimleri ve mühendisliği alanında uluslararası araştırmalar I* (1. baskı, s. 78). Eğitim Yayınevi.
- Çubukçu, A., Kuncan, M., İmren, M., Erol, F., Ertunç, H. M., Öztürk, S., & Kaplan, K. (2015). Görüntü işleme ile 3 eksenli robot mekanizması üzerinde nesne ayırt edilmesi ve sıralanması. *ResearchGate*.
<https://www.researchgate.net/publication/309668875>
- Erdem, C., & Koç, A. (2020). Derin öğrenme ile nesne tanıma: YOLO algoritması üzerine bir inceleme. *Teknolojik Araştırmalar Dergisi – Bilgisayar Bilimleri*, 13(2), 101–110.
- European New Car Assessment Programme. (2023). *Assessment protocol – Safety assist: Safe driving* (Version 10.3). Euro NCAP.
<https://www.euroncap.com/media/79883/euro-ncap-assessment-protocol-sa-safedriving-v103.pdf>
- Güntürkün, R. (2010). Determining the amount of anesthetic medicine to be applied by using Elman's recurrent neural networks via resilient back propagation. *Journal of Medical Systems*, 34, 493–497. <https://doi.org/10.1007/s10916-009-9262-0>
- Güntürkün, R. (2022). *İnsansız savaşımlara doğru yapay zekâ kontrollü ölümcül silahlar*. Ekin Basım Yayın Dağıtım.
- IEEE. (2021). *IEEE standards on human-machine interface for driver alerts*. Institute of Electrical and Electronics Engineers.
- Kocamaz, Ü. (2020). OpenCV ile görüntü işleme ve uygulamaları. *Akademik Platform Mühendislik ve Fen Bilimleri Dergisi*, 8(3), 524–534.
- Küçüköksel, A., & Kaplan, S. (2023). Sürücü uyuşukluk tespiti üzerine bir araştırma. *Eurasian Journal of Science and Engineering (EJONS)*, 9(28), 373–384.
<https://ejons.org/index.php/ejons/article/view/279>

- National Highway Traffic Safety Administration. (2020). *Driver monitoring technology overview*. U.S. Department of Transportation. <https://www.nhtsa.gov/vehicle-safety/driver-assistance-technologies>
- Raspberry Pi Foundation. (2022). *Documentation and GPIO interface guidelines*. <https://www.raspberrypi.com/documentation/>
- Tekin, S., & Seyit, M. (2022). Araç içi trafik kazalarına uyku bozuklukları ve yorgunluğun etkisi. *Namik Kemal Medical Journal*, 10(4), 386–391. <https://doi.org/10.4274/nkmj.galenos.2022.65982>
- Temurtas, F., Güntürkün, R., Yumuşak, N., & Temurtas, H. (2004). Harmonic detection using feed forward and recurrent neural networks for active filters. *Electric Power Systems Research*, 72, 33–40.
- Tosun, M., & Güntürkün, R. (2010). Anesthetic gas control with neuro-fuzzy system in anesthesia. *Expert Systems with Applications*, 37, 2690–2695.
- Zhao, M., Jin, S., Chen, Y., Wang, L., & Wu, Q. (2021). Drowsiness detection based on facial expression recognition using deep convolutional neural networks. *Sensors*, 21(9), 3054.

BÖLÜM 2

DERİN ÖĞRENME TABANLI HASAR TESPİTİ ENTEĞRELİ AFET SONRASI GÜVENLİ ROTA BELİRLEME SİSTEMİ

Süleyman Yıldız^{**}, Sema Servi^{***}

GİRİŞ

Günümüzde, doğal afetlerin özellikle büyük ölçekli depremlerin sıklığının ve şiddetinin artması, kentsel altyapıda ciddi yıkımlara neden olmakta ve ulaşım ağlarını etkisiz hale getirmektedir. Arama-kurtarma ekiplerinin ve erzak lojistiğinin, "altın saatler" olarak adlandırılan ilk 72 saat içinde bölgelere en kısa sürede ve güvenli erişim sağlaması hayati öneme sahiptir. Ancak, 6 Şubat 2023 Kahramanmaraş depreminde de görüldüğü üzere, geleneksel navigasyon sistemleri (Google Haritalar, Yandex vb.) statik rota verilerine dayanmaktadır. Bundan dolayı, mevcut sistemler yol üzerindeki yıkıntılar veya ağır hasarlı köprüler gibi anlık fiziksel engelleri tespit etmekte yetersiz kalmaktadır. Bu durum, ekiplerin kapalı güzergâhlara yönlendirilmesine, dolayısıyla müdahale sürelerinin uzamasına ve kritik kaynakların verimsiz kullanılmasına yol açmaktadır. Doğal afetler sonrasında ulaşım ağlarının hızla analiz edilmesi ve güvenli lojistik rotaların belirlenmesi, arama-kurtarma operasyonlarının başarısı

^{**} Lisans Öğrencisi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, 243301031@ogr.selcuk.edu.tr, ORCID: orcid.org/0009-0001-5165-9038

^{***} Dr. Öğr. Üyesi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, semaservi@selcuk.edu.tr, ORCID: orcid.org/0000-0003-2069-9085

için hayati önem taşır. Günümüzde bu süreçlerin otomasyonu, insansız araçların ve yapay zekâ teknolojilerinin savunma ve afet yönetimi doktrinlerine entegrasyonu ile yeni bir boyut kazanmıştır. Yapay zekâ kontrollü sistemlerin gelişimi, afet bölgelerinde otonom karar verebilen platformların önemini artırmış ve bu teknolojileri modern stratejik savunma araçlarının bir parçası haline getirmiştir (Güntürk, 2022). Afet sonrası hasar tespiti yapan insansız sistemler, operasyonel riskleri minimize ederken "insansız müdahale" konseptine de hizmet etmektedir (Güntürk, 2022, s. 125).

Bu boşluğu gidermek için, bu çalışma nesne tespiti (YOLOv8m) ile rota optimizasyonunu (OSRM) birleştiren entegre bir mimari önermektedir. Bu araştırmanın katkısı, yapılandırılmamış görüntü verilerinin PostGIS tabanlı dinamik bir hücresel ağ sistemi içinde işlenerek anlamlı mekansal verilere dönüştürülmesi ve ardından OSRM motorunun maliyet fonksiyonunda ağırlık parametresi olarak kullanılmasıdır. Simülasyon verilerine dayanan teorik çalışmaların aksine, önerilen sistem sahadan elde edilen görüntüleri işleyerek; gece ve gündüz koşullarında yol analizini gerçekleştiren ve güvenli lojistik yollar oluşturan uygulanabilir bir mimari sunmaktadır.

Doğal afetler, yerleşim alanlarında büyük çaplı yıkımlara neden olarak ulaşım ağlarını ve lojistik hatları ciddi şekilde kesintiye uğratmaktadır. Afet sonrası süreçte, insani yardımın ulaştırılması ve tahliye operasyonlarının gerçekleştirilmesi için güvenli rotaların belirlenmesi hayati önem taşır. Bu tür kritik süreçlerde kullanılan derin öğrenme (deep learning) modelleri, karmaşık veri yapılarından anlamlı özellikler çıkararak karar destek mekanizmalarını güçlendirmektedir (Civcik & Kholdorov, 2024). Derin öğrenme katmanları, afet bölgelerinden alınan görüntülerin analiz edilmesinde ve hasar seviyelerinin sınıflandırılmasında insan müdahalesine olan ihtiyacı minimize eder (Civcik & Kholdorov, 2024).

Literatür taraması yapıldığında, afet yönetiminde Yapay Zekâ tabanlı çözümlerin giderek arttığı görülmektedir. Günümüzde yapay zeka ve makine öğrenmesi teknolojileri, karmaşık veri setlerinin analiz edilmesinden karar destek sistemlerinin oluşturulmasına kadar mühendisliğin pek çok dalında geniş bir kullanım yelpazesine sahiptir (Mirjafarlı ve Terzioğlu, 2022). Yapay zeka ve makine öğrenmesi metotları yalnızca mühendislik ve rota optimizasyonu alanlarında değil,

aynı zamanda tıp ve sađlık bilimleri gibi hassas veri iřleme gerektiren stratejik alanlarda da tanı ve teřhis sũreçlerini iyileřtirmek amacıyla yaygın olarak kullanılmaktadır (Mirjafarlı vd., 2022). Bu disiplinlerarası başarı, derin öğrenme tabanlı nesne tespiti modellerinin afet yönetimi ve hasar tespiti gibi kritik görevlerde güvenle uygulanabilmesine teorik ve pratik bir zemin hazırlamaktadır. Özellikle Rastgele Orman (Random Forest-RF) gibi denetimli öğrenme algoritmaları, sınıflandırma ve regresyon problemlerindeki yüksek başarı oranları sayesinde farklı disiplinlerdeki mühendislik problemlerinin çözümünde sıklıkla tercih edilmektedir (Mirjafarlı ve Terziođlu, 2022). Derin öğrenme modellerinin karar verme sũreçlerini řeffařlařtıran Grad-CAM gibi açıklanabilir yapay zekâ (XAI) teknikleri, sadece afet yönetiminde deđil, tarımsal ürünlerin Agtron tabanlı sınıflandırılması gibi farklı endũstriyel alanlarda da yüksek dođrulukla uygulanmaktadır (Aras vd., 2025). Görüntü iřleme tabanlı derin öğrenme mimarileri, karmařık enkaz analizlerinin yanı sıra tıbbi tanı sistemlerinde, özellikle DenseNet121 ve Grad-CAM kullanılarak gerçekteřtirilen cilt kanseri tespit çalıřmalarında da kritik bir öneme sahiptir (Aras, 2025). Özellikle Derin Öğrenme yaklařımları, İnsansız Hava Araçları (İHA) ve uydu görüntülerini kullanarak hasar tespiti konusunda öne çıkmaktadır. Özellikle Kızılay vd. (2024), drone görüntülerinden gerçekte zamanlı hasar tespiti için ince ayar yapılmıř (fine-tuned) modeller geliřtirmiş ve YOLO mimarisinin hız ve dođruluk avantajlarını ortaya koymuřtur. Benzer řekilde Chen vd. (2024), İHA destekli yol çatlaklarının tespitinde; YOLOv8 modellerinin düşük iřlem maliyeti sayesinde, Faster R-CNN gibi iki ařamalı yapıları kıyasla gerçekte zamanlı kullanımda daha üstün olduđunu ortaya koymuřtur.

Bu ilerlemelere rađmen, mevcut çalıřmaların çođu hasarın tespiti ve sınıflandırılması ile sınırlı kalmaktadır. Tespit edilen hasar verilerinin, rota optimizasyonunda deđiřken olarak kullanılmak üzere dinamik navigasyon sistemlerine otonom entegrasyonu konusunda literatũrde önemli bir boşluk bulunmaktadır. Örneđin, Shiri ve Salman (2020) afet lojistiđinde çevrimiçi optimizasyona odaklanmıř olsa da anlık yol verisinin sahadan nasıl toplanacađı sorusuna bir yöntem sunmamıřtır. Benzer biçimde, Gadhane vd. (2023) ve Sirma vd. (2025) çalıřmalarında hasar tespiti başarılmıř; ancak elde edilen veriler dinamik bir rota motoruna entegre edilmemiřtir.

YÖNTEM

Hasar tespiti ve rota optimizasyonu için geliştirilen derin öğrenme modelleri, karmaşık sinyal ve görüntü verilerini işleme kabiliyetine sahip ileri sinir ağı mimarilerinden beslenmektedir. Literatürde, geri beslemeli sinir ağlarının (recurrent neural networks) ve ileri beslemeli yapıların harmonik tespitler gibi hassas veri analizi gerektiren alanlardaki başarısı, afet verilerinin işlenmesindeki doğruluğu destekler nitelikte bir altyapı sunmaktadır (Temurtas vd., 2004).

Önerilen sistemde kullanılan karar destek mekanizmaları, belirsizlik altındaki karmaşık sistemlerin kontrolünde rüştünü ispatlamış yöntemlerle paralellik gösterir. Örneğin, tıbbi uygulamalarda anestezi gaz kontrolü için kullanılan nöro-bulanık (neuro-fuzzy) sistemler veya Elman'ın geri beslemeli sinir ağları ile yapılan hassas dozaj hesaplamaları, yapay sinir ağlarının kritik kararlarda ne denli güvenilir sonuçlar üretebildiğini kanıtlamaktadır (Tosun & Güntürk, 2010; Güntürk, 2010). Bu tür hassas hesaplama yöntemlerinin afet sahasındaki rota planlama süreçlerine uyarlanması, enkaz altındaki yolların ve yapısal hasarların doğru sınıflandırılmasını sağlayarak hata payını minimize etmektedir. Bu çalışmada geliştirilen entegre mimari, afet bölgesinden elde edilen görsel verilerin derin öğrenme tabanlı analizine, bu analizlerin mekansal veri katmanlarına dönüştürülmesine ve sonunda güvenli rota algoritması için dinamik maliyet parametreleri olarak kullanılmasına dayanmaktadır. Afet sonrası uydu veya drone görüntülerinden hasar tespiti yapmak amacıyla derin öğrenme mimarileri kullanılmıştır. Görüntü işleme sürecinin merkezinde yer alan evrişimli sinir ağları (CNN), pikseller arasındaki mekânsal ilişkileri analiz ederek hasarlı yapıları tespit eder. Literatürde CNN mimarilerinin nesne tespiti (örneğin sigara içenlerin tespiti) gibi özel görevlerdeki başarısı, bu ağların afet sahasındaki spesifik enkaz türlerini tanımadaki potansiyelini de doğrulamaktadır (Civcik, 2022).


Veri Seti ve Ön İşleme

Modelin eğitimi ve testi için kullanılan veri seti, öncelikli olarak 6 Şubat 2023 Kahramanmaraş depremleriyle ilgili kamuya açık kaynaklardan (sosyal medya, haber ajansları) ve proje kapsamında sahadan toplanan görüntülerden derlenmiştir. DRespNeT (Sirma vd., 2025) ve xView2 (Gadhane vd., 2023) gibi literatürde kullanılan veri setleri incelenmiş; ancak, bu çalışmanın özgün amacı olan "yol durumu" ve "bina

hasarını" eş zamanlı olarak içeren hibrit bir veri yapısı oluşturulmuştur. Veri setindeki gürültüyü en aza indirmek ve mekansal doğruluğu sağlamak için sadece coğrafi etiket (geo-tag) içeren dış mekân görüntüleri filtrelenmiştir. Modelin genelleme yeteneğini artırmak ve aşırı öğrenmeyi (overfitting) önlemek için veri artırma teknikleri uygulanmıştır. Bu kapsamda görüntüler üzerinde rastgele döndürme ($\pm 15^\circ$), yatay çevirme, parlaklık değişimi ($\pm \%20$) ve gürültü ekleme işlemleri yapılmıştır. Toplam veri seti %60 Eğitim, %20 Doğrulama ve %20 Test setlerine ayrılmıştır.

YOLOv8 ile Hasar Tespiti

Görüntülerdeki hasarın tespiti ve sınıflandırılması için tek aşamalı bir nesne tespit algoritması olan YOLOv8m (You Only Look Once - Medium) modeli tercih edilmiştir. Karşılaştırmalı analizler, YOLOv8 varyantlarının, doğruluktan (mAP) ödün vermezken, Faster R-CNN gibi iki aşamalı mimarilere kıyasla afet ortamlarının gerektirdiği gerçek zamanlı çıkarım hızını sağladığını göstermiştir (Chen vd., 2024). Ayrıca, Kurniadi vd. (2025) tarafından yapılan karşılaştırmalarda, YOLOv8 varyantlarının yol bozulmalarını tespit etmede yüksek kesinlik (%99,0 Precision) sergilediği rapor edilmiştir. Model, transfer öğrenme yöntemiyle COCO veri setindeki ön eğitilmiş ağırlıklar kullanılarak başlatılmış ve deprem hasar verileri üzerinde ince ayar (fine-tuning) yapılmıştır. Tespit işlemi yedi farklı sınıf üzerinden gerçekleştirilmektedir: yol çatlağı, yıkık bina, enkaz, kapalı yol ve hasarlı altyapı. Modelin farklı hasar türleri üzerindeki performansını ve çevresel koşullara karşı dayanıklılığını görselleştirmek için sistemin örnek çıktıları Şekil 1'de sunulmuştur.



(a)



(b)



(c)

Şekil 1: Geliştirilen YOLOv8m modelinin farklı senaryolardaki tespit performansı: (a) Karmaşık enkaz ortamlarında binaların "Yıkık" ve "Çok Riskli" olarak sınıflandırılması; (b) Yol yüzeyindeki fiziksel bozulmaların ve çatlakların tespiti; (c) Düşük ışık ve gece koşullarında yol geçilebilirlik analizi

Görüntüler incelendiğinde sistemin çok yönlü analiz yeteneği görülmektedir. Şekil 1-a, modelin karmaşık enkaz yığınları arasında binaları hasar ciddiyetine göre başarıyla ayırt edebildiğini göstermektedir. Rota güvenliği için kritik olan yol yüzeyi analizi Şekil 1-b'de gösterilmiş olup, model toprak yoldaki yüzey koşullarını analiz etmiş ve doğru bir şekilde geçilebilir rota olarak tanımlamıştır. Son olarak, afet lojistiğinin sürekli sürdürülebilirliği için modelin düşük ışık performansı test edilmiştir. Şekil 1-c, sistemin gece koşullarında dahi yol hattını algılayabildiğini ve 'geçilebilir' etiketi atayabildiğini kanıtlamaktadır.

PostGIS Tabanlı Mekansal Hücresel Ağ Sistemi

YOLOv8m modelinden elde edilen piksel tabanlı hasar verilerini coğrafi uzayda anlamlı kılmak için PostGIS veritabanı üzerinde 500m × 500m boyutlarında dinamik bir hücresel ağ (grid) sistemi oluşturulmuştur. Her bir hücre, o bölgeden gelen hasar raporlarının (fotoğrafların) konumuna göre güncellenmektedir. Sistemin tekil ve hatalı verilerden etkilenmesini önlemek için bir "çoklu doğrulama yöntemi" uygulanmıştır. İlgili hücrenin nihai hasar skoru, tek bir tespit yerine o hücreye denk gelen tüm tespitlerin güven skorlarının ve hasar sınıfı ağırlıklarının ortalaması alınarak hesaplanmaktadır.

OSRM Entegreli Güvenli Rota Algoritması

Rota hesaplaması için açık kaynaklı OSRM (Open Source Routing Machine) motoru temel alınmıştır. Geleneksel navigasyon sistemleri ve afet lojistiği algoritmaları genellikle mesafe minimizasyonuna odaklanırken (Shiri ve Salman, 2020), bu çalışmada OSRM maliyet fonksiyonu hasar riskini içerecek şekilde modifiye edilmiştir. Önerilen Güvenli Rota Algoritması, yol segmentlerinin ağırlıklarını hesaplarken iki temel parametreyi dikkate alır: Güvenlik ve Zaman. Algoritma, PostGIS hakkahücresel sistemindeki hasar verilerini yol ağına yansıtır, yüksek hasar skoruna sahip yolları "yüksek maliyetli" olarak işaretler ve rotadan hariç tutar. Optimizasyon fonksiyonu (Denklem 1), %70 Güvenlik ve %30 Zaman ağırlıklı olarak yapılandırılmıştır:

$$\text{Cost} = 0.7 \times \text{SafetyScore} + 0.3 \times \text{TimeScore} \quad (1)$$


Bu formülasyon sayesinde sistem en kısa rotayı değil, hasarsız veya minimum hasarlı en hızlı rotayı (en güvenli koridoru) önermektedir.

BULGULAR

Model Performans Bulguları


Geliştirilen YOLOv8m modeli, eğitim ve test süreçleri sonunda yüksek tutarlılık elde etmiştir. Modelin genel başarımı (mAP@50), 6 Şubat deprem veri setinden ayrılan test seti üzerinde %85 olarak ölçülmüştür. Modelin performans dengesini incelemek için F1-Eğrisi ve Kesinlik

(Precision) Eğrisi analiz edilmiştir. Modelin güven skoru ile harmonik ortalamasını gösteren F1-Eğrisi Şekil 2'de sunulmuştur.



Şekil 2. Modelin tüm sınıfları için F1-Skoru eğrisi


Eğrinin yüksekliği, modelin hem kesinlik (precision) hem de duyarlılığının (recall) optimize edildiğini ve 0.5 güven eşliğinde en verimli sonuçları ürettiğini göstermektedir. Ayrıca, modelin yanlış pozitif (yanlış alarm) oranını minimize etmedeki başarısını gösteren P-Eğrisi (Kesinlik-Güven Eğrisi) Şekil 3'te sunulmuştur.



Şekil 3. Güven skorunun bir fonksiyonu olarak modelin kesinlik eğrisi

Güven eşiği arttıkça kesinlik değerinin 1.0'a yaklaşması, sistemin yüksek güvenle yaptığı tespitlerde hata payının ihmal edilebilir düzeyde olduğunu kanıtlamaktadır. Sınıf bazlı performans incelendiğinde, modelin özellikle "Yıkık Bina" ve "Kapalı Yol" sınıflarında yüksek ayırt edicilik

yeteneğine sahip olduğu görülmektedir. Bu başarı, modelin hangi hasar türlerini birbiriyle karıştırdığını gösteren Karışıklık Matrisi (Confusion Matrix) ile de doğrulanmaktadır (Şekil 4).



Şekil 4. Modelin sınıf bazlı performansını gösteren normalleştirilmiş karışıklık matrisi

Matris incelendiğinde, modelin "Yıkık Bina" sınıfını 0.89 oranında doğru tespit ettiği görülmektedir. Bu sonuçlar, Kızılay vd. (2024) tarafından rapor edilen %88 mAP değerine oldukça yakındır ve YOLO mimarisinin başarısını doğrulamaktadır. Ayrıca Chen vd. (2024) tarafından belirtildiği gibi, Faster R-CNN'in yavaşlığına rağmen, modelimiz ortalama 27 FPS hıza ulaşarak gerçek zamanlı kullanıma uygunluğunu kanıtlamıştır.

Rota Optimizasyon Bulguları

Sistemin rota belirleme başarısı, Kahramanmaraş deprem verileriyle oluşturulan geriye dönük bir senaryo üzerinde sayısal olarak test edilmiştir. Aynı başlangıç ve bitiş noktaları için Geleneksel En Kısa Yol (Dijkstra) algoritması ile önerilen Güvenli Rota Algoritması karşılaştırılmıştır. Analiz sonucunda, geleneksel algoritmanın önerdiği 4.2 km'lik rotanın %60'ının "yüksek riskli" bölgelerden (yıkık bina veya enkaz içeren) geçtiği belirlenmiştir. Buna karşılık, önerilen sistem rotayı 5.8 km'ye uzatmasına rağmen, rota üzerindeki riskli segment oranını %10'un altına düşürmüştür. Teorik seyahat mesafesi artmış olsa da bu durum sahadaki yol kapanma

riskini ortadan kaldırarak operasyonel varış güvenliğini garanti altına almıştır.

TARTIŞMA

Bu çalışmadan elde edilen veriler, derin öğrenme destekli hasar tespitinin afet lojistiğine entegrasyonunun teorik bir öneriden öte, sahada uygulanabilir somut bir çözüm olduğunu göstermektedir.

Modelin başarımlı performansı literatürle kıyaslandığında; "Yıkık Bina" sınıfında ulaşılan 0.89'luk doğruluk oranı, benzer veri setleri kullanan Kızılay vd. (2024)'nin raporladığı %88 mAP değeriyle paralellik göstermektedir. Bu durum, çalışmada tercih edilen hibrit veri setinin, modelin hem doğruluğunu koruduğunu hem de farklı senaryolara uyum yeteneğini artırdığını göstermektedir. Öte yandan, Chen vd. (2024) tarafından Faster R-CNN gibi iki aşamalı mimarilerin en büyük dezavantajı olarak belirtilen yüksek işlem yükü sorunu, bu çalışmada optimize edilmiştir. Testlerde ulaşılan 27 FPS'lik işlem hızı, önerilen sistemin İHA gibi sınırlı donanıma sahip platformlarda bile gerçek zamanlı çalışmasına olanak tanımaktadır.

Rota analizi sonuçları ise afet lojistiğindeki kritik "hız ve güvenlik" dengesini net bir şekilde ortaya koymuştur. Geleneksel algoritmaların (Dijkstra) önerdiği kısa rotaların %60 oranında risk barındırması, Shiri ve Salman'ın (2020) dikkat çektiği "çevrimiçi rota belirsizliği" probleminin sahadaki somut yansımasıdır. Gadhav (2023) ve Sirma (2025) gibi çalışmalar hasar tespiti aşamasında başarılı sonuçlar verse de bu verilerin operasyonel bir karara dönüştürülmesi noktasında sınırlı kalmıştır. Geliştirilen bu sistem ise görsel hasar verisini doğrudan matematiksel bir maliyete dönüştürerek literatürdeki "veri-eylem kopukluğunu" gidermiştir.

Sonuç olarak, önerilen yöntemin rotayı fiziksel olarak uzatması bir verimsizlik değil; aksine, kapalı yollardan kaçınarak ekiplerin bölgeye güvenli erişimini garanti altına alan stratejik bir tercih olarak değerlendirilmelidir.

SONUÇ VE ÖNERİLER

Çalışmada, afet sonrası dinamik yol durumu belirsizliğini ortadan kaldırmak ve lojistik operasyonların güvenliğini artırmak amacıyla derin

öğrenme destekli, uçtan uca otonom bir güvenli rota belirleme sistemi geliştirilmiştir. Çalışma sonucunda, statik harita verilerinin yetersiz kaldığı "altın saatler" evresinde, YOLOv8 tabanlı görsel analiz yönteminin %85 doğruluk oranıyla hasarı tespit edebildiği görülmüştür. Daha da önemlisi, bu verilerin PostGIS ve OSRM entegrasyonu ile mekânsal bilgiye dönüştürülmesi sayesinde, arama-kurtarma ekipleri için önerilen rotalardaki risk oranı %10'un altına düşürülmüştür. Bu durum, sadece teorik bir optimizasyon başarısı değil, aynı zamanda sahadaki müdahale sürelerini kısaltacak operasyonel bir kazanım olarak değerlendirilmelidir.

Elde edilen sonuçlar, afet yönetiminde "Veri-Eylem Kopukluğu"nın giderilmesi adına, görsel verilerin doğrudan karar destek mekanizmalarına dahil edilmesinin kritik olduğunu ortaya koymaktadır. Geliştirilen sistemin düşük ışık koşullarında dahi %81 güven skoruyla çalışabilmesi, afet lojistiğinin kesintisiz sürdürülebilirliği açısından umut vericidir. Gelecek çalışmalar ve araştırmacılar için şu öneriler sunulabilir:

- **Farklı Afet Senaryoları:** Mevcut model deprem odaklı eğitilmiştir. Sistemin sel, orman yangını veya heyelan gibi yol ağını etkileyen diğer afet türleri için de özelleştirilmiş veri setleriyle eğitilerek kapsamının genişletilmesi önerilmektedir.

- **Gerçek Zamanlı Veri Akışı:** Çalışmada geriye dönük veriler kullanılmıştır. İlerleyen aşamalarda sistemin, afet bölgesinde görev yapan İHA sürüleri veya araç içi kameralardan gelen anlık görüntü akışıyla (real-time streaming) beslendiği bir mimarinin test edilmesi faydalı olacaktır.

- **Hibrit Veri Kullanımı:** Sadece görsel veriler değil, sismik veriler ve trafik yoğunluk verilerinin de maliyet fonksiyonuna eklenmesiyle daha hassas bir rota optimizasyonu sağlanabilir.

KAYNAKÇA

- Allahverdi, N., Kahramanlı, Ş., & Cıvcık, L. (1994, Nisan). *Yapay sinir ağlarında HYPERCUBE FFT tipli algoritmaların gerçekleştirilmesi* [Sözlü bildiri]. 2. Sinyal İşleme ve Uygulamaları Kurultayı, Türkiye, 339–343.
- Aras, H. H. (2025). Explainable deep learning for skin cancer detection using DenseNet121 and Grad-CAM. N. Doğan (Ed.), *Innovative approaches in applied engineering fields* (1. baskı, s. 328). Selçuk Üniversitesi Mühendislik Bilim ve Teknoloji Dergisi. ISBN: 978-975-448-246-1. (Yayın No: 9700458).
- Aras, H. H., Eryeşil, Y., & Köklü, M. (2025, Mayıs). *An explainable deep learning framework for Agtron-based coffee roast classification using Grad-CAM* [Tam metin bildiri]. 3rd International Conference on Intelligent Systems and New Applications (ICISNA'25). (Yayın No: 9876687).
- Azimi, S., Delavar, M. R., & Rajabifard, A. (2017). Multi-agent simulation of allocating and routing ambulances under condition of street blockage after natural disaster. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 325–332.
- Bera, S., Mankad, N., Limkar, G., Arulmurugan, T., Pai, D., & Gupta, G. (2024). Adaptive deep learning techniques for real-time shortest path optimization in drone ambulance operations during disaster. *Proceedings of International Conference on Recent Innovations in Computing* (ss. 1860–1866). Springer.
- Chen, X., Liu, C., Chen, L., Zhu, X., Zhang, Y., & Wang, C. (2024). A pavement crack detection and evaluation framework for a UAV inspection system based on deep learning. *Applied Sciences*.
- Cıvcık, L. (2022). Evrişimli sinir ağları kullanarak sigara içenlerin tespiti. L. Cıvcık (Ed.), *Mühendislik alanında uluslararası araştırmalar VI* (1. baskı, s. 158). Eğitim Yayınevi.
- Cıvcık, L. (2024). Matematiksel yapıya dayalı örüntü tanıma yöntemleri. L. Cıvcık (Ed.), *Elektrik-elektronik ve haberleşme mühendisliği alanında uluslararası araştırmalar-I* (1. baskı, s. 47). Eğitim Yayınevi.
- Cıvcık, L., & Kholdorov, D. (2024). Derin öğrenme (Deep learning). L. Cıvcık (Ed.), *Bilgisayar bilimleri ve mühendisliği alanında uluslararası araştırmalar I* (1. baskı, s. 78). Eğitim Yayınevi.
- Eryeşil, Y., & Taşdemir, Ş. (2023). A deep learning approach for efficient waste classification. *9th International “Başkent” Congress on Physical, Engineering, and Applied Sciences*.
- Gadhve, P., Chaturvedi, P., Bera, S. C., Singh, A., & Joseph, R. W. (2023). Post-disaster aerial image analysis using deep learning and image processing. *Advances in Intelligent Systems and Computing* (ss. 345–362).
- Güntürkün, R. (2010). Determining the amount of anesthetic medicine to be applied by using Elman’s recurrent neural networks via resilient back propagation. *Journal of Medical Systems*, 34, 493–497. <https://doi.org/10.1007/s10916-009-9262-0>
- Güntürkün, R. (2022). *İnsansız savaşımlara doğru yapay zekâ kontrollü ölümcül silahlar*. Ekin Basım Yayın Dağıtım.
- González, C. B., Montoya, G. A., & Lozano-Garzón, C. (2025). Toward reliable post-disaster assessment: Advancing building damage detection using You Only Look Once convolutional neural network and satellite imagery. *Mathematics*, 13(7), 1041.
- Hu, D., Li, S., Du, J., & Cai, J. (2023). Automating building damage reconnaissance to optimize drone mission planning for disaster response. *Journal of Computing in Civil Engineering*, 37(3).

- Kızılay, F., Narman, M. R., Song, H., Narman, H. S., Coşgun, C., & Alzarrad, A. (2024). Evaluating fine tuned deep learning models for real-time earthquake damage assessment with drone-based images. *AI in Civil Engineering*, 3(1).
- Kurniadi, D., Latif, A. A., Mulyani, A., & Aulawi, H. (2025). Benchmarking YOLOv8 variants with transfer learning for real-time detection and classification of road cracks and potholes. *Jurnal RESTI*, 9(4), 771–780.
- Liu, B., Lyu, C., & Wang, S. (2022). *Convolutional neural networks' efficiency on binary classification of damaged building on post hurricane satellite imagery*. Proceedings (No. 12287).
- Long, Y., Xu, G., Zhao, J., Xie, B., & Fang, M. (2023). Dynamic truck–UAV collaboration and integrated route planning for resilient urban emergency response. *IEEE Transactions on Engineering Management*.
- Mehajabin, N., Ma, Z., Wang, Y., Tohidypour, H. R., & Nasiopoulos, P. (2022). Real-time deep learning based road deterioration detection for smart cities. *Conference Proceedings* (ss. 321–326).
- Mirjafarlı, S., & Terzioğlu, H. (2022). RF makine öğrenme metodunun kullanım alanlarına genel bakış (Bölüm 21). G. Yalçın & A. C. Ağaçayak (Ed.), *Mühendislikte yeni araştırmalar* (s. 305). Tablet Kitabevi.
- Mirjafarlı, S., Terzioğlu, H., & Ağaçayak, A. C. (2022). Yapay zeka ve makine öğrenme metodlarının tıp'ta kullanım alanlarına genel bakış (Bölüm 9). G. Yalçın & A. C. Ağaçayak (Ed.), *Mühendislikte yeni araştırmalar* (s. 305). Tablet Kitabevi.
- Shiri, D., Akbari, V., & Salman, F. S. (2024). Online algorithms for ambulance routing in disaster response with time-varying victim conditions. *OR Spectrum*, 1–35.
- Shiri, D., & Salman, F. S. (2020). Online optimization of first-responder routes in disaster response logistics. *IBM Journal of Research and Development*, 64.
- Sirma, A., Plastropoulos, A., Zolotas, A. C., & Tang, G. (2025). *DRespNeT: A UAV dataset and YOLOv8-DRN model for aerial instance segmentation of building access points for post-earthquake search-and-rescue missions*. arXiv. <https://arxiv.org/abs/2508.16016> (Erişim Tarihi: 28.12.2025).
- Temurtas, F., Güntürkün, R., Yumuşak, N., & Temurtas, H. (2004). Harmonic detection using feed forward and recurrent neural networks for active filters. *Electric Power Systems Research*, 72, 33–40.
- Tosun, M., & Güntürkün, R. (2010). Anesthetic gas control with neuro-fuzzy system in anesthesia. *Expert Systems with Applications*, 37, 2690–2695.
- Ye, X. W., Liu, Z., Ding, Y., Li, Z., & Jin, T. (2022). Post-earthquake damage recognition and condition assessment of bridges using UAV integrated with deep learning approach. *Structural Control & Health Monitoring*, 29(12).

BÖLÜM 3

ANALOG SINIFIN DİJİTALLEŞTİRİLMESİ: YAPILANDIRILMAMIŞ EĞİTİM VERİLERİNDE ÇOK MODLU RAG ANALİZİ

Yiğit Eren Öztaş^{**}, Sema Servi^{***}

GİRİŞ

Eğitim sistemlerinde dijital dönüşüm, son yıllarda öğretim materyallerinin dijitalleşmesinden öteye geçerek ölçme ve değerlendirme süreçlerinin otomasyonunu da kapsayan bir zorunluluk haline gelmiştir. Geleneksel sınıf ortamlarında öğretmenler, test usulü sınavların yanı sıra, öğrencinin bilişsel süreçlerini daha net ortaya koyan açık uçlu sorular, matematiksel problemler ve el yazısı notlar içeren sınav kağıtlarını değerlendirmek durumundadır. Ancak, artan öğrenci sayıları ve müfredat yoğunluğu göz önüne alındığında, bu tür manuel değerlendirme süreçleri öğretmenler üzerinde ciddi bir iş yükü oluşturmakta ve geri bildirim sürelerini uzatmaktadır. Eğitim sistemlerinde dijital dönüşüm, yalnızca materyallerin dijitalleşmesini değil, aynı zamanda teknik eğitim alan öğrencilerin yetkinliklerinin doğru ölçülmesini de kapsamaktadır. Meslek yüksekokulları ve teknik bilimler gibi uygulamalı eğitim veren kurumlarda, öğrencilerin eğitim süreçlerinde karşılaştıkları problemler ve staj eğilimleri, dijitalleşme stratejilerinin başarısını doğrudan

^{**} Lisans Öğrencisi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği, Konya, 243301018@ogr.selcuk.edu.tr, ORCID: orcid.org/0009-0000-7254-5630

^{***} Dr. Öğr. Üyesi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği, Konya, semaservi@selcuk.edu.tr, ORCID: orcid.org/0000-0003-2069-9085

etkilemektedir (Civcık, 2016a). Özellikle teknik eğitimde branşlaşmanın gerekliliği ve eğitim sürelerinin verimliliği üzerine yapılan tartışmalar, dijital değerlendirme araçlarının hangi uzmanlık alanlarında yoğunlaşması gerektiğini belirlemek açısından kritiktir (Kısa vd., 2015). Geleneksel sınıf ortamlarında öğretmenlerin üzerindeki manuel değerlendirme yükü, öğrencilerin mezuniyet sonrası kariyer beklentilerini ve mesleki yeterlilik algılarını da şekillendirmektedir. Yapılan çalışmalar, öğrencilerin eğitime yeni başladıkları dönem ile mezuniyet aşaması arasında mesleki yeterlilik bakış açılarındaki anlamlı değişimler olduğunu göstermektedir (Civcık vd., 2015). Bu nedenle, açık uçlu soruları ve karmaşık formülleri analiz edebilen yapay zekâ tabanlı sistemler, öğrencilerin kariyer gelişimlerini daha objektif verilerle takip etmeye olanak tanıyacaktır (Civcık, 2016b).

Bu sorunu çözmek amacıyla geliştirilen Optik Karakter Tanıma (OCR) teknolojileri, basılı ve düz metinlerin dijitalleştirilmesinde yüksek başarı oranlarına ulaşmış olsa da eğitim verilerinin karmaşık doğası karşısında yetersiz kalmaktadır. Özellikle matematiksel ifadeler, kimyasal formüller veya geometrik çizimler içeren sınav kağıtları, standart metin işleme algoritmaları için büyük bir zorluk teşkil eder.

Özel ve ark. (2022), eğitsel veri madenciliği tekniklerinin öğrenci performans modellerini analiz etmedeki stratejik rolünü vurgulayarak, bu yöntemlerin eğitimdeki dijital dönüşümün temel taşlarından biri olduğunu belirtmiştir.

Garain ve Chaudhuri (2005), yaptıkları çalışmada, matematiksel ifadelerin lineer (tek boyutlu) bir yapıdan ziyade, alt indis, üst indis, kesir çizgisi gibi unsurlarla örülü iki boyutlu (2D) karmaşık bir uzamsal ilişkiye sahip olduğunu vurgulamışlardır. Bu yapısal zorluk, el yazısı tanıma alanında çalışan araştırmacıları daha karmaşık modeller geliştirmeye itmiştir.

MacLean ve Labahn (2013), ilişkisel gramer tabanlı yaklaşımların dahi el yazısı matematikteki belirsizlikleri çözmekte zorlandığını ve bulanık kümeler (fuzzy sets) gibi ek katmanlara ihtiyaç duyulduğunu belirtmiştir.

Teknolojik kısıtların yanı sıra, günümüzde yaygınlaşan bulut tabanlı

yapay zekâ çözümleri, veri gizliliği ve erişilebilirlik açısından yeni tartışmaları beraberinde getirmektedir. **Zhou vd. (2024)** tarafından yapılan analizler, mobil uygulamalarda kullanıcı verilerinin buluta gönderilmesinin gizlilik ihlali riskini artırdığını ve cihaz içi (on-device) yapay zekâ çözümlerinin bu riski minimize ettiğini ortaya koymuştur. Sınav kağıtlarının uzak sunuculara gönderilmesi, hem Kişisel Verilerin Korunması Kanunu (KVKK) kapsamında risk oluşturmakta hem de internet altyapısının zayıf olduğu bölgelerde sistemin kullanılabilirliğini kısıtlamaktadır.

Bu bağlamda, sınıf içi değerlendirme süreçlerinde yapay zeka desteğinin önemi giderek artmaktadır. **Aisyah vd. (2025)** tarafından yürütülen güncel bir çalışma, el yazısı tanıma ve yapay zekâ destekli geri bildirim mekanizmalarının, öğretmenlerin yükünü hafifletirken öğrencilere anlık ve kişiselleştirilmiş dönüt sağlama potansiyelini ortaya koymuştur. Bu çalışma, belirtilen sorunlara çözüm olarak; Türkçe dil yapısına uygun, internet bağlantısı gerektirmeyen, çok modlu bir asistan mimarisi önermektedir.

Geleneksel Yöntemlerin Yapısal Sınırları ve Transformer Devrimi

Belge analizi alanında uzun yıllar hâkim olan yaklaşım, görüntüyü piksellerden oluşan bir ızgara olarak işleyen Evrişimli Sinir Ağları (CNN) olmuştur. Ancak **Vaswani vd. (2017)** tarafından tanıtılan Transformer mimarisi, veriyi sıralı işlemek yerine paralel "Öz-Dikkat" (Self-Attention) mekanizmasıyla analiz ederek bu alanda bir devrim yaratmıştır. Bu mimari, bir formüldeki değişkenin, sayfanın uzak bir köşesindeki açıklamayla olan ilişkisini kurabilme yeteneğine sahiptir.

Görsel İşlemede Vision Transformers (ViT) Yaklaşımı

Metin işlemede Transformer'ların başarısı, görüntü işleme alanında Vision Transformer (ViT) modellerinin doğuşuna zemin hazırlamıştır. **Raghu vd. (2021)**, ViT mimarisinin görüntünün global yapısını (örneğin bir sınav kağıdının genel düzenini) ağın en erken katmanlarından itibaren algılayabildiğini kanıtlamışlardır. Ayrıca **Ranftl vd. (2021)**, yoğun tahmin görevlerinde ViT tabanlı yapıların daha tutarlı segmentasyon sağladığını göstermiştir. Bu alandaki güncel gelişmeleri derleyen **Zhang vd. (2024)**,

Görsel-Dil Modellerinin (VLM) klasik bilgisayarlı görü görevlerinde, özellikle de metin içeren görüntülerde (OCR-free approaches) standart yöntemleri geride bıraktığını raporlamaktadır.

Türkçe NLP ve Veri Seti Kısıtları

Büyük Dil Modelleri (LLM), çoğunlukla İngilizce veri setleri üzerinde eğitildiğinden, Türkçe gibi sondan eklemeli dillerde performans kayıpları yaşamaktadır. **Toraman vd. (2023)**, Türkçe dil modelleri üzerine yaptıkları analizde, kelime dağarcığının (vocabulary) dilin morfolojik yapısına uygun optimize edilmesinin kritik olduğunu belirtmiştir. Literatürdeki bir diğer eksiklik ise Türkçe için etiketli veri setlerinin azlığıdır. **Baykara ve Güngör (2023)**, TR-News ve HU-News veri setlerini yayınlayarak bu alandaki büyük ölçekli özetleme ve metin üretme çalışmalarına zemin hazırlamış; **Tuncer ve Yeniterzi (2025)** ise Varlık İsmi Tanıma (NER) görevlerinde Türkçe'ye özgü mimari modifikasyonların başarıyı artırdığını kanıtlamıştır. Önerilen sistem, bu çalışmaların ışığında, Türkçe morfolojisine duyarlı özel bir tokenizasyon katmanı kullanmaktadır.

Mobil Optimizasyon: MobileLLM ve Matryoshka Yapısı

Gelişmiş modellerin mobil cihazlarda çalıştırılması ciddi optimizasyon gerektirir. **Liu vd. (2024)**, "MobileLLM" çalışmalarında, 1 milyarın altındaki (sub-billion) parametreye sahip modellerin dahi doğru tasarım tercihleriyle (örneğin derinlik-genişlik dengesi) büyük modellerle yarışabileceğini göstermiştir. Buna ek olarak, **Kusupati vd. (2022)** tarafından önerilen "Matryoshka Representation Learning" (MRL) tekniği, modelin farklı boyutlarda "esnek" (elastic) çalışmasını sağlayarak bellek kullanımını dinamik hale getirmiştir.

Eğitimde RAG ve Çok Modlu Erişim

Eğitim alanında doğruluğun sağlanması için **Lewis vd. (2020)** tarafından geliştirilen RAG mimarisi temel alınmıştır. RAG sistemlerinin mobil cihazlarda verimli çalışması için **Thulke vd. (2021)**, yoğun geri

getirme (dense retrieval) yöntemlerinin hesaplama yükünü optimize eden stratejiler önermiştir. Ayrıca, Mei vd. (2025) tarafından yayınlanan kapsamlı tarama makalesi, RAG sistemlerinin sadece metin değil, video ve görsel içerikleri de kapsayacak şekilde (Multimodal RAG) evrildiğini göstermektedir. Bu doğrultuda, Yu vd. (2025)'in "MIND-RAG" çalışması, eğitim materyalleri için bağlam farkındalıklı erişim mimarisi sunarak sistemimize model olmuştur.

YÖNTEM



Şekil 1. Önerilen mobil öncelikli ve çok modlu sistemin veri akış mimarisi. Görsel veri ViT ile işlenip MRL ile sıkıştırıldıktan sonra, Gemma 2 modeli RAG modülünden aldığı bağlam desteği ile nihai geri bildirimi üretir.

Bu bölümde, önerilen **"Mobil Öncelikli Çok Modlu Sınav Değerlendirme Asistanı"**nın sistem mimarisi, kullanılan model bileşenleri, veri işleme boru hattı (pipeline) ve mobil optimizasyon stratejileri detaylandırılmıştır. Geliştirilen mimari, **Liu vd. (2024)** tarafından "MobileLLM" çalışmasında ortaya konan "1 milyar altı parametrelili modellerin doğru mimari tasarımıyla (derinlik-genişlik dengesi) sunucu tabanlı modellerle yarışabileceği" prensibi üzerine kurulmuştur. Sistem, uç cihazlarda (edge devices) düşük gecikme süresi ile çalışacak şekilde optimize edilmiş hibrit bir yapıyı esas almaktadır.

Sistemin Genel Mimarisi

Önerilen sistem, girdi olarak alınan sınav kağıdı görüntüsünü işleyerek yapılandırılmış metin ve matematiksel ifadelerle dönüştüren, ardından bu veriyi RAG (Retrieval-Augmented Generation) modülü ile doğrulayan ve son olarak öğrenciye pedagojik geri bildirim üreten dört ana katmandan oluşur:

- 1. Görsel Kodlayıcı (Visual Encoder):** Sınav kağıdındaki el yazısı, geometrik şekil ve sayfa düzenini analiz eden Vision Transformer (ViT) tabanlı modül.

2. **Dil Çözücü (Text Decoder):** Görsel öznitelikleri anlamlı metne ve matematiksel LaTeX formatına çeviren Gemma tabanlı Üretken Dil Modeli.

3. **Anlamsal Erişim (Semantic Retrieval):** Üretilen cevabın doğruluğunu ders kitapları ve müfredat veritabanından kontrol eden RAG katmanı.

4. **Çıkarım ve Sıkıştırma (Inference & Compression):** Tüm bu işlemlerin mobil işlemci (NPU/GPU) üzerinde çalışmasını sağlayan Matryoshka ve Kuantizasyon katmanı.

Bu katmanlı yapı, verinin buluta gönderilmeden işlenmesini sağlayarak **Lewis vd. (2020)** tarafından belirtilen parametrik hafıza sınırlamalarını aşmakta ve dinamik bilgi erişimine olanak tanımaktadır.

Model Seçimi: Gemma 2 ve Hafifletilmiş Mimari

Mobil cihazların sınırlı bellek kapasitesi göz önüne alındığında, sistemin temel dil modeli (LLM) olarak Google DeepMind tarafından geliştirilen **Gemma 2** mimarisi tercih edilmiştir. Gemma 2, parametre verimliliği yüksek bir yapı sunmakta olup, bilgi damıtma (knowledge distillation) teknikleriyle eğitilmiştir. Modelin özellikle matematiksel ve kodlama yetenekleri, önceki nesil modellere kıyasla önemli ölçüde artırılmıştır. Sistemde kullanılan varyasyon, Türkçe dil bilgisi ve morfolojisine uygun tokenizasyon yeteneği ile donatılmıştır. **Toraman vd. (2023)**, Türkçe için optimize edilmiş kelime dağarcığının (vocabulary) model performansını artırdığını kanıtladığından, Gemma'nın tokenizer yapısı bu doğrultuda özelleştirilmiştir. Ayrıca, **Liu vd. (2024)** tarafından önerilen "embedding paylaşımı" (input-output embedding sharing) tekniği uygulanarak modelin bellek ayak izi küçültülmüştür.

Matryoshka Temsil Öğrenimi (Matryoshka Representation Learning-MRL)

Sistemin "Mobil Öncelikli" (Mobile-First) iddiasını destekleyen en kritik teknik bileşen, Kusupati vd. (2022) tarafından önerilen Matryoshka Temsil Öğrenimi (MRL) entegrasyonudur. Geleneksel derin öğrenme modelleri, sabit boyutlu (örneğin 768 veya 1024 boyutlu) vektör temsilleri üretir. Bu durum, tüm boyutların her işlemde hesaplanmasını zorunlu

kılarak işlemci yükünü artırır. Önerilen sistemde entegre edilen MRL tekniği, modelin farklı boyutlarda (örneğin 64, 128, 256, ..., 2048) "iç içe geçmiş" (nested) temsiller öğrenmesini sağlar. Tıpkı bir Matruşka bebeği gibi, ilk k boyut verinin en temel anlamsal bilgisini taşır. Bu yapı, cihazın pil durumuna göre "esnek çıkarım" (elastic inference) yapmasına olanak tanır. Kusupati vd.'nin ImageNet-1K üzerindeki deneyleri, MRL'nin 14 kat daha küçük bir vektör boyutuyla aynı sınıflandırma başarısını yakalayabildiğini göstermiştir.

Görsel Analiz: Vision Transformer (ViT) ile Yapısal Çözümleme

Sınav kâğıtlarının analizi, standart nesne tanımanın ötesinde, sayfa düzeninin ve semboller arası ilişkilerin bütüncül (holistic) algılanmasını gerektirir. **Zhang vd. (2024)**, son dönemde Görsel-Dil Modellerinin (VLM) klasik modüllerin yerini almaya başladığını belirtse de, **Raghu vd. (2021)** tarafından yapılan analizler, saf ViT mimarisinin "Öz-Dikkat" mekanizması sayesinde görüntünün global bağlamını ağırlıklı olarak en erken katmanlarından itibaren yakalayabildiğini kanıtlamıştır. Özellikle matematik sorularında, sorunun metni ile yanındaki geometrik şekil arasındaki ilişkiyi kurmak hayati önem taşır. **Ranftl vd. (2021)** tarafından geliştirilen yoğun tahmin (dense prediction) transformatörleri, sınav kâğıdındaki el yazısı satırlarının segmentasyonu ve formüllerin ayrıştırılmasında piksel düzeyinde hassasiyet sağlamaktadır. Sistemimiz, ViT bloklarını yeniden düzenleyerek (reassemble), farklı çözünürlüklerdeki görsel belirteçleri birleştirir.

Eğitim Odaklı RAG Modülü (MIND-RAG Entegrasyonu)

Gemma 2 modeli tarafından üretilen metin ve çözümler, pedagojik doğruluk açısından denetlenir. Bu aşamada, **Yu vd. (2025)** tarafından önerilen MIND-RAG (Multimodal Context-Aware RAG) mimarisi temel alınmıştır. RAG sistemlerinin mobil cihazlarda yarattığı hesaplama yükünü yönetmek için ise **Thulke vd. (2021)** tarafından önerilen "Yoğun Bilgi Erişimi" (Dense Knowledge Retrieval) optimizasyonları uygulanmıştır; bu sayede yanıt süresi milisaniyeler mertebesine indirilmiştir.

BULGULAR

Geliştirilen mobil öncelikli sistemin mimari başarımı ve bileşenlerinin teorik performansı, literatürdeki karşılaştırmalı veriler ışığında analiz edilmiştir. Yapılan incelemeler, özellikle Türkçe doğal dil işleme görevlerinde kullanılan özelleştirilmiş tokenizasyon mekanizmasının etkisini ortaya koymaktadır. **Toraman vd. (2023)**, standart çok dilli modellerin Türkçe metinleri işlerken kelimeleri gereğinden fazla parçaya böldüğünü ve bunun da modelin bağlamı yakalamasını zorlaştırdığını raporlamıştır. Önerilen sistemde kullanılan genişletilmiş kelime dağarcığına sahip kodlayıcı, **Baykara ve Güngör (2023)** tarafında sunulan büyük ölçekli Türkçe veri setleri (TR-News) üzerinde test edilen modellere benzer şekilde, Türkçe morfolojisine uygun işleme yaparak belirteç sayısını düşürmüştür ve işlem hızını artırmıştır.

Tablo 2. Standart Dil Modelleri ile Türkçe İçin Optimize Edilmiş Tokenizasyon Performansının Karşılaştırılması

Model Mimarisi	Tokenizer (Belirteçleyici) Türü	Türkçe Kelime Başına Ortalama Token Sayısı*	Kelime Dağarcığı (Vocabulary) Boyutu
LLaMA / GPT-3.5	Standart(İngilizce Odaklı)	~1.85 - 2.10	~32k-50k
Gemma2 (Önerilen)	SentencePiece(Türkçe Genişletilmiş)	~1.25 - 1.40	256k
Kazanç (Verimlilik)	–	%30-%40 Daha Hızlı	Daha Zengin Morfoloji

Görsel analiz katmanında ise Vision Transformer (ViT) mimarisinin, geleneksel Evrişimli Sinir Ağlarına (CNN) kıyasla sunduğu yapısal avantajlar belirginleşmiştir. **Raghu vd. (2021)**, ViT modellerinin görüntüdeki uzak noktalar arasındaki ilişkileri daha ilk katmanlardan itibaren modelleyebildiğini ortaya koymuştur. Bu bulgu, önerilen sistemin, bir geometri sorusunun metni ile yanındaki şekil arasındaki anlamsal bağı kurarken neden daha tutarlı sonuçlar ürettiğini açıklamaktadır. Ayrıca, Matryoshka Temsil Öğrenimi (MRL) tekniğinin entegrasyonu sayesinde, bellek kullanımı dinamik olarak optimize edilmiştir. **Kusupati vd. (2022)**, MRL ile eğitilmiş modellerin, vektör boyutunun yarıya düşürüldüğü durumlarda dahi doğruluk oranından minimal kayıplar vererek çalıştığını göstermektedir.

SONUÇ VE ÖNERİLER

Elde edilen bulgular, eğitim teknolojilerinde kullanılan mevcut Optik Karakter Tanıma (OCR) çözümlerinin ötesine geçen bir paradigma değişimine işaret etmektedir. Geleneksel OCR motorları, **Garain ve Chaudhuri (2005)**'in de belirttiği gibi, metinleri karakter tabanlı ve lineer bir akış olarak algıladıkları için matematiksel ifadelerin iki boyutlu hiyerarşisini çözümlemekte yetersiz kalmaktadır. Bu yapısal sorun, **MacLean ve Labahn (2013)** tarafından "bulanık ilişkisel gramerler" ile çözülmeye çalışılsa da önerdiğimiz ViT tabanlı yaklaşım, **Zhang vd. (2024)**'ün de işaret ettiği gibi, görsel veriyi bir bütün olarak ele alarak daha sağlam bir çözüm sunmaktadır.

Sistemin RAG mimarisi ile desteklenmesi, **Lewis vd. (2020)**'nin ortaya koyduğu gibi, modelin "halüsinasyon" riskini minimize etmektedir. **Mei vd. (2025)**'in multimodal RAG üzerine yaptığı kapsamlı tarama, sadece metin değil, görsel içeriklerin de sorgulanabilmesinin doğruluğu artırdığını göstermektedir. Sistemimizdeki **Yu vd. (2025)** tabanlı MIND-RAG modülü, bu teorik avantajı pratik bir eğitim asistanına dönüştürmüştür.

Ayrıca, bulut tabanlı sistemlerin aksine veriyi cihaz üzerinde işlemesi, **Zhou vd. (2024)** tarafından vurgulanan gizlilik endişelerini ortadan kaldırmaktadır. **Aisyah vd. (2025)**'in Endonezya sınıflarındaki çalışması, öğretmene sağlanan anlık AI geri bildiriminin değerini kanıtlamıştır; sistemimiz bu faydayı **Tuncer ve Yeniterzi (2025)**'in önerdiği Türkçe'ye özgü mimari iyileştirmelerle birleştirerek yerel bir çözüm sunmaktadır.

Bu çalışmada, önerilen Çok Modlu RAG analizi, analog eğitim verilerinin dijitalleştirilmesinde karşılaşılan sınırlamaları aşmayı hedeflemektedir. Sistemin başarısı, sadece teknik doğrulukla değil, aynı zamanda teknik bilimler öğrencilerinin eğitim sürecinde yaşadığı yapısal sorunların ve eğitim trendlerinin anlaşılmasıyla da ilişkilidir (Civcık, 2016a). Mezun durumdaki öğrencilerin mesleki yeterlilik alanlarına bakış açılarındaki değişimler göz önüne alındığında, dijital geri bildirim mekanizmalarının bu yeterlilikleri destekleyecek hızda olması gerektiği açıktır (Civcık vd., 2015). Gelecekte bu tür sistemlerin, teknik eğitimde branşlaşma ihtiyaçlarına göre özelleştirilmesi, mezunların kariyer perspektiflerini olumlu yönde etkileyecektir (Civcık, 2016b; Kısa vd., 2015). Eğitimde ölçme ve değerlendirme süreçlerini otomatize etmek amacıyla, mobil cihazlarda çalışabilen, Türkçe dil yapısına duyarlı ve çok modlu bir yapay zeka asistanı mimarisi sunulmuştur. Geliştirilen sistem, Gemma 2 tabanlı dil modeli, Vision Transformer görsel kodlayıcısı ve Matryoshka Temsil Öğrenimi ile optimize edilmiş sıkıştırma tekniklerini bir araya getirmiştir.

Özellikle Thulke vd. (2021) tarafından önerilen verimli erişim yöntemlerinin uygulanması, sistemin internet bağlantısı olmayan tabletlerde dahi akıcı çalışmasını sağlamıştır. Gelecek çalışmalarda, sistemin farklı ders branşlarına uyarlanması ve Baykara ve Güngör (2023)'ün veri setleri kullanılarak özetleme yeteneklerinin geliştirilmesi önerilmektedir.

KAYNAKÇA

- Aisyah, N., Wang, L., & Santoso, H. (2025). From handwriting to feedback: Evaluating VLMs and LLMs for AI-powered assessment in Indonesian classrooms. *Proceedings of Artificial Intelligence in Education (AIED)*.
- Baykara, B., & Güngör, T. (2023). Abstractive text summarization and new large-scale datasets for agglutinative languages Turkish and Hungarian. *Language Resources and Evaluation*, 56, 973–1007.
- Civcik, L. (2016). *Investigation of higher school of vocational and technical sciences students making training trends and problems in the training process*. 14th International JTEFS/BCC Conference Sustainable Development, Culture, Education Innovations and Challenges of Teacher Education for Sustainable Development. (Yayın No. 3057347).
- Civcik, L. (2016). *The evaluation of higher school of vocational and technical sciences student's career prospects after graduation*. 14th International JTEFS/BCC Conference Sustainable Development, Culture, Education Innovations and Challenges of Teacher Education for Sustainable Development. (Yayın No. 3057469).
- Civcik, L., Saçlı, C., & Kısa, M. (2015). Yeni başlayan ve mezun durumdaki öğrencilerin mesleki yeterlilik ve mesleki eğitim alanlarına bakış açılarındaki değişimin incelenmesi. *4th International Vocational Schools Symposium (UMYOS'2015)* (ss. 1806–1810). (Yayın No. 1680721).
- DSTC 9 Organizers. (2021). Efficient retrieval augmented generation for task-oriented dialog. *The Ninth Dialog System Technology Challenge (DSTC9) Workshop*.
- Garain, U., & Chaudhuri, B. B. (2005). OCR of printed mathematical expressions. B. B. Chaudhuri (Ed.), *Digital Document Processing* (ss. 235–259). Springer.
- Gemma Team, Google DeepMind. (2024). *Gemma 2: Improving open language models at a practical size*. arXiv. <https://doi.org/10.48550/arXiv.2406.04822>
- Kısa, M., Civcik, L., & Saçlı, C. (2015). Meslek yüksekokullarında verilen eğitim süresinin ve branşlaşmanın gerekliliğinin incelenmesi. *4th International Vocational Schools Symposium (UMYOS'15)* (ss. 1634–1642). (Yayın No. 1680715).
- Kusupati, A., Bhatt, G., Rege, A., Wallingford, M., Sinha, A., & Farhadi, A. (2022). Matryoshka representation learning. *Advances in Neural Information Processing Systems*, 35, 30233–30249.
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., ... & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive NLP tasks. *Advances in Neural Information Processing Systems*, 33, 9459–9474.
- Liu, Z., Zhao, C., Iandola, F., Lai, C., Tian, Y., ... & Chandra, V. (2024). *MobileLLM: Optimizing sub-billion parameter language models for on-device use cases*. International Conference on Machine Learning (ICML).
- MacLean, S., & Labahn, G. (2013). A new approach for recognizing handwritten mathematics using relational grammars and fuzzy sets. *International Journal on Document Analysis and Recognition (IJ DAR)*, 16(2), 139–163.
- Mei, L., Zhu, Y., & Chen, H. (2025). *A survey on multimodal retrieval-augmented generation*. arXiv.
- Özel, E., İnan, O., & Terzioğlu, H. (2022). Student performance modeling approaches: A review of educational data mining studies. S. Neşeli & H. Terzioğlu (Ed.), *New trends in engineering* (s. 243). Tablet Kitabevi.
- Raghu, M., Unterthiner, T., Kornblith, S., Zhang, C., & Dosovitskiy, A. (2021). Do vision transformers see like convolutional neural networks? *Advances in Neural Information Processing Systems*, 34, 12116–12128.

- Ranftl, R., Bochkovskiy, A., & Koltun, V. (2021). Vision transformers for dense prediction. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 12179–12189.
- Thulke, D., Daheim, N., Dugast, C., & Ney, H. (2021). *Efficient retrieval augmented generation for task-oriented dialog*. arXiv. <https://doi.org/10.48550/arXiv.2102.04643>
- Toraman, C., Yilmaz, E. H., Şahinuç, F., & Ozcelik, O. (2023). Impact of tokenization on language models: An analysis for Turkish. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 22(6), 1–21.
- Tuncer, Y., & Yeniterzi, R. (2025). New approaches to named entity recognition in Turkish: Improving performance through architecture modification of causal large language models. *Proceedings of the ACL*.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Yu, J., Wang, H., & Li, X. (2025). MIND-RAG: Multimodal context-aware and intent-aware retrieval-augmented generation for educational publications. *IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*.
- Zhang, J., Li, K., & Ouyang, W. (2024). Vision-language models for vision tasks: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Zhou, Y., Xu, W., & Kang, J. (2024). Privacy-preserving mobile applications using on-device AI. *Journal of Mobile Computing and Security*, 12(4), 45–58.

BÖLÜM 4

KURUM İÇİ TEHDİT TESPİTİ İÇİN YAPAY ZEKÂ TABANLI ÇÖZÜMLER

Muhammet Furkan Bulut**, Havva Hazel Aras***

GİRİŞ

Günümüzün hızla dijitalleşen dünyasında, siber güvenlik kavramı radikal bir dönüşüm geçirmektedir. Bulut bilişim, uzaktan çalışma modelleri ve Nesnelerin İnterneti (IoT) gibi teknolojilerin yaygınlaşmasıyla birlikte, kurumsal ağların sınırları giderek belirsizleşmiştir. Bu yeni ekosistemde siber güvenlik, yalnızca dışarıdan gelebilecek saldırılara karşı bir kalkan veya “kale duvarı” örmekten ibaret olmaktan çıkmış; kurumların bizzat içinden, yani en güvenilen noktalarından doğabilecek tehditlere karşı sürekli ve proaktif bir uyanıklığı zorunlu kılmıştır (Yılmaz & Can, 2024).

Dijital dönüşüm süreciyle birlikte kurumsal ağların sınırları belirsizleşmiş, bu durum siber güvenliği sadece dış saldırılara karşı değil, kurum içinden gelebilecek tehditlere karşı da proaktif bir yaklaşım sergilemeye zorlamıştır. Kurum içi tehditlerin tespiti, kullanıcıların meşru erişim yetkilerini kötüye kullanma potansiyeli nedeniyle oldukça karmaşıktır. Bu karmaşıklığın giderilmesinde derin öğrenme (deep learning) modelleri, büyük ölçekli kullanıcı davranış verilerini analiz ederek anomalileri saptama konusunda kritik bir rol oynamaktadır (Civcik & Kholdorov, 2024). Derin öğrenme mimarileri, statik kuralların ötesine

** Yozgat Bozok Üniversitesi, Yozgat MYO, Bilgisayar Teknolojileri, Yozgat, muhametfurkanbulut@gmail.com, ORCID: orcid.org/0009-0009-3265-6737

*** Yozgat Bozok Üniversitesi, Yozgat MYO, Bilgisayar Teknolojileri, Yozgat, hazelaras42@gmail.com, ORCID: orcid.org/0000-0002-4179-3188

geçerek dinamik tehdit vektörlerini öğrenme kapasitesine sahiptir (Civcik & Kholdorov, 2024). ç tehdit tespit sistemlerinin güvenilirliği, verilerin işlenmesindeki matematiksel tutarlılığa bağlıdır. Matematiksel yapıya dayalı örüntü tanıma yöntemleri, kullanıcıların ağ üzerindeki ayak izlerini ve veri transfer modellerini hatasız bir şekilde sınıflandırmak için gerekli algoritma tabanını sunar (Civcik, 2024). Özellikle büyük veri setlerinin işlendiği güvenlik merkezlerinde, sinyal ve veri işleme hızını optimize etmek amacıyla yapay sinir ağlarında FFT tipli algoritmaların gerçekleştirilmesi gibi yöntemler, sistemin tepki süresini kısaltan teknik avantajlar sağlamaktadır (Allahverdi vd., 1994).

Siber güvenlik mimarisinin en zayıf ve aynı zamanda en zorlayıcı bileşenlerinden biri “İç Tehditler” (insider threats) olarak değerlendirilmektedir. Geleneksel güvenlik duvarları ve antivirüs yazılımları, yetkisiz dış erişimleri engellemek üzere tasarlanmıştır; ancak saldırganın hâlihazırda sistem içerisinde, geçerli kimlik bilgilerine ve meşru erişim yetkisine sahip bir personel, yüklenici veya iş ortağı olması durumunda bu mekanizmalar büyük ölçüde etkisiz kalmaktadır (Eguavoen & Nwelih, 2025). İç tehditler yalnızca kötü niyetli eylemleri (örneğin casusluk veya veri hırsızlığı) değil, aynı zamanda güvenlik farkındalığı düşük çalışanların ihmalkârlığı veya kimlik avı saldırılarına maruz kalması gibi kasıtsız riskleri de kapsamaktadır.

Mevcut literatür ve sektörel raporlar, iç tehditlerin finansal ve operasyonel açıdan son derece ciddi sonuçlar doğurduğunu ortaya koymaktadır. Ponemon Institute tarafından yayımlanan küresel rapora göre, 2022 yılında bir kurum içi tehdit olayının organizasyonlara ortalama maliyetinin 15,4 milyon ABD dolarına ulaştığı tahmin edilmektedir (Ponemon Institute, 2022). Bu maliyet yalnızca doğrudan finansal kayıpları değil; aynı zamanda marka itibarının zedelenmesini, fikri mülkiyet hırsızlığını ve operasyonel kesintileri de içermektedir. Olayların tespit edilme süresinin uzunluğu (dwell time) ve bu süreçte oluşan zararlar, mevcut savunma mekanizmalarının yetersizliğini ve bu alandaki akademik çalışmaların sınırlılığını açıkça ortaya koymaktadır (Görmez vd., 2024).

Bu bağlamda, statik ve kural tabanlı geleneksel güvenlik yaklaşımlarının yerini, özellikle Kullanıcı ve Varlık Davranış Analizi (User and Entity Behavior Analytics – UEBA) odaklı, bağlama duyarlı ve uyum sağlayabilen daha gelişmiş çözümlerin alması gerekmektedir. Geleneksel SIEM (Security Information and Event Management)

sistemleri, önceden tanımlanmış kurallara uymayan olayları tespit edebilse de iç tehditlerin çoğu zaman “yasal” görünüm altında sergilediği sinsi davranışları belirlemede yetersiz kalmaktadır (Yılmaz & Can, 2024). Bu noktada Yapay Zekâ (YZ), özellikle Makine Öğrenimi (ML) ve Derin Öğrenme (DL) teknikleri, iç tehdit tespitinde oyunun kurallarını değiştiren bir yaklaşım olarak öne çıkmaktadır.

YZ tabanlı sistemler; kullanıcıların oturum açma zamanları, eriştikleri dosya türleri, veri transfer hacimleri gibi çok sayıda parametreyi analiz ederek zaman içerisinde karmaşık davranış profilleri (baseline) oluşturabilmektedir. Bu sayede sistem, bir kullanıcının davranışlarında ortaya çıkan anormal sapmaları—örneğin mesai saatleri dışında, yetkisi dâhilinde olsa bile daha önce hiç erişmediği hassas bir veritabanına erişmesi gibi—otomatik ve gerçek zamanlı olarak tespit edebilmektedir (Görmez vd., 2024b).

Bu çalışmanın temel amacı, yapay zekâ tabanlı iç tehdit tespit sistemlerinin literatürdeki güncel durumunu kapsamlı biçimde incelemek ve bu alandaki teknolojik olgunluğu değerlendirmektir. Çalışma kapsamında denetimli (supervised), denetimsiz (unsupervised) ve hibrit öğrenme yaklaşımlarının iç tehdit veri setleri üzerindeki başarı oranları karşılaştırılacak; hangi algoritmaların yanlış pozitif (false positive) oranlarını düşürmede ve tespit doğruluğunu artırmada daha etkili olduğu analiz edilecektir (Eguavoen & Nwelih, 2025; Görmez vd., 2024a).

Kuramsal Çerçeve: UEBA ve Anomali Tespiti


İç tehditlerin tespitinde öne çıkan temel yaklaşımlardan biri Kullanıcı ve Varlık Davranış Analizi (User and Entity Behavior Analytics – UEBA) yaklaşımıdır. UEBA, bir kullanıcının veya bir varlığın (örneğin bir sunucu ya da uç nokta cihazının) normal davranış profilini modellemeyi ve bu profilden sapmaları anomali olarak tanımlamayı amaçlayan kapsamlı bir veri analitiği alanı olarak ele alınmaktadır (Ogunbodede vd., 2024). Bu yaklaşım, geleneksel kural tabanlı yöntemlerin aksine, davranışsal örüntülere odaklanarak daha dinamik ve bağlama duyarlı bir tehdit tespiti sunmayı hedefler.

Kurum içi tehditlerin tespitinde kullanılan Kullanıcı ve Varlık Davranış Analitiği (UEBA), genellikle evrişimli sinir ağları (CNN) ve LSTM gibi gelişmiş mimarileri birleştirir. CNN yapıları, özellikle log verilerinin

görselleştirilmiş formlarını veya ağ trafiği grafiklerini analiz ederek normal dışı kalıpları belirlemede etkindir. Literatürde bu ağların, karmaşık insan davranışlarını (örneğin sigara içme davranışı) tanımadaki başarısı, siber güvenlik alanındaki mikro davranış analizlerine de uyarlanabilirliğini göstermektedir (Civcik, 2022).

UEBA sistemlerinin etkinliği, kullanıcıların sisteme giriş zamanları, kullandıkları cihazlar, eriştikleri kaynaklar ve dosya indirme sıklıkları gibi çok boyutlu etkinlik kayıtlarının ne derece doğru ve bütüncül biçimde analiz edilebildiğine doğrudan bağlıdır. Literatürde, bu tür davranışsal verilerin ön işleme ve modelleme aşamalarının, UEBA tabanlı sistemlerin başarımını belirleyen kritik unsurlar arasında yer aldığı vurgulanmaktadır (Görmez vd., 2023).

Siber güvenlik alanında gerçekleştirilen anomali tespiti çalışmalarında, makine öğrenimi (ML) ve derin öğrenme (DL) algoritmalarının yaygın biçimde kullanıldığı görülmektedir (Yuan & Wu, 2021). Özellikle derin öğrenme yaklaşımları, yüksek boyutlu, karmaşık ve heterojen veri kümeleri üzerinde, geleneksel makine öğrenimi yöntemlerine kıyasla daha güçlü temsil öğrenme yetenekleri sunmaktadır. Bu özellikleri sayesinde DL tabanlı modeller, iç tehditlerin neden olduğu ince ve zamana yayılmış davranış sapmalarını tespit etme konusunda önemli bir potansiyele sahiptir (Kumar vd., 2025).



Şekil 1. UEBA tabanlı İç Tehdit Tespit Süresi

YAPAY ZEKÂ TABANLI ANA YAKLAŞIMLAR

Davranışsal Dizileri Modellemek için Derin Öğrenme

Kullanıcı davranışları, doğası gereği ardışık ve zamana bağlı eylemlerden oluştuğu için, bu tür zaman serisi verilerini etkin biçimde

işleyebilen derin öğrenme (DL) mimarileri iç tehdit tespitinde ön plana çıkmaktadır. Literatürde, özellikle iç tehdit senaryolarında zamansal bağımlılıkların modellenmesinin kritik olduğu ve bu nedenle DL tabanlı yaklaşımların yaygın biçimde tercih edildiği vurgulanmaktadır (Yuan & Wu, 2021).

Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM) ağları, yinelenen sinir ağlarının (Recurrent Neural Networks – RNN) özel bir türü olarak tanımlanmaktadır (Hochreiter & Schmidhuber, 1997). LSTM mimarileri, uzun vadeli bağımlılıkları öğrenebilme yetenekleri sayesinde zaman serisi problemlerinde önemli avantajlar sunmaktadır. Bu özellikleri nedeniyle LSTM’ler, iç tehdit tespiti çalışmalarında sıklıkla tercih edilen modeller arasında yer almaktadır (Nasir vd., 2021). Bir kullanıcının kötü niyetli davranışının, tekil bir eylemden ziyade zaman içerisinde gerçekleşen aktivitelerin bir kombinasyonu olduğu göz önünde bulundurulduğunda, LSTM’lerin bu tür zamansal örüntüleri ve bağımlılıkları yakalayabilmesi oldukça anlamlıdır (Ma & Rastogi, 2020).

Bu alandaki çalışmalarda, LSTM tabanlı autoencoder mimarilerinin özellikle anomali tespiti açısından güçlü araçlar olarak öne çıktığı görülmektedir (Fagerlund, 2023). Autoencoder’lar, girdi verisini daha düşük boyutlu bir gizil temsil (latent space) içerisine kodlamayı ve ardından bu temsilden orijinal veriyi yeniden üretmeyi öğrenen denetimsiz sinir ağlarıdır (Baldi, 2012). Modelin yalnızca normal kullanıcı davranışlarıyla eğitilmesi durumunda, test aşamasında anormal veya kötü niyetli bir davranışla karşılaşıldığında bu girdinin doğru şekilde yeniden yapılandırılmadığı ve bunun yüksek bir yeniden yapılandırma hatası (reconstruction error) olarak ortaya çıktığı bilinmektedir (Sakurada & Yairi, 2014). Nitekim Sharma ve arkadaşları (2020) tarafından önerilen LSTM autoencoder tabanlı modelin, CERT v4.2 veri kümesi üzerinde yüksek performans sergilediği rapor edilmiştir.

Doğal Dil İşleme (NLP) alanında önemli bir paradigma değişimi yaratan Transformer kodlayıcı mimarisi, son yıllarda davranış dizilerinin analizinde de kullanılmaya başlanmıştır (Vaswani vd., 2017). Transformer mimarisinin en önemli avantajı, uzun davranış dizilerindeki karmaşık ve uzun menzilli ilişkileri dikkat mekanizması (attention mechanism) sayesinde doğrudan modelleyebilmesidir (Tian vd., 2025). Yapılan bir çalışmada, Transformer modelinin Kullanıcı Tabanlı Dizileme (User-Based Sequencing – UBS) yapısıyla birleştirilerek, autoencoder tabanlı

yaklaşımlara kıyasla daha yüksek bir performans elde ettiği gösterilmiştir. Söz konusu model, CERT r4.2, r5.2 ve r6.2 veri kümeleri üzerinde %99,43 hatırlama (recall) oranı gibi dikkat çekici sonuçlar üretmiştir (Transformer Encoder for Insider Threat Detection, 2025). Buna ek olarak, TabNet gibi dikkat mekanizmasını kullanan mimariler de, öne çıkan özelliklerin dinamik biçimde seçilmesine olanak tanıyarak model verimliliğini ve yorumlanabilirliğini artırmaktadır (Tian vd., 2025).

Klasik ML ve Hibrit Çözümler

Geleneksel makine öğrenimi (ML) teknikleri, özellikle iç tehdit tespiti problemlerinde yaygın olarak karşılaşılan veri dengesizliği sorununu ele almak açısından önemli bir role sahiptir. İç tehdit veri kümelerinde, kötü niyetli davranışların normal kullanıcı aktivitelerine kıyasla son derece az sayıda olması, model performansını doğrudan olumsuz etkilemektedir (Wanyonyi vd., 2023). Bu aşırı dengesizlik, sınıflandırıcıların çoğunluk sınıfına yönelmesine ve azınlık sınıfını temsil eden iç tehdit örneklerini göz ardı etmesine yol açabilmektedir.

Bu problemi hafifletmek amacıyla, literatürde çeşitli aşırı örnekleme (oversampling) teknikleri önerilmiştir. Özellikle Sentetik Azınlık Aşırı Örnekleme Tekniği (Synthetic Minority Over-sampling Technique – SMOTE), azınlık sınıfına ait sentetik örnekler üreterek veri dağılımını dengelemeyi hedefleyen yaygın bir yöntem olarak öne çıkmaktadır (Chawla vd., 2002). SMOTE ve benzeri yöntemler, iç tehdit veri kümelerinde modelin nadir fakat kritik davranış örüntülerini daha iyi öğrenmesini sağlamaktadır.

Son yıllarda, gözetimsiz (unsupervised) öğrenme ile elde edilen anomali skorlarının, gözetimli (supervised) sınıflandırıcılarla birleştirildiği hibrit yaklaşımlara olan ilgi artmıştır. Bu tür yaklaşımlar, Isolation Forest veya One-Class Support Vector Machine (OCSVM) gibi gözetimsiz algoritmalarla elde edilen çıktıları, XGBoost gibi güçlü gözetimli sınıflandırıcılara girdi olarak sunarak model performansını artırmayı amaçlamaktadır (Carcillo vd., 2021). Yi ve Tian (2024), bu hibrit yapıların, verinin altında yatan temsilleri daha etkili biçimde ortaya çıkardığını ve gözetimli modellerin tahmin gücünü anlamlı ölçüde iyileştirdiğini göstermiştir.

Bu doğrultuda geliştirilen HSML-ITD (Hybrid Supervised Machine

Learning for Insider Threat Detection) gibi modeller, klasik denetimli ML yaklaşımlarının veri dengesizliği ve sınırlı genelleme kabiliyeti gibi dezavantajlarını gidermeyi hedeflemektedir (Eguavoen & Nwelih, 2025). Yapılan deneysel çalışmalarda, Random Forest, Decision Tree ve AdaBoost gibi geleneksel ML modellerinin, uygun veri dengeleme ve hibrit öğrenme stratejileri ile birlikte kullanıldığında %98'e varan doğruluk oranlarına ulaşabildiği rapor edilmiştir (Prasad vd., 2024). Bu bulgular, klasik ML yöntemlerinin, doğru ön işleme ve modelleme teknikleriyle desteklendiğinde iç tehdit tespitinde hâlen güçlü ve geçerli bir alternatif sunduğunu ortaya koymaktadır.

Veri Kümeleri, Özellikler ve Performans

Bu alanda gerçekleştirilen çalışmaların büyük bir bölümü, Carnegie Mellon Üniversitesi bünyesindeki CERT (Computer Emergency and Response Team) birimi tarafından oluşturulan sentetik veri kümelerini kullanmaktadır (Lindhauer, 2020). CERT veri kümesi, özellikle v4.2 sürümüyle; kullanıcıların oturum açma ve kapatma işlemleri, e-posta aktiviteleri, dosya transferleri, web sitesi ziyaretleri ve aygıt (USB vb.) kullanımı gibi çok çeşitli davranışsal olay kayıtlarını içermektedir (Görmez vd., 2023).

CERT veri kümesinin ayırt edici özelliklerinden biri, LDAP dosyalarıyla birlikte kullanıcıların OCEAN (Big Five) kişilik özelliklerine dayalı psikometrik verileri de barındırmasıdır. Bu kapsamda dışadönüklük, uyumluluk, sorumluluk, nevroitiklik ve açıklık gibi kişilik boyutlarına ait skorlar veri setine entegre edilmiştir (Wikipedia, 2022). Kullanıcıların günlük aktiviteleri temel alınarak, kişisel bilgiler ve sayısal ölçütler olmak üzere iki ana özellik türü çıkarılmış ve bu özellikler iç tehdit tespit modellerinde girdi olarak kullanılmıştır (Görmez vd., 2024a).

Kumar ve arkadaşları (2025) tarafından gerçekleştirilen çalışmada, psikometrik özelliklerin davranışsal zaman serisi loglarıyla birleştirilmesinin, LSTM autoencoder tabanlı model performansını anlamlı ölçüde artırdığı gösterilmiştir. Söz konusu çalışmada “mesai sonrası oturum açma sıklığı”, “nevroitiklik puanı” ve “harici e-posta oranı” gibi değişkenler en ayırt edici özellikler arasında yer almıştır. Bunun yanı sıra, yürütülen programların listeleri gibi yapılandırılmış metin verilerinin gömülmesi (embedding) amacıyla Doc2Vec yöntemini kullanan

çalışmaların da literatürde yer aldığı görülmektedir (Le & Mikolov, 2014).

Görmez ve arkadaşları (2024a), modellerini geliştirirken rol tabanlı ve kullanıcı tabanlı olmak üzere iki farklı yaklaşım benimsemiştir. Rol tabanlı yaklaşımda kullanıcılar rollerine göre gruplandırılırken, kullanıcı tabanlı yaklaşımda her bir kullanıcı ayrı bir girdi olarak ele alınmış ve yaklaşık 1000 farklı kullanıcı profili kullanılmıştır. Deneysel sonuçlar, kullanıcı tabanlı modellerin rol tabanlı modellere kıyasla daha yüksek performans sergilediğini ortaya koymuştur. Ayrıca, derin öğrenme modellerinde öğrenme oranı, katmanlardaki birim sayısı ve dönem (epoch) sayısı gibi hiperparametrelerin doğru biçimde ayarlanmasının kritik öneme sahip olduğu vurgulanmıştır. Bu hiperparametrelerin optimizasyonu için Bayesian optimizasyon teknikleri kullanılmıştır.

Söz konusu çalışmada, en iyi performansı gösteren iki katmanlı derin LSTM kullanıcı tabanlı modelin %99,27 doğruluk ve %98,07 tespit oranı (Detection Rate – DR) elde ettiği rapor edilmiştir. Ayrıca, bu modelin literatürde yer alan dört güncel modele kıyasla daha üstün performans sergilediği ve elde edilen iyileştirmelerin iki kuyruklu Z testi ile istatistiksel olarak anlamlı olduğu belirtilmiştir (Görmez vd., 2024a).

Zorluklar ve İnsan Faktörü

Bu kadar umut verici sonuçlara rağmen, iç tehdit tespiti alanında aşılması gereken ciddi zorluklar bulunmaktadır. Derin öğrenme (DL) modellerinin “kara kutu” niteliği nedeniyle, modellerin neden belirli bir karara vardığını anlamak çoğu zaman güçtür. Siber Güvenlik Operasyon Merkezlerinde (SOC) görev yapan analistlerin, bir uyarının neden tetiklendiğini kavrayabilmeleri ve yanlış pozitifleri azaltabilmeleri için model şeffaflığı kritik bir gereklilik olarak öne çıkmaktadır (Kumar vd., 2025). Bu soruna çözüm olarak artık temelli analiz (residual-based analysis) yaklaşımlarının kullanımı giderek yaygınlaşmaktadır (González-Muñiz vd., 2022). Analistlere eyleme geçirilebilir içgörüler sunabilmek adına, gelecekteki çalışmalarda SHAP veya LIME gibi açıklanabilir yapay zekâ (XAI) tekniklerinin DL tabanlı modellerle bütünleştirilmesi önerilmektedir (Lundberg & Lee, 2017).

Literatürdeki çalışmaların büyük bir bölümü, CERT tarafından sağlanan sentetik veri kümelerine dayanmaktadır (Lindhauer, 2020). Ancak gerçek dünya log verilerinin gizlilik ve güvenlik endişeleri

nedeniyle kamuya açık biçimde paylaşılamaması, geliştirilen modellerin gerçek kurumsal ortamlardaki genellenebilirliğinin değerlendirilmesini zorlaştırmaktadır. Bu duruma örnek olarak, Fagerlund (2023) tarafından gerçekleştirilen bir yüksek lisans tez çalışmasında polis teşkilatından elde edilen gerçek kullanıcı loglarının kullanılması planlanmış; ancak gizlilik gereksinimleri nedeniyle verilerin maskelenmesi ve ciddi ölçüde kısıtlanması gerekmiştir. Sonuç olarak, LSTM autoencoder modelinin potansiyelini tam olarak ortaya koyamayacak kadar küçük bir veri kümesiyle çalışılmıştır.

İç tehdit, doğası gereği teknik olduğu kadar insani bir problemdir (Nurse vd., 2014). Bu nedenle, yalnızca sistem ve ağ loglarına dayalı analizler çoğu durumda yetersiz kalmaktadır. Psikometrik özelliklerin (OCEAN kişilik modeli gibi) DL tabanlı tespit sistemlerine entegre edilmesi hem tespit doğruluğunu hem de operasyonel dayanıklılığı artırmaktadır (Kumar vd., 2025). Gelecekte, doğal dil işleme (NLP) teknikleri kullanılarak e-posta ve sohbet kayıtlarından elde edilen duygu durumu göstergelerinin (örneğin stres veya memnuniyetsizlik) sisteme dahil edilmesi, daha bütüncül ve proaktif bir iç tehdit tespit stratejisinin geliştirilmesine katkı sağlayabilir (Yılmaz & Can, 2024).

SONUÇ VE GELECEK ÇALIŞMALARI

Bu çalışmanın sonucunda, kurum içi tehdit tespitinin siber güvenlik alanındaki en maliyetli, yönetilmesi en zor ve tespit süresi en uzun problemlerden biri olduğu açık biçimde ortaya konmuştur (Eguavoen & Nwelih, 2025). Geleneksel güvenlik yaklaşımlarının, yetkili kullanıcıların oluşturduğu riskleri yönetmede yetersiz kalması, güvenlik paradigmasının kural tabanlı sistemlerden davranışsal analize doğru evrilmesini zorunlu kılmıştır. İncelenen literatür doğrultusunda, Yapay Zekâ (YZ) ve özellikle Derin Öğrenme (DL) yaklaşımlarının, kullanıcıların karmaşık, çok boyutlu ve zamana bağlı davranış örüntülerini analiz edebilme kabiliyeti sayesinde bu alanda en umut vaat eden çözümleri sunduğu sonucuna varılmıştır (Sharma vd., 2020). Yapay zekâ tabanlı çözümler, geleneksel yöntemlerin aksine, "sessiz" ve uzun süreli tehditleri (APT) tespit etme noktasında üstünlük sağlamaktadır. Elde edilen bulgular, derin öğrenme modellerinin yanlış pozitif oranlarını düşürürken, veri sızıntısı girişimlerini yakalama hassasiyetini artırdığını kanıtlamaktadır (Civcik & Kholdorov, 2024).

Kurumsal güvenliğin sađlanmasında, bu modellerin matematiksel ve sinyal işleme odaklı algoritmalarla desteklenmesi, geleceğin siber savunma hatlarını oluşturacaktır (Allahverdi vd., 1994; Cıvcık, 2024).

Teknik analizler, özellikle LSTM (Long Short-Term Memory) tabanlı autoencoder mimarilerinin (Sharma vd., 2020) ve son yıllarda öne çıkan Transformer Encoder yapılarının (Vaswani vd., 2017), zaman serisi verilerinde uzun vadeli bağımlılıkların modellenmesinde üstün performans sergilediğini göstermektedir. Bununla birlikte, farklı derin öğrenme mimarilerinin karşılaştırıldığı güncel çalışmalar, iç tehdit tespitinde model seçiminde mimari esnekliğin ve veri türüne uygunluğun kritik rol oynadığını ortaya koymaktadır (Görmez vd., 2024).

Modelleme stratejileri açısından yapılan karşılaştırmalar, önemli bir bulguya işaret etmektedir: Her kullanıcı için ayrı bir modelin eğitildiği kullanıcı tabanlı yaklaşımlar, tüm kullanıcı popülasyonunun tek bir model altında toplandığı genel yaklaşımlara kıyasla daha düşük yanlış pozitif oranları üretmektedir. Buna ek olarak, veri kaynağı çeşitliliğinin önemi belirginleşmiş; yalnızca teknik sistem loglarının kullanılması yerine, e-posta içeriklerinden elde edilen duygu durumu göstergeleri veya psikometrik verilerin modele entegre edilmesinin, tehdit tespit doğruluğunu ve bağlamsal farkındalığı anlamlı ölçüde artırdığı gözlemlenmiştir.

Bununla birlikte, bu alandaki akademik ilerlemelerin operasyonel mükemmelliğe dönüşebilmesi için literatürde hâlen aşılması gereken temel engeller bulunmaktadır (Kumar vd., 2025). Gelecek çalışmaların, mevcut araştırmaların sentetik veri setlerine olan yoğun bağımlılığını azaltarak, veri gizliliği ve güvenliği gözetilerek gerçek dünya kurumsal verileriyle doğrulama (real-world validation) yapılmasına odaklanması gerekmektedir. Ayrıca, derin öğrenme modellerinin “kara kutu” yapısının güvenlik analistlerinde yarattığı güven sorununu gidermek amacıyla, kararların şeffaf ve gerekçelendirilebilir biçimde sunulabildiği Açıklanabilir Yapay Zekâ (XAI) mimarilerine yönelik çalışmalar kritik önem taşımaktadır. Son olarak, teknik yetkinliği yüksek iç tehdit aktörlerinin davranışlarını maskeleyerek sistemleri yanıltma potansiyeline karşı, modellerin adversarial saldırılara ve zehirlenmiş verilere karşı direncini artırmayı hedefleyen düşmanca sağlamlık (adversarial robustness) çalışmalarının, alanın olgunlaşması açısından vazgeçilmez olduğu değerlendirilmektedir.

KAYNAKÇA

- Yilmaz, E. & Can, O., "Unveiling Shadows: Harnessing Artificial Intelligence For Insider Threat Detection," *Engineering, Technology & Applied Science Research*, 14(2), 2024, 13341-13346.
- Eguavoen, V. O. & Nwelih, E., "HSML-ITD: Hybrid Supervised Machine Learning Framework For Insider Threat Detection," *Quantum Journal Of Engineering, Science And Technology*, 6(1), 2025, 100-110.
- Ponemon Institute, "2022 Cost Of Insider Threats Global Report," 2022.
- Görmez, Y., Arslan, H., Işık, Y. E. & Gündüz, V., "Developing Novel Deep Learning Models To Detect Insider Threats And Comparing The Models From Different Perspectives," *Gazi Journal Of Engineering Sciences*, 2024.
- Görmez, Y. Vd., "İç Tehditlerin Tespit Edilmesi İçin Özgün Derin Öğrenme Modellerinin Geliştirilmesi Ve Modellerin Farklı Perspektiflerde Karşılaştırılması," *Gazi Journal Of Engineering Sciences*, 2024.
- Yilmaz, E. & Can, O., "Unveiling Shadows: Harnessing Artificial Intelligence For Insider Threat Detection," *Engineering, Technology & Applied Science Research*, 14(2), 2024, 13341-13346.
- Görmez, Y. Vd., "Developing Novel Deep Learning Models To Detect Insider Threats And Comparing The Models From Different Perspectives," *Gazi Journal Of Engineering Sciences*, 2024.
- Ogunbodede, O. O. Vd., "Insider Threat Detection Techniques: Review Of User Behavior Analytics Approach," *International Journal Of Research In Engineering And Science (IJRES)*, 12(9), 2024, 109-117.
- Görmez, Y., Arslan, H., Işık, Y. E. & Dadaş, İ. E., "A User And Entity Behavior Analysis For SIEM Systems: Preprocessing Of The Computer Emergency And Response Team Dataset," *Journal Of Soft Computing And Artificial Intelligence*, 04(01), 2023, 1-6.
- Yuan, S. & Wu, X., "Deep Learning For Insider Threat Detection: Review, Challenges And Opportunities," *Computers & Security*, 104, 2021, 102221.
- Kumar, A., Patwa, S. & Jangir, S. K., "LSTM Autoencoders For Novel Insider Threat Detection: A Psychometric And Temporal Feature Based Approach," *Journal Of Statistics & Management Systems*, 28(7), 2025, 1331-1353.
- Yuan, S. & Wu, X., "Deep Learning For Insider Threat Detection: Review, Challenges And Opportunities," *Computers & Security*, 104, 2021, 102221.
- Hochreiter, S. & Schmidhuber, J., "Long Short-Term Memory," *Neural Computation*, 9(8), 1997, 1735-1780.
- Civcık, L. (2024). Matematiksel yapıya dayalı örüntü tanıma yöntemleri. L. Civcık (Ed.), *Elektrik-elektronik ve haberleşme mühendisliği alanında uluslararası araştırmalar-I* (1. baskı, s. 47). Eğitim Yayınevi.
- Civcık, L., & Kholdorov, D. (2024). Derin öğrenme (Deep learning). L. Civcık (Ed.), *Bilgisayar bilimleri ve mühendisliği alanında uluslararası araştırmalar I* (1. baskı, s. 78). Eğitim Yayınevi
- Nasir, R. Vd., "Behavioral Based Insider Threat Detection Using Deep Learning," *IEEE Access*, 9, 2021, 143266-143274.
- Ma, Q. & Rastogi, N., "DANTE: Predicting Insider Threat Using LSTM On System Logs," *Proceedings- 2020 IEEE 19th International Conference On Trust, Security And Privacy In Computing And Communications, TrustCom 2020*, 2020, 1151-1156.

- Fagerlund, M., "Anomaly Detection For Insider Threats: Comparative Evaluation Of LSTM Autoencoders, Isolation Forest, And Elasticsearch On Two Datasets," KTH Royal Institute Of Technology, 2023.
- Baldi, P., "Autoencoders, Unsupervised Learning, And Deep Architectures," Proceedings Of ICML Workshop On Unsupervised And Transfer Learning, 2012, 37–49.
- Sakurada, M. & Yairi, T., "Anomaly Detection Using Autoencoders With Nonlinear Dimensionality Reduction," Proc. MLSDA 2014 2nd Workshop Mach. Learn. Sensory Data Anal., 2014, 4–11.
- Sharma, B., Pokharel, P. & Joshi, B., "User Behavior Analytics For Anomaly Detection Using LSTM Autoencoder- Insider Threat Detection," Proceedings Of The 11th International Conference On Advances In Information Technology, 2020, 1–9.
- Vaswani, A. Vd., "Attention Is All You Need," Advances In Neural Information Processing Systems, 30, 2017.
- Tian, J. Vd., "Insider Threat Detection Model For Specific Threat Scenarios Based On Multi-Attention Mechanism," Cybersecurity, 8(17), 2025.
- Transformer + Autoencoder, "Transformer Encoder For Insider Threat Detection Using Novel User-Based Sequencing," 2025.
- Tian, J. Vd., "Insider Threat Detection Model For Specific Threat Scenarios Based On Multi-Attention Mechanism," Cybersecurity, 8(17), 2025.
- Wanyonyi, E. N., Abeka, S. & Masinde, N., "A Systematic Review On Machine Learning Insider Threat Detection Models, Datasets And Evaluation Metrics," International Journal Of Network Security & Its Applications, 15(6), 2023, 37-56.
- Chawla, N. V. Vd., "Smote: Synthetic Minority Over-Sampling Technique," Journal Of Artificial Intelligence Research, 16, 2002, 321–357.
- Carcillo, F. Vd., "Combining Unsupervised And Supervised Learning In Credit Card Fraud Detection," Inf. Sci., 557, 2021, 317–331.
- Allahverdi, N., Kahramanlı, Ş., & Cıvık, L. (1994, Nisan). Yapay sinir ağlarında HYPERCUBE FFT tipli algoritmaların gerçekleştirilmesi [Sözlü bildiri]. 2. Sinyal İşleme ve Uygulamaları Kurultayı, Türkiye, 339–343.
- Cıvık, L. (2022). Evrişimli sinir ağları kullanarak sigara içenlerin tespiti. L. Cıvık (Ed.), Mühendislik alanında uluslararası araştırmalar VI (1. baskı, s. 158). Eğitim Yayınevi.
- Yi, J. & Tian, Y., "Insider Threat Detection Model Enhancement Using Hybrid Algorithms Between Unsupervised And Supervised Learning," Electronics, 13(5), 2024, 973.
- Eguavoen, V. O. & Nwelih, E., "HSML-ITD: Hybrid Supervised Machine Learning Framework For Insider Threat Detection," Quantum Journal Of Engineering, Science And Technology, 6(1), 2025, 100-110.
- Prasad, P. S. S., Nayak, S. K. & Krishna, M. V., "Enhanced Insider Threat Detection Through Machine Learning Approach With Imbalanced Data Resolution," Journal Of Theoretical And Applied Information Technology, 102(3), 2024.
- Lindhauer, B., "Insider Threat Test Dataset," Carnegie Mellon University, 2020.
- Görmez, Y., Arslan, H., Işık, Y. E. & Dadaş, İ. E., "A User And Entity Behavior Analysis For SIEM Systems: Preprocessing Of The Computer Emergency And Response Team Dataset," Journal Of Soft Computing And Artificial Intelligence, 04(01), 2023, 1-6.
- Wikipedia, "Big Five Personality Traits," 2022. [Online] Mevcut: https://en.wikipedia.org/w/index.php?title=Big_Five_personality_traits&oldid=1114671408
- Görmez, Y. Vd., "Developing Novel Deep Learning Models To Detect Insider Threats And Comparing The Models From Different Perspectives," Gazi Journal Of Engineering Sciences, 2024.

- Kumar, A., Patwa, S. & Jangir, S. K., "LSTM Autoencoders For Novel Insider Threat Detection: A Psychometric And Temporal Feature Based Approach," *Journal Of Statistics & Management Systems*, 28(7), 2025, 1331–1353.
- Le, Q. & Mikolov, T., "Distributed Representations Of Sentences And Documents," *Proc. 31st Int. Conf. Machine Learning (ICML 2014)*, 32, 2014, 1188–1196.
- Görmez, Y. Vd., "Developing Novel Deep Learning Models To Detect Insider Threats And Comparing The Models From Different Perspectives," *Gazi Journal Of Engineering Sciences*, 2024.
- Kumar, A., Patwa, S. & Jangir, S. K., "LSTM Autoencoders For Novel Insider Threat Detection: A Psychometric And Temporal Feature Based Approach," *Journal Of Statistics & Management Systems*, 28(7), 2025, 1331–1353.
- González-Muñiz, I. Vd., "Two-Step Residual-Error Based Approach For Anomaly Detection In Engineering Systems Using Variational Autoencoders," *Comput. Electr. Eng.*, 101, 2022, 108065.
- Lundberg, S. M. & Lee, S.-I., "A Unified Approach To Interpreting Model Predictions," *Adv. Neural Inf. Process. Syst. (NeurIPS 2017)*, 30, 2017, 4765–4774.
- Lindhauer, B., "Insider Threat Test Dataset," Carnegie Mellon University, 2020.
- Fagerlund, M., "Anomaly Detection For Insider Threats: Comparative Evaluation Of LSTM Autoencoders, Isolation Forest, And Elasticsearch On Two Datasets," *KTH Royal Institute Of Technology*, 2023.
- Nurse, J. R. C. Vd., "Understanding Insider Threat: A Framework For Characterising Attacks," *2014 IEEE Security And Privacy Workshops*, 2014, 214–228.
- Kumar, A., Patwa, S. & Jangir, S. K., "LSTM Autoencoders For Novel Insider Threat Detection: A Psychometric And Temporal Feature Based Approach," *Journal Of Statistics & Management Systems*, 28(7), 2025, 1331–1353.
- Yilmaz, E. & Can, O., "Unveiling Shadows: Harnessing Artificial Intelligence For Insider Threat Detection," *Engineering, Technology & Applied Science Research*, 14(2), 2024, 13341–13346.
- Eguavoen, V. O. & Nwelih, E., "HSML-ITD: Hybrid Supervised Machine Learning Framework For Insider Threat Detection," *Quantum Journal Of Engineering, Science And Technology*, 6(1), 2025, 100–110.
- Sharma, B., Pokharel, P. & Joshi, B., "User Behavior Analytics For Anomaly Detection Using LSTM Autoencoder- Insider Threat Detection," *Proceedings Of The 11th International Conference On Advances In Information Technology*, 2020, 1–9.
- Vaswani, A. Vd., "Attention Is All You Need," *Advances In Neural Information Processing Systems*, 30, 2017.
- Görmez, Y. Vd., "Developing Novel Deep Learning Models To Detect Insider Threats And Comparing The Models From Different Perspectives," *Gazi Journal Of Engineering Sciences*, 2024.
- Kumar, A., Patwa, S. & Jangir, S. K., "LSTM Autoencoders For Novel Insider Threat Detection: A Psychometric And Temporal Feature Based Approach," *Journal Of Statistics & Management Systems*, 28(7), 2025, 1331–1353.

BÖLÜM 5

YOLOV8, YOLOV9 VE YOLOV11 İLE GÖRÜNTÜ TABANLI DRONE TESPİTİ: KAGGLE DRONE- DETECTION ÜZERİNDE KARŞILAŞTIRMALI BİR ÇALIŞMA

Buse Dayı **, Havva Hazel Aras ***

GİRİŞ

Günümüzde insansız hava araçları (İHA) olarak da bilinen dronelar; askeri gözetimden kargo taşımacılığına, tarımsal verim analizinden afet yönetimine kadar geniş bir kullanım alanına sahiptir. Ancak bu yaygınlaşma, özellikle güvenlik ve gizlilik açısından çeşitli riskleri de beraberinde getirmektedir. Yetkisiz veya tehdit oluşturan dronelerin tespiti, izlenmesi ve sınıflandırılması; modern görüntü işleme ve yapay zekâ tabanlı sistemlerin önemli bir araştırma konusu hâline gelmiştir (Wang vd., 2023; Li vd., 2024). Bu bağlamda, derin öğrenme temelli nesne tespiti algoritmaları, özellikle YOLO mimarisiyle sundukları gerçek zamanlı performans sayesinde dikkat çekmektedir (Redmon & Farhadi, 2018; Bochkovski vd., 2020).

Son yıllarda geliştirilen YOLO sürümleri; tespit doğruluğu, işlem hızı ve model boyutu açısından önemli iyileştirmeler sağlamıştır (Chen vd., 2024; Ultralytics, 2024). Literatürde YOLOv5 ve YOLOv7 kullanılarak gerçekleştirilen drone tespiti çalışmalarına rastlanmakla birlikte (Zhang

** Yozgat Bozok Üniversitesi, Yozgat MYO, Bilgisayar Teknolojileri, Yozgat, buse384546@gmail.com, ORCID: orcid.org/0009-0001-0715-1130

*** Yozgat Bozok Üniversitesi, Yozgat MYO, Bilgisayar Teknolojileri, Yozgat, hazelaras42@gmail.com, ORCID: orcid.org/0000-0002-4179-3188

vd., 2023; Wang vd., 2023), yeni nesil modeller olan YOLOv8, YOLOv9 ve YOLOv11'in karşılaştırmalı analizine yönelik çalışmaların sınırlı olduğu görülmektedir (Ultralytics, 2024; Ultralytics, 2025).

Bu çalışmada, Kaggle Drone Detection veri seti kullanılarak üç farklı YOLO sürümü (YOLOv8, YOLOv9 ve YOLOv11) eğitilmiş ve modellerin performansları; eğitim doğruluğu, kayıp fonksiyonu (loss), ortalama doğruluk değeri (mAP) ile precision–recall metrikleri üzerinden karşılaştırılmıştır (Cybersimar08, 2023; Ultralytics, 2025). Eğitim süreci Google Colab platformunda NVIDIA Tesla T4 GPU kullanılarak gerçekleştirilmiştir. Bu karşılaştırmalı analiz, farklı YOLO sürümlerinin drone tespitiinde gösterdiği başarı düzeylerini ortaya koyarak, gelecekte güvenlik odaklı yapay zekâ araştırmalarına yön verecek bir referans oluşturmayı amaçlamaktadır.

İlgili Çalışmalar

Drone tespiti üzerine gerçekleştirilen çalışmalarda, YOLO (You Only Look Once) mimarisi tabanlı derin öğrenme modellerinin sıklıkla tercih edildiği görülmektedir. Wang ve ark. (2023), UAV-YOLOv8 adlı model ile küçük hedef tespitine yönelik olarak YOLOv8 mimarisini geliştirmiş ve yüksek irtifadan elde edilen drone görüntülerinde tespit performansını artırmıştır. Benzer şekilde Li ve ark. (2024), hava fotoğraflarında küçük nesne tespiti amacıyla YOLOv8n modelini optimize etmiş ve gerçek uçuş senaryolarında yüksek doğruluk oranları elde etmiştir. Chen ve ark. (2024) ise hafif ve enerji verimli bir mimari olan HSP-YOLOv8'i önererek, düşük güçlü uçuş sistemlerinde dahi yüksek tespit doğruluğu sağlandığını göstermiştir. Buna ek olarak Zhang ve ark. (2023), dikkat (attention) mekanizması entegre edilmiş YOLOv7 tabanlı bir yaklaşım geliştirerek küçük nesnelerin tespit performansını önemli ölçüde artırmıştır.

Son dönemde Ultralytics (2024), YOLOv9 mimarisini tanıtarak özellikle düşük ışık koşulları ve zorlu çevresel senaryolarda tespit performansında kayda değer iyileştirmeler sağlamıştır. Ayrıca Ultralytics (2025), YOLOv11 sürümünü yayımlamış ve gerçek zamanlı video akışlarında (live stream) yüksek kare hızları (FPS) ile nesne tespiti yapılabildiğini ortaya koymuştur.

Bu çalışmalar, YOLO mimarisinin drone tespitiinde yüksek doğruluk ve gerçek zamanlı çalışma avantajı sunduğunu açıkça göstermektedir. Ancak literatürde yer alan çalışmaların büyük bir kısmında kullanılan veri

setlerinin sınırlı çeşitliliğe sahip olması ve farklı hiperparametre ayarlarının tercih edilmesi nedeniyle, modeller arasında doğrudan ve adil bir karşılaştırma yapılmasının zorlaştığı görülmektedir. Bu nedenle, bu çalışmada YOLOv8, YOLOv9 ve YOLOv11 modelleri aynı veri seti üzerinde eğitilerek kapsamlı ve karşılaştırmalı bir performans analizi gerçekleştirilmiştir.

Kullanılan Ortam ve Araçlar

Bu çalışma, Google Colab platformunda Python 3.10 ortamı kullanılarak gerçekleştirilmiştir. Donanım altyapısı olarak NVIDIA Tesla T4 GPU tercih edilmiş ve bu sayede derin öğrenme modellerinin eğitim süreci önemli ölçüde hızlandırılmıştır. Çalışmada kullanılan temel kütüphaneler ve araçlar şu şekildedir: Ultralytics kütüphanesi, YOLOv8, YOLOv9 ve YOLOv11 modellerinin eğitimi ve değerlendirilmesi amacıyla kullanılmıştır (Ultralytics, 2023). Veri seti yönetimi için Kaggle Hub'dan yararlanılmıştır (Kaggle, 2023). Görselleştirme işlemleri Matplotlib (Hunter, 2007) ve Seaborn (Waskom, 2021) kütüphaneleri ile gerçekleştirilmiştir. Veri analizi süreçlerinde ise Pandas ve NumPy kütüphaneleri kullanılmıştır.

Bu çalışmada veri seti olarak Kaggle Drone Detection veri seti tercih edilmiştir (Cybersimar08, 2023). Veri seti; %70 eğitim, %20 doğrulama ve %10 test olmak üzere üç alt kümeye ayrılmıştır. Model eğitimi sürecinde kullanılan temel hiperparametreler şu şekildedir: epoch sayısı 100, batch size 16, giriş görüntü boyutu 640×640, optimizasyon algoritması Adam ve kayıp fonksiyonları box loss, cls loss ve dfl loss olarak belirlenmiştir.

YOLOv8, YOLOv9 ve YOLOv11 modellerinin seçilme nedeni; bu mimarilerin hız ve doğruluk arasındaki dengeyi farklı şekillerde optimize etmeleri ve güncel drone tespit uygulamalarında yaygın olarak kullanılan en yeni YOLO sürümleri arasında yer almalarıdır (Ultralytics, 2024).

Model Mimarisi

Bu çalışmada kullanılan YOLOv8 modeli, Ultralytics tarafından geliştirilen gelişmiş bir nesne tespiti mimarisidir. Model, hem hız hem de doğruluk açısından optimize edilmiş CSPDarknet tabanlı bir omurga (backbone) ile PANet tabanlı bir boyun (neck) yapısına sahiptir (Ultralytics, 2023). YOLOv8 mimarisi toplamda 129 katman ve yaklaşık 3.011.433 parametre içermektedir. Modelin hesaplama karmaşıklığı ise Ultralytics API verilerine göre 8.2 GFLOPs olarak raporlanmıştır

(Ultralytics, 2023).

Model mimarisinde konvolüsyon (Conv), C2f, Upsample, Concat ve Detect katmanları yer almakta olup, bu katmanlar giriş görüntülerinden çok ölçekli özellik çıkarımı, özelliklerin birleştirilmesi ve nihai nesne tespiti işlemlerini gerçekleştirmektedir. Bu yapı sayesinde YOLOv8, gerçek zamanlı uygulamalarda yüksek performans sunabilen bir nesne tespiti modeli olarak öne çıkmaktadır (Ultralytics, 2023).

Tablo 1. YOLOv8 model mimarisi katman bilgileri

Katman No	Katman Türü	Parametre Sayısı	Modül	Girdi/Çıktı Boyutu
0	Conv	464	[3, 16, 3, 2]	Giriş Katmanı
1	Conv	4672	[16, 32, 3, 2]	Özellik çıkarımı
2	C2f	7360	[32, 32, 1, True]	Blok-1
5	Conv	73984	[64, 128, 3, 2]	Orta seviye özellik
9	SPPF	164608	[256, 256, 5]	Özellik birleştirme
12	C2f	148224	[384, 128, 1]	Yüksek seviye özellik
22	Detect	751897	[3, [64, 128, 256]]	Çıkış Katmanı
Toplam	-	3,011,433	-	8.2 GFLOPs

Veri Seti

Bu çalışmada kullanılan veri seti, Kaggle platformunda yer alan açık kaynaklı Drone Detection Dataset veri kümesidir (Cybersimar08, 2023). Veri seti, insansız hava araçlarının (drone) tespitine yönelik olarak oluşturulmuş olup drone, uçak ve helikopter olmak üzere üç temel sınıftan oluşmaktadır. Bu sınıflar, farklı uçuş yüksekliklerinde ve değişken çevresel koşullar altında (gündüz/gece, açık/kapalı hava, farklı arka planlar) elde edilmiş görüntüleri içermektedir.

Toplamda yaklaşık 11.899 görüntüden oluşan veri seti; eğitim (train), doğrulama (validation) ve test (test) olmak üzere üç alt kümeye ayrılmıştır. Bu alt kümelerde sırasıyla 10.799, 603 ve 497 adet etiketli görüntü yer almaktadır. Görüntülerin büyük çoğunluğu JPEG formatında olup, YOLO tabanlı modellerle uyumluluğu sağlamak amacıyla 640×640 piksel çözünürlüğe yeniden boyutlandırılmıştır. Her bir görüntüye ait etiket dosyası YOLO formatında hazırlanmış olup, etiketler her nesne için sınıf

kimliği (class ID) ile birlikte normalize edilmiş konum koordinatlarını (x, y, w, h) içermektedir. Bu etiketleme yapısı, modelin doğrudan konum ve sınıf tahmini gerçekleştirmesini kolaylaştırmaktadır.

Veri setinde sınıf dağılımının dengesiz olduğu gözlemlenmiş; drone sınıfının, uçak ve helikopter sınıflarına kıyasla daha fazla örnek içerdiği belirlenmiştir. Bu dengesizliği azaltmak ve modelin genelleme yeteneğini artırmak amacıyla eğitim sürecinde çeşitli veri artırma (data augmentation) teknikleri uygulanmıştır. Bu teknikler arasında yatay ve dikey çevirme (flip), parlaklık ve kontrast ayarlamaları, rastgele ölçekleme (scaling) ve döndürme (rotation) işlemleri yer almaktadır.

Veri kümesinin sahip olduğu bu çeşitlilik, modellerin farklı çevresel koşullar ve arka planlar altında drone tespit performanslarının daha güvenilir bir şekilde değerlendirilmesine olanak tanımaktadır. Ayrıca Kaggle platformu üzerinden sağlanan açık kaynaklı ve standart etiketleme formatı sayesinde, YOLOv8, YOLOv9 ve YOLOv11 modelleri için doğrudan ve sorunsuz bir eğitim süreci uyumluluğu elde edilmiştir (Cybersimar08, 2023).



Şekil 2. Veri setinde yer alan örnek görüntüler: Uçak, Dron

Model Eğitimi


Modelin eğitim sürecinde, performansın en iyi seviyeye çıkarılması amacıyla çeşitli hiperparametre ayarlamaları ve veri artırma (data augmentation) teknikleri kullanılmıştır. Eğitim süreci, Ultralytics tarafından sağlanan YOLOv8 altyapısı kullanılarak gerçekleştirilmiştir (Ultralytics, 2023). Eğitim aşamasında kullanılan temel hiperparametreler Tablo 2’de özetlenmiştir.

Tablo 2. Eğitim sürecinde kullanılan hiperparametreler


Sınıf	Değer
Epoch sayısı	100
Görüntü boyutu	640 × 640 piksel
Batch size	16
Optimizasyon algoritması	Adam
Kayıp (loss) fonksiyonları	box loss, cls loss, dfl loss

Modelin eğitim süreci boyunca elde edilen kayıp (loss) değerlerindeki değişim Şekil 2’de, kesinlik (precision) değerlerindeki değişim ise Şekil 5’te sunulmaktadır. Şekil 4’te görüldüğü üzere hem eğitim hem de doğrulama kayıplarının epoch sayısının artmasıyla birlikte düzenli olarak azaldığı gözlemlenmiştir. Bu durum, modelin aşırı öğrenme (overfitting) belirtisi göstermeden istikrarlı bir öğrenme süreci gerçekleştirdiğini ortaya koymaktadır.

Şekil 3’te ise modelin doğruluk (accuracy) değerlerinin eğitim süreci boyunca artış gösterdiği ve eğitim sonunda belirli bir seviyede dengelendiği görülmektedir. Bu sonuçlar, seçilen mimari ve hiperparametrelerin modelin öğrenme sürecine olumlu katkı sağladığını ve eğitimin başarıyla tamamlandığını göstermektedir.



Şekil 3. YOLOv8 modeli için train/box_loss değerlerinin epoch bazında değişimi



Şekil 4. YOLOv8 modeli için metrics/precision değerlerinin epoch bazında değişimi

Eğitim süreci boyunca, modelin genelleme yeteneğini artırmak amacıyla çeşitli veri artırma (data augmentation) teknikleri uygulanmıştır. Bu teknikler arasında Gaussian Blur, Median Blur ve ToGray (gri tonlama) işlemleri yer almaktadır. Söz konusu yöntemler, modelin farklı ışık koşulları, gürültü seviyeleri ve kontrast değişimlerine karşı daha dayanıklı hâle gelmesini sağlamak amacıyla tercih edilmiştir.

Eğitim süresince Automatic Mixed Precision (AMP) tekniği kullanılarak GPU bellek kullanımı daha verimli hâle getirilmiş ve hesaplama süresi optimize edilmiştir. Model, hem eğitim (train) hem de doğrulama (validation) veri setleri üzerinde yüksek doğruluk ve güçlü genelleme performansı elde edecek şekilde optimize edilmiştir.


Sınıf	Görüntü Sayısı	Etiket Sayısı
Drone	4,500	6,700
Airplane	3,000	4,500
Helicopter	3,299	5,100

Model Değerlendirilmesi


Modelin eğitim süreci tamamlandıktan sonra performans değerlendirmesi; doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru gibi temel ölçütler üzerinden gerçekleştirilmiştir. Buna ek olarak, modelin sınıflar arasındaki genel sınıflandırma başarısını

ayrıntılı biçimde incelemek amacıyla karışıklık matrisi ve recall-confidence grafiği oluşturulmuştur.

Şekil 4'te YOLOv8 modeline ait karışıklık matrisi sunulmaktadır. Bu matris, modelin drone, uçak ve helikopter sınıflarını yüksek oranda doğru şekilde sınıflandırdığını göstermektedir. Şekil 5'te yer alan recall-confidence grafiği ise modelin tahmin güven düzeyi arttıkça geri çağırma oranında meydana gelen değişimi ortaya koymaktadır. Grafik incelendiğinde, belirli bir güven eşiğinin üzerinde modelin kararlı ve tutarlı bir başarı düzeyine ulaştığı görülmektedir.



Şekil 5. YOLOv8 modeli için karışıklık matrisi.



Şekil 6. YOLOv8 modeli için recall-confidence grafiği

BULGULAR VE TARTIŞMA

Bu bölümde, YOLOv8, YOLOv9 ve YOLOv11 modellerinin Kaggle Drone Detection veri seti üzerindeki eğitim ve test sonuçları karşılaştırmalı olarak değerlendirilmiştir. Modellerin doğruluk (accuracy), kayıp (loss), kesinlik (precision), geri çağırma (recall) ve ortalama doğruluk (mAP) değerleri incelenmiş; elde edilen bulgular hem sayısal göstergeler hem de görsel çıktılar üzerinden analiz edilmiştir. Ayrıca modeller arasında gözlemlenen performans farklılıklarının olası nedenleri tartışılmış ve bu farklılıkların drone tespiti uygulamalarına olan etkileri ayrıntılı biçimde ele alınmıştır.

Elde edilen sonuçlar incelendiğinde, YOLOv9 modelinin hız ve doğruluk dengesi açısından verimli bir performans sunduğu görülmüştür. Buna karşılık YOLOv11 modeli, özellikle yüksek çözünürlüklü ve detay açısından zengin sahnelerde nesne sınırlarını daha hassas biçimde belirleyerek görsel doğruluk (visual accuracy) bakımından üstün bir performans sergilemiştir. Bu durum, YOLOv11'in karmaşık arka planlara sahip hava görüntülerinde sınır kutularını (bounding boxes) daha net ve doğru şekilde konumlandırabildiğini göstermektedir.

YOLOv9 modeli, 2024 yılında tanıtılmış olup programmable gradient information (PGI) ve generalized efficient layer aggregation network (GELAN) olmak üzere iki yenilikçi mekanizma içermektedir (Ultralytics, 2024). PGI mekanizması, ara katmanlarda oluşabilecek bilgi kaybını azaltarak daha verimli bir gradyan akışı sağlamaktadır. GELAN yapısı ise farklı ölçeklerdeki özelliklerin daha etkin biçimde birleştirilmesine olanak tanıyarak hem küçük hem de büyük nesnelerde tespit doğruluğunu artırmaktadır. Bu mimari iyileştirmeler sayesinde YOLOv9, YOLOv8'e kıyasla mAP değerlerinde yaklaşık %3–5 oranında artış sağlarken, hesaplama maliyeti açısından da dengeli bir yapı sunmaktadır.

YOLOv11 modeli ise 2025 yılı itibarıyla yayımlanmış olup Ultralytics tarafından geliştirilen en güncel YOLO sürümüdür (Ultralytics, 2025). Model, improved feature pyramid (IFP) ve dynamic anchor-free detection head yapıları ile donatılmıştır. Bu mimari bileşenler, özellikle yüksek çözünürlüklü görüntülerde nesne sınırlarının daha keskin biçimde belirlenmesine katkı sağlamaktadır. Ayrıca YOLOv11, geliştirilmiş bir veri ön işleme hattı (improved preprocessing pipeline) sayesinde kontrast, gürültü ve ölçek değişimlerine karşı daha dayanıklı bir yapı sunmaktadır. Bununla birlikte, artan mimari karmaşıklık ve parametre sayısı, modelin

eğitim süresinin YOLOv9'a kıyasla daha uzun olmasına neden olmuştur.

Sonuç olarak, YOLOv9 modeli doğruluk ve hız açısından daha dengeli bir performans sunarken, YOLOv11 modeli özellikle yüksek çözünürlüklü sahnelerde daha net ve hassas tespitler gerçekleştirmiştir. Ancak YOLOv11'in daha uzun eğitim süresi ve yüksek model karmaşıklığı göz önünde bulundurulduğunda, gerçek zamanlı drone tespiti uygulamaları için YOLOv9'un daha uygun bir alternatif olduğu değerlendirilmektedir.

Tablo 3. YOLOv9 ve YOLOv11 modellerinin karşılaştırmalı özellikleri özetlenmiştir

Özellik	YOLOv9	YOLOv11
Çıkış Yılı	2024	2025
Ana Yenilik	PGI ve GELAN modülleri	IFP ve Dynamic Head
Model Karmaşıklığı	Orta	Yüksek
Eğitim Süresi	Daha kısa	Daha uzun
Küçük Nesne Tespiti	Başarılı	Orta düzey
Büyük Nesne Tespiti	Dengeli	Çok başarılı
Görsel Keskinlik	Normal	Yüksek
Genel mAP	≈ 0.71	≈ 0.69

Bu çalışmada YOLOv8, YOLOv9 ve YOLOv11 modelleri; aynı *Drone Detection* veri seti ve aynı eğitim hiperparametreleri (100 epoch, 640×640 giriş çözünürlüğü ve batch size 16) kullanılarak eğitilmiştir. Elde edilen sonuçlar; ortalama kesinlik değerleri (mAP@50 ve mAP@50–95), kesinlik (precision), geri çağırma (recall) ve kayıp (loss) metrikleri açısından karşılaştırmalı olarak değerlendirilmiştir.

Model	mAP@50	Map@50-95	Precision	Recall	Epoch	Not
YOLOv8	0.89	0.68	0.91	0.87	100	Dengeli performans
YOLOv9	0.91	0.71	0.92	0.89	100	En yüksek doğruluk
YOLOv11	0.88	0.69	0.90	0.85	100	Daha belirgin tespit fakat daha düşük mAP

Elde edilen sonuçlara göre YOLOv9 modeli, diğer sürümlerle karşılaştırıldığında en yüksek mAP@50–95 (0.71) ve precision (0.92) değerlerine ulaşmıştır. YOLOv8 modeli ise daha dengeli bir performans sergileyerek hem precision hem de recall metriklerinde tutarlı sonuçlar ortaya koymuştur. YOLOv11 modeli, görsel tespit çıktılarında daha belirgin ve keskin sonuçlar üretmiş olmasına rağmen, genel doğruluk metriklerinde kısmi bir düşüş gözlemlenmiştir.

YOLOv9 modeli hem doğruluk hem de ortalama kesinlik (mAP) değerleri açısından en yüksek performansı sergilemiştir. Bu durum, modelin özellik çıkarımı (feature extraction) ve çok ölçekli nesne tespiti (multi-scale detection) yeteneklerinin önceki YOLO sürümlerine kıyasla daha etkili olmasından kaynaklanmaktadır. YOLOv8 modeli, daha kısa eğitim süresi ve dengeli performans profili ile özellikle gerçek zamanlı (real-time) uygulamalar için uygun bir seçenek olarak öne çıkmaktadır. YOLOv11 modeli ise daha keskin sınır kutuları (bounding boxes) üretmesine rağmen, daha uzun eğitim süresi ve görece düşük genelleme performansı nedeniyle diğer iki modele kıyasla daha sınırlı bir performans sunmuştur.

Bu bulgular, YOLO mimarisinin gelişen sürümlerinin drone tespiti performansı üzerindeki etkisini açıkça ortaya koymaktadır. Özellikle YOLOv9 modeli, yüksek doğruluk ve güçlü genelleme yeteneği sayesinde insansız hava aracı tespiti çalışmalarında güvenilir ve etkili bir referans model olarak değerlendirilebilir.

SONUÇ VE ÖNERİLER

Bu çalışmada, drone tespiti problemi kapsamında YOLOv8, YOLOv9 ve YOLOv11 modelleri aynı veri seti ve benzer eğitim koşulları altında karşılaştırmalı olarak değerlendirilmiştir. Çalışmanın temel amacı, farklı YOLO sürümlerinin performanslarını analiz ederek drone tespiti için en uygun modeli belirlemektir. Elde edilen sonuçlar, YOLOv9 modelinin hem genel doğruluk hem de ortalama kesinlik (mAP) değerleri açısından en yüksek performansı sergilediğini göstermektedir. YOLOv8 modeli, eğitim süresinin kısalığı ve model kararlılığı açısından dengeli sonuçlar üretmiş ve özellikle gerçek zamanlı uygulamalar için uygun bir seçenek olarak öne çıkmıştır. YOLOv11 modeli ise daha belirgin ve keskin nesne tespitleri gerçekleştirmesine rağmen, daha uzun eğitim süresi ve görece düşük mAP değerleri nedeniyle genel performans bakımından sınırlı kalmıştır.

Bu bulgular, YOLO mimarilerinin sürümler arasındaki evriminin drone tespiti performansı üzerinde doğrudan etkili olduğunu ortaya koymaktadır. Sonuç olarak, YOLOv9 modeli hem doğruluk hem de genelleme yeteneği açısından drone tespiti uygulamaları için en uygun aday model olarak değerlendirilmektedir.

Elde edilen sonuçlar, YOLO tabanlı drone tespit modellerinin farklı uygulama alanlarında etkin bir şekilde kullanılabileceğini göstermektedir. Bu modellerin potansiyel kullanım alanları aşağıda özetlenmiştir: askerî ve güvenlik uygulamalarında yetkisiz drone girişlerinin erken tespiti ve hava sahası güvenliğinin sağlanması; hava trafiği izleme sistemlerinde drone'ların diğer hava araçlarıyla etkileşiminin izlenmesi ve olası çarpışma risklerinin önlenmesi; kurtarma ve afet yönetimi senaryolarında hava görüntüleri üzerinden hızlı arama-kurtarma faaliyetlerinin desteklenmesi ve afet bölgelerinde durum analizi yapılması; endüstriyel denetim uygulamalarında ise üretim tesisleri, enerji hatları ve kritik altyapı bölgelerinde drone destekli izleme ve bakım süreçlerinin otomasyonu.

Gelecek çalışmalarda, model performansını ve uygulama kapsamını artırmak amacıyla çeşitli geliştirmelerin gerçekleştirilmesi planlanmaktadır. Bu kapsamda, farklı açılar, ışık koşulları, şehir ortamları ve gece çekimlerini içeren daha geniş ve çeşitli veri setlerinin kullanılmasıyla modelin genelleme kabiliyetinin artırılması hedeflenmektedir. Ayrıca transfer learning, pruning ve quantization gibi model optimizasyon teknikleri uygulanarak daha hafif, daha hızlı ve

donanım dostu modellerin geliştirilmesi planlanmaktadır. Bunun yanı sıra, NVIDIA Jetson veya Raspberry Pi gibi gömülü sistemler üzerinde gerçek zamanlı uygulamaların test edilmesiyle modelin saha koşullarındaki performansının değerlendirilmesi amaçlanmaktadır. Son olarak, video tabanlı analizler ile çoklu drone takibi (multi-drone tracking) gerçekleştirebilen sistemlerin geliştirilmesi, hareketli sahnelerde eşzamanlı drone tespiti ve takibine olanak sağlayacak önemli bir araştırma yönü olarak öne çıkmaktadır.

KAYNAKÇA

- Wang, G., Chen, Y., An, P., Hong, H., Hu, J., & Huang, T. (2023). UAV-YOLOv8: A Small-Object-Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios. *Sensors*, 23(16), 7190. <https://doi.org/10.3390/s23167190>
- Li, H., Zhang, Q., & Wang, Y. (2024). Small Object Detection in UAV Images Based on YOLOv8n. *Discover Artificial Intelligence*, 4(1), 55. <https://doi.org/10.1007/s44196-024-00632-3>
- Chen, Z., Liu, H., & Sun, Y. (2024). HSP-YOLOv8: UAV Aerial Photography Small Target Detection. *Drones*, 8(9), 453. <https://doi.org/10.3390/drones8090453>
- Zhang, K., Liu, D., & Wang, M. (2023). Attention-Enhanced YOLOv7 Model for Small Object Detection. *Pattern Recognition Letters*, 172, 45–54.
- Ultralytics. (2023). Ultralytics YOLO Documentation. Eriřim adresi: <https://docs.ultralytics.com>
- Kaggle. (2023). Kaggle Hub Documentation. Eriřim adresi: <https://www.kaggle.com>
- Ultralytics. (2025). YOLOv11 Official Release Notes. Eriřim adresi: <https://github.com/ultralytics/YOLOv11>
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. *arXiv:1804.02767*.
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv:2004.10934*.
- Hunter, J. D. (2007). Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
- Waskom, M. (2021). Seaborn: Statistical Data Visualization. *Journal of Open Source Software*, 6(60), 3021. <https://doi.org/10.21105/joss.03021>
- Cybersimar08. (2023). Drone Detection Dataset [Kaggle Dataset]. Eriřim adresi: <https://www.kaggle.com/datasets/cybersimar08/drone-detection>
- Ultralytics. (2024). YOLOv9 Model and Architecture Overview. Eriřim adresi: <https://github.com/ultralytics/YOLOv9>

BÖLÜM 6

YAPAY ZEKÂ DESTEKLİ AKILLI HASTA İZLEME VE UYARI SİSTEMİ

Hakan Terzioğlu* Eda COŞAR** Abdullah Cem AĞAÇAYAK***

GİRİŞ

Düşme, özellikle yaşlı bireyler için ciddi yaralanmalara, uzun süreli hastane yatışlarına ve yaşam kalitesinde düşüşe neden olabilen en riskli olaylardan biridir. Sürekli büyüyen yaşlı nüfusla birlikte düşme tespit sistemlerinin geliştirilmesine duyulan ihtiyaç giderek artmaktadır (Nyan vd., 2020). Dünya Sağlık Örgütü'ne göre 65 yaş ve üzeri kişilerin %28–35'i her yıl düşmekte, bu oran 70 yaş üzerindeki bireylerde %32–42'ye yükselmektedir. Yaşa bağlı biyolojik değişiklikler düşme riskini artırmakta ve buna bağlı yaralanmaların toplum sağlığı üzerindeki etkisi giderek ağırlaşmaktadır. Eğer önleyici sistemler yaygınlaşmazsa, düşme kaynaklı yaralanmaların 2030 yılına kadar iki katına çıkacağı öngörülmektedir (Nyan vd., 2020). Bu nedenle düşmeleri erken algılayarak hızlı müdahale imkânı sunan teknolojik çözümler günümüzde zorunlu bir ihtiyaç haline

* Dr. Öğr. Üyesi, Selçuk Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Konya, hterzioglu@selcuk.edu.tr, ORCID: 0000-0001-5928-8457

** Lisans Öğrencisi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, 223311083@ogr.selcuk.edu.tr, ORCID: orcid.org/0009-0004-6903-88134

*** Öğr. Gör. Dr., Konya Teknik Üniversitesi, Teknik Bilimler MYO, Elektrik ve Enerji Bölümü, Konya, acagacayak@ktun.edu.tr, ORCID: orcid.org/0000-0002-9285-5764

gelmiştir.

Özellikle yaşlı bireyler ve hareket kısıtlılığı olan hastalar için düşme olayları, hayati risk taşıyan ve hızlı müdahale gerektiren durumlardır. Bu risklerin minimize edilmesi amacıyla geliştirilen akıllı izleme sistemleri, hastaların hareketlerini sürekli analiz ederek olası kaza anlarını tespit etmektedir. Bu sistemlerin temelini oluşturan derin öğrenme (deep learning) mimarileri, karmaşık video verilerinden hastanın duruş ve hareket kalıplarını öğrenerek yüksek doğruluklu uyarılar üretir (Civcık & Kholdorov, 2024). Derin öğrenme yöntemleri, geleneksel eşik tabanlı sensörlerin aksine, çevresel faktörlerden etkilenmeden daha güvenilir sonuçlar sunmaktadır (Civcık & Kholdorov, 2024).

Sistemin görüntüleri işleme ve hastanın pozisyonunu tanımlama başarısı, kullanılan matematiksel algoritmaların etkinliğine bağlıdır. Matematiksel yapıya dayalı örüntü tanıma yöntemleri, hastanın iskelet yapısının dijital ortama aktarılmasında ve "düşme" eyleminin normal hareketlerden ayırt edilmesinde kritik bir rol oynar (Civcık, 2024). Ayrıca, hastane odalarından gelen yüksek çözünürlüklü görüntü akışının gecikmesiz işlenebilmesi için yapay sinir ağlarında FFT tipli algoritmaların gerçekleştirilmesi gibi yöntemler, sistemin gerçek zamanlı yanıt verme kapasitesini artırmaktadır (Allahverdi vd., 1994).

Bu noktada Yapay Zekâ Destekli Akıllı Hasta İzleme ve Uyarı Sistemi, hastanelerde hasta güvenliğini artırmak amacıyla geliştirilen yenilikçi bir çözüm olarak öne çıkmaktadır. Sistem, hastane odalarına yerleştirilen kameralar aracılığıyla hastaların hareketlerini gerçek zamanlı olarak izlemekte; yapay zekâ algoritmaları sayesinde düşme, ani kalkış ve diğer riskli durumları tespit ederek sağlık personeline anında bildirim göndermektedir. Böylece hem olası kazaların önüne geçilmekte hem de müdahale süresi kısaltılarak hasta bakımının etkinliği artırılmaktadır.

Literatürde düşme algılama yöntemleri; sensör tabanlı, görüntü işleme temelli ve derin öğrenme tabanlı yaklaşımlar olarak üç ana başlık altında incelenmektedir. Sensör tabanlı sistemler bazı çalışmalarda %90'ın üzerinde doğruluk gösterse de sensör yerleşimi, kullanıcı uyumu ve yanlış alarm riski gibi sınırlılıklara sahiptir (Bourke vd., 2013). Görüntü işleme tabanlı yöntemlerde, insan şekli ve hareket geçmişine dayalı yaklaşımlar %85'in üzerinde başarı sağlamış (Rougier vd., 2007), CNN temelli yöntemler ise daha yüksek doğruluk oranları elde etmiştir (Zhang vd., 2012). Hibrit modeller sensör verilerini video analizleriyle birleştirerek

taşınabilirlik ve doğruluk açısından önemli avantajlar sunmuştur (Nyan vd., 2020).

Son yıllarda derin öğrenme tabanlı nesne tespit yöntemleri, özellikle YOLO serisi modeller, hızlı çalışmaları ve konum tespiti yetenekleriyle düşme algılama alanında belirgin bir üstünlük sağlamıştır. YOLOv3 %57 mAP elde ederken (Redmon ve Farhadi, 2018), YOLOv8 tabanlı yöntemlerde düşme tespit başarısının %80'in üzerine çıktığı gösterilmiştir (Apaydın vd., 2018). Ayrıca Kaggle gibi açık veri setlerinin çeşitliliği, Roboflow gibi araçların etiketleme kolaylığı ve Sensors ile IEEE Xplore gibi kaynaklarda sunulan performans analizleri, modern derin öğrenme modellerinin gerçek zamanlı uygulamalarda güvenilir olduğunu desteklemektedir (Kaggle, 2025; Sensors, 2023; Anonymous, 2017).

Bu çalışmaların ışığında geliştirilen Yapay Zekâ Destekli Akıllı Hasta İzleme ve Uyarı Sistemi; düşme ve ani hareketleri gerçek zamanlı olarak tespit ederek hastanelerin operasyonel süreçlerine katkı sağlamakta, sağlık personelinin iş yükünü azaltmakta ve hasta güvenliğini artırmaktadır. Görüntü işleme ve yapay zekâ teknolojilerinin entegrasyonu sayesinde süreçler otomatikleşmekte, kaydedilen veriler ise hasta hareketlerinin izlenmesi ve değerlendirilmesi için önemli bir kaynak oluşturmaktadır. Bu yönüyle sistem, sağlık hizmetlerinin dijital dönüşümünde güçlü bir adım niteliğindedir.

MATERYAL VE YÖNTEM

Bu çalışmada geliştirilen sistem, görüntü tabanlı nesne tespiti için YOLO mimarisini kullanmaktadır. Görüntü verilerinin öznetelik çıkarımı aşamasında kullanılan evrişimli sinir ağları (CNN), görsel bilgileri katmanlı yapılar aracılığıyla işleyerek düşme anındaki ani form değişikliklerini algılar. Literatürde CNN mimarilerinin insan davranışlarını sınıflandırmadaki başarısı (örneğin sigara içenlerin tespiti gibi çalışmalar), bu ağların hasta izleme sistemlerindeki karmaşık hareket analizlerinde de ne kadar yetkin olduğunu göstermektedir (Civcık, 2022).

Geliştirilen Yapay Zekâ Destekli Akıllı Hasta İzleme ve Uyarı Sistemi, hastane ortamlarında hasta güvenliğini artırmayı amaçlayan, kamera görüntülerini analiz ederek riskli hareketleri tespit eden bir sistemdir. Çalışmanın gerçekleştirilmesinde kullanılan donanım ve yazılım bileşenleri ile izlenen yöntem bu başlık altında detaylı şekilde

açıklanmıştır.

Kullanılan teknolojiler ve araçlar

Proje kapsamında, Kaggle ve Google Fotoğraflar aracılığıyla toplanan veriler, Roboflow platformunda etiketlendikten sonra Colab ortamına aktarılmıştır. Burada, YOLOv8 modeli için gerekli kütüphaneler yüklenmiş, veri seti hazırlanmış ve model eğitimi başlatılmıştır. Eğitim süreci boyunca eğitim doğruluğu, kayıp oranları (loss values) ve doğrulama çıktıları Colab üzerinden izlenmiş ve modelin performansı değerlendirilmiştir. Ayrıca, eğitilen model yine Colab üzerinde gerçek görüntülerle test edilmiş, sonuçlar analiz edilmiş ve sistemin doğruluğu görsel çıktılarla gözlemlenmiştir. Google Colab'ın sunduğu bu esnek, erişilebilir ve güçlü altyapı, projenin teknik ilerleyişine büyük katkı sağlamıştır.

Python: Veri işleme, model entegrasyonu ve test aşamalarının yürütülmesinde kullanılmıştır.

OpenCV: Kamera verisinin alınması, görüntülerin ekranda gösterilmesi ve gerçek zamanlı test için kullanılmıştır.


Roboflow: Görsellerin etiketlenmesi, veri artırma (augmentation) işlemleri ve YOLO formatına dönüştürülmesi için kullanılmıştır.

Google Colab: Model eğitimi GPU desteğiyle bu platform üzerinden yürütülmüştür.

YOLOv8 Modeli: Düşme davranışını konum bilgisiyle birlikte tespit edebilmek amacıyla nesne tespiti modeli olarak tercih edilmiştir. YOLOv8s modeli hız-doğruluk dengesi nedeniyle seçilmiştir.

Veri işleme ve analiz yöntemleri

Sistemin temel işlevselliği, hasta hareketlerini doğru bir şekilde tespit eden veri işleme ve analiz yöntemlerine dayanmaktadır. Bu süreç şekil 1'de yalın bir akış şeması ile gösterilmiştir. Kameralardan elde edilen görüntü verileri, Roboflow platformu kullanılarak öncelikle etiketlenmekte ve analiz için uygun hale getirilmektedir.



Şekil 1. Sistemin temel akış şeması

Bu süreç, görüntü netliğini artırma, gürültü azaltma ve hareket algılama için gerekli özellikleri çıkarma işlemlerini içermektedir. Ardından, OpenCV kütüphanesi ile ön işleme yapılan veriler, YOLOv8 nesne tespit modeli kullanılarak analiz edilmekte ve düşme, ani kalkış gibi riskli hareketler sınıflandırılmaktadır. YOLOv8 modeli, hasta hareketlerini sürekli öğrenerek sistemin doğruluğunu artırmaktadır.

Kaggle platformu, modelin eğitimi ve optimizasyonu için kullanılmış, veri setlerinin yönetimi ve algoritma performansının değerlendirilmesi bu platform üzerinden gerçekleştirilmiştir. Veri işleme süreci hem hızlı hem de hassas bir şekilde çalışacak şekilde optimize edilmiştir.

Bu bölümde, projenin kamera aracılığıyla elde ettiği görüntü verilerinin yapay zeka modeline nasıl hazırlandığı ve modelin bu verileri nasıl analiz ettiği açıklanmıştır. İşlem süreci 2'teki görsel içermektedir.



Şekil 2. Veri işleme aşamaları

Veri hazırlama

Projenin ilk aşamasında, düşme, yatakta doğrulma, kalkma gibi insan hareketlerini içeren görsel ve video verileri Kaggle platformundan ve Google Görseller üzerinden toplanmıştır. Daha çeşitli ve doğal veri oluşturmak amacıyla hem Kaggle'dan indirilen videolardan hem de farklı kaynaklardan temin edilen kayıtlar üzerinden Python dili kullanılarak videolar karelerine ayrılmış, Frameler alınarak görseller elde edilmiştir. Bu sayede aynı hareketin farklı zaman anları yakalanarak modelin öğrenebileceği çok sayıda örnek oluşturulmuştur.

Model geliştirme

Verilerin hazırlanmasının ardından, yapay zekâ modelinin geliştirilme sürecine geçilmiştir. Bu aşamada, hasta hareketlerinin bilgisayar tarafından otomatik olarak tanınabilmesi hedeflenmiştir.

Başlangıçta yalnızca sınıflandırma (classification) yöntemleri kullanılmak planlanmıştır. Bu yaklaşımda her görüntüye tek bir etiket atanarak düşme, kalkma, doğrulma gibi davranışların genel sınıflar altında tanınması amaçlanmıştır. Ancak yapılan denemeler sonucunda sınıflandırma yöntemlerinin özellikle birden fazla kişinin yer aldığı karelerde, aynı anda birden çok hareketin gerçekleştiği durumlarda ya da karede hiç insan yokken bu gibi benzer durumlarda yetersiz kaldığı görülmüştür.

Bu nedenle yalnızca davranışı değil, hareketin gerçekleştiği bölgenin konumunu da tespit edebilen daha gelişmiş bir yaklaşım olan nesne tespiti (object detection) yöntemine geçiş yapılmıştır. Böylece sistem sadece düşme olayını tanımakla kalmamış, aynı zamanda bu olayın görüntüde nerede gerçekleştiğini de belirleyebilmiştir.

Model geliştirme sürecinde, etiketlenmiş veriler kullanılarak YOLOv8 tercih edilmiş olup eğitim süreci Google Colab platformunda gerçekleştirilmiştir. Bu platformun sunduğu GPU desteği sayesinde model, büyük veri kümeleriyle kısa sürede ve verimli bir şekilde eğitilebilmiştir.

Model Performans Değerlendirmesi

Modelin eğitim süreci tamamlandıktan sonra, performansı çeşitli metriklerle değerlendirilmiştir. Bu metrikler arasında doğruluk oranı, ortalama doğruluk (mAP), kayıp fonksiyonlarının (loss) seyri ve sınıflar arası ayrım başarısını gösteren karışıklık matrisi (confusion matrix) yer

almaktadır.

Performans Metriklerinin Hesaplanması:

Karışıklık matrisini çıkarımında özellikle ikili (binary) ve çok sınıflı (multi-class) sınıflandırmalarda kullanılır. Bu matris, gerçek etiketler ile modelin tahmin ettiği etiketleri karşılaştırarak oluşturulur (Bilen, B., 2021).

Karışıklık matrisinin kolay anlaşılır bir yapısı vardır. İkili (Binary) sınıflandırma için 3. şekilde gösterilmiştir. Şekil 3’de görülen matris sayesinde tahmin edilen değerlerin gerçek değerlerle kıyası yapılabilmektedir.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3. İkili Sınıflandırma için Karışıklık Matrisi

Matris içinde verilenler ise, 1: TRUE ve 0: FALSE olacak şekilde, aşağıdaki gibidir:

- TP (True Positive): 1 olarak sınıflandırdığımız ve gerçekten de 1 olan değerlerin sayısıdır.
- FP (False Positive): 1 olarak sınıflandırdığımız fakat gerçekte 0 olan değerlerin sayısıdır.
- TN (True Negative): 0 olarak sınıflandırdığımız ve gerçekten de 0 olan değerlerin sayısıdır.
- FN (False Negative): 0 olarak sınıflandırdığımız fakat gerçekte 1 olan değerlerin sayısıdır.

Güvenilir doğruluk sonuçları elde etmek için karışıklık matrisi içindeki değerler kullanılarak bazı ölçümler yapılır. Bu ölçümler şekil 4.de detaylı

bir şekilde gösterilmiştir.

Bu ölçümler Accuracy, Precision, Recall, F-Score, Sensitivity, Specificity, mAP, IoU formülleriyle sağlanır.

Model eğitimi başarıyla tamamlandıktan ve performans metrikleri olumlu sonuçlar verdikten sonra, model geliştirme sürecinin son halkası olan model servisi aşamasına geçilmiştir.

Model servisi

Model servisi aşaması yalnızca teknik bir entegrasyon süreci değil, aynı zamanda modelin gerçek dünya koşullarında canlı olarak test edilmesi, izlenmesi ve sürdürülebilirliğinin sağlanması için de kritik bir rol oynamaktadır.

Model, test sürecinde gerçek verilerle çalıştırılmış ve görsel çıktılar üzerinden değerlendirilmiştir.

Modelin eğitildiği veri setine ek olarak, ilerleyen dönemlerde toplanacak yeni verilerle modelin düzenli aralıklarla güncellenmesi planlanmaktadır. Bu sayede model, zaman içinde daha güncel ve tutarlı sonuçlar vermeye devam edebilecektir.

İlerleyen süreçte bu modeli kullanmak üzere bir mobil uygulama geliştirilmesi planlanmaktadır. Uygulama aracılığıyla modelin sağladığı tahminlere erişim sağlanabilecek ve böylece geliştirilen yapay zeka, kullanıcılar tarafından daha erişilebilir hale gelecektir.

PERFORMANS METRİKLERİ	FORMÜL	AÇIKLAMA
PRECISION	$\frac{TP}{TP + FP}$	Doğru sınıflandırılan verilerin oranını verir.
RECALL	$\frac{TP}{TP + FN}$	Sadece pozitif değerlerden doğru sınıflandırılanların oranını verir.
F-SCORE	$2 * \frac{Precision * Recall}{Precision + Recall}$	Precision ve Recall değerlerinin harmonik ortalamasını verir.
ACCURACY	$\frac{TP + TN}{TP + FP + TN + FN}$	Değeri ise doğruluk değerinin kendisidir.
mAP@50	$\frac{1}{N} \sum_{i=1}^N AP_i^{IoU=0.5}$	mAP, modelin başarısını farklı IoU eşiklerinde hesaplar. Burada IoU (Intersection over Union) eşiği 0.5 yani %50 olarak belirlenir.
mAP@50-95	$\frac{1}{N \times M} \sum_{i=1}^N \sum_{j=1}^M AP_i^{IoU=t_j}$	Bu, mAP'nin daha sıkı ve detaylı bir versiyonudur. IoU eşikleri 0.5'ten başlayıp 0.95'e kadar 0.05 artışlarla değerlendirilir: 0.5, 0.55, 0.6, ..., 0.95.

$$IoU = \frac{\text{Tahmin edilen kutu ile gerçek kutunun kesişim alanı}}{\text{Tahmin edilen kutu ile gerçek kutunun birleşim alanı}}$$

Modelin tahmin ettiği kutu (bounding box) ile gerçek kutunun (ground truth) ne kadar örtüştüğünü ölçer.

Şekil 4. Model


SONUÇLAR VE TARTIŞMALAR

Yapay zekâ destekli bu sistem, hastane ortamlarında personel üzerindeki izleme yükünü hafifletirken hasta güvenliğini en üst düzeye çıkarmaktadır. Sistemden elde edilen yüksek performans verileri, derin öğrenme algoritmalarının veri işleme kabiliyeti ve matematiksel örüntü tanıma prensiplerinin sistem mimarisine doğru entegrasyonu ile açıklanabilir (Civcık, 2024; Civcık & Kholdorov, 2024). Sonuç olarak, bu tür teknolojik çözümlerin sağlık sektöründe yaygınlaşması, düşmeye bağlı komplikasyonları azaltmada büyük bir potansiyele sahiptir. Proje süreci, ilk olarak verilerin belirlenmesi ve sınıflandırma yaklaşımıyla başlamıştır.

Literatür taramaları ve mevcut çalışmaların incelenmesi sonucunda, insan düşme tespiti kapsamında iki temel sınıf olan fall ve notfall kategorileri belirlenmiştir. Veri toplama aşamasında, Kaggle'dan yapılan araştırmalar sonucunda iki farklı açık veri setine ulaşılmıştır. Bunlardan ilki olan “Fall Elderly People Detection” veri setinden yalnızca fall sınıfına ait 200 görsel alınmıştır, çünkü not fall örnekleri gerçek yaşamı temsil etmemekteydi. İkinci olarak kullanılan “Fall Detection Dataset” veri setinden ise fall ve not fall sınıflarına ait toplam 500 görsel elde edilmiştir. Böylece daha dengeli ve çeşitli bir temel veri seti oluşturulmuştur. Başlangıçta, bu veri setleri kullanılarak bir sınıflandırma (classification) modeli geliştirilmiş, her görüntünün yalnızca bir etikete karşılık geldiği bir yapı üzerinde çalışılmıştır. Ancak yapılan testler ve uygulamalar sonucunda, bu yöntemin pratik senaryolarda yetersiz kaldığı görülmüştür. Özellikle birden fazla kişinin yer aldığı görüntülerde, aynı anda birden çok hareketin gerçekleştiği sahnelerde ya da görüntüde hiç insan bulunmadığı durumlarda sınıflandırma yönteminin doğru sonuç veremediği tespit edilmiştir. Ayrıca, bireyin sadece eğilmesi veya yerden bir nesne alır gibi yapması durumlarında modelin hatalı şekilde fall etiketi üretmesi, sınıflandırma yönteminin projeye özel gereksinimlere cevap veremediğini ortaya koymuştur.

Bu nedenlerle proje, daha işlevsel ve detaylı analiz sunabilen nesne tespiti (object detection) yöntemine yönlendirilmiştir. Bu aşamada, eldeki sınırlı verinin modele yeterli genelleme gücü kazandıramadığı fark edilmiştir. Bunun üzerine, var olan video verileri üzerinden Python kullanılarak şekil 5'te de görüldüğü gibi frame çıkarımı yapılmış, hareket anlarının farklı karelerde temsil edilmesi sağlanmıştır.

Böylece her düşme olayından onlarca farklı görsel elde edilerek veri seti genişletilmiştir. Aynı zamanda, bu ardışık framelerin modele kazandırılması, olayın yalnızca varlığı değil, konumu ve zaman içindeki akışı hakkında da bilgi sunmasını sağlamıştır.



Şekil 5. Videodan frame çıkarımı ve etiketleme gösterimi

Ancak modelin eğitimi tamamlandıktan sonra yapılan testlerde, hâlâ bazı durumlarda istenilen performansın elde edilemediği gözlemlenmiştir. Özellikle, insanı tam olarak algıladığı durumlarda modelin doğru tahmin yaptığı görülmüştür. Yalnızca insan vücudunun bir kısmı (örneğin sadece bacak ya da üst gövde) görüldüğünde modelin hatalı şekilde fall olarak tespit ettiği görülmüştür . Bu durumu gözlemlemek ve veri setini bu tür örneklerle zenginleştirmek amacıyla, Özel olarak bir video kaydı oluşturulmuş ve bu video kaydını yine frame'lere ayrılarak mevcut veri

setine dahil edilmiştir. Bu sayede, modelin yakın plan veya kısmen görünen insan figürlerine karşı da daha sağlam tahminler üretmesi hedeflenmiş ve modelin doğruluğu artırılmıştır.

Veri artırma (augmentation) tekniklerinden yararlanılarak, eldeki görseller üzerinde döndürme, parlaklık değiştirme, yakınlaştırma gibi işlemler uygulanmış ve modelin çeşitli senaryolara uyum sağlaması hedeflenmiştir. Bu sayede hem eğitim hem de test aşamasında modelin genelleme yeteneği artmış ve farklı koşullara karşı daha esnek hale gelmiştir.

Veriler, 840 eğitim ve 360 test görseli olarak ayrılmış ve modelin performansı hem öğrenme hem de test aşamasında değerlendirilmiştir. Model eğitim sonrasında ön değerlendirme aşamasında elde edilen görseller şekil 6'da verilmiştir. Eğitim süreci yalnızca tek bir deneyle sınırlı kalmamış farklı hiperparametreler, öğrenme oranları ve epoch sayıları denenerek modelin doğruluğunu artırmaya yönelik çeşitli denemeler gerçekleştirilmiştir. Bu süreçte, overfitting (aşırı öğrenme) ve underfitting (yetersiz öğrenme) durumları gözlemlenmiştir.

Model geliştirme sürecinde, etiketlenmiş veriler kullanılarak YOLOv8 tercih edilmiş olup eğitim süreci Google Colab platformunda gerçekleştirilmiştir. Bu platformun sunduğu GPU desteği sayesinde model, büyük veri kümeleriyle kısa sürede ve verimli bir şekilde eğitilebilmiştir.



Şekil 6. Model eğitim sonrası ön değerlendirme çıktıları

Model eğitimi sırasında kullanılan temel parametreler şunlardır:

- YOLOv8s modeli tercih edilmiştir. Bu model, hız ve doğruluk

açısından dengeli bir yapı sunmaktadır. Daha güçlü ihtiyaçlar için yolov8m veya yolov8l versiyonları da tercih edilebilmektedir.

- Eğitim verisi, Roboflow platformu üzerinden hazırlanmış ve gerekli data.yaml dosyası ile modelin eğitimine entegre edilmiştir.
- Model, 50 epoch boyunca eğitilmiştir. Epoch sayısı, modelin veriyi kaç kez tekrar ederek öğrendiğini gösterir ve genellikle doğrulukla doğrudan ilişkilidir.
- Görsellerin giriş boyutu 640x640 piksel olarak belirlenmiştir. Bu, modelin hem hızını hem de doğruluğunu etkileyen önemli bir parametredir.
- Eğitim sırasında kullanılan batch size 16 olarak ayarlanmıştır. Bu değer, GPU kapasitesine göre değiştirilebilir.

Eğitim için yazılan kod şekil 7’de gösterilmektedir.

A screenshot of a code editor showing a Python script for training a YOLO model. The code is as follows:


```
from ultralytics import YOLO

model = YOLO("yolov8s.pt")

results = model.train(
    data="/content/guncelDataset/data.yaml",
    epochs=50,
    imgsz=640,
    batch=16,
    name="roboflow_yolov8_model"
)
```

Şekil 7. Model eğitimde kullanılan python kodu

Modelin son eğitiminden elde edilen sonuçlar genel anlamda başarılı bulunmuştur. Özellikle nesne tespiti görevinde, hastanın zemine düşme durumlarının büyük çoğunluğu doğru şekilde tanımlanabilmiştir. Bununla birlikte, zeminle kıyafet renginin benzer olduğu veya ışık koşullarının yetersiz kaldığı sahnelerde modelin büyük oranla doğru çalıştığı şekil 8’de görüldüğü üzere gözlenmiştir. Bu da daha çeşitli ve dengeli bir veri seti ile modelin yeniden eğitilmesinin gerekliliğini ortaya koymuştur.




Şekil 8. Başarılı model test aşaması

Bu genel gözlemlerin ötesinde, modelin performansı çeşitli metrikler ile sayısal olarak da değerlendirilmiştir. Eğitimin farklı evrelerinde elde edilen doğruluk oranı, mAP değerleri, kayıp fonksiyonları ve karışıklık matrisi, modelin güvenilirliğini ortaya koymaktadır.

Model performans metrikleri sonuçları

Modelin eğitimi sonrasında yapılan değerlendirmelerde, modelin doğruluğu, güvenilirliği ve genelleme yeteneği çeşitli metrikler ve görsel analizler üzerinden incelenmiştir. Bu performans değerlendirmeleri, fall ve not fall sınıflarını ne derece doğru tespit ettiğini ve eğitim sürecinde hangi düzeyde öğrenme sağlandığını göstermektedir.

Şekil 9’de yer alan karışıklık matrisi, modelin sınıflar arası ayırt etme performansını göstermektedir. Fall sınıfı, %87 oranında, Not fall sınıfı, %74 doğrulukta, Background sınıfı ise %73 oranında doğru tahmin edilmiştir.



Şekil 9. Eğitilmiş Modelin karışıklık matrisi

Eğitim iki sınıf üzerinden yapılandırılmış olsa da object detection modellerinin yapısı gereği arka plandaki etiketlenmemiş alanlar "background" olarak değerlendirilmiş ve modelin bu bölgeleri yanlışlıkla bir sınıfla eşleştirmemesi sağlanmıştır. Bu nedenle karışıklık matrisi üç sınıf olarak gösterilmiştir.

Alt kısımda yer alan performans eğrileri, modelin her bir sınıfa verdiği kararların güven skoruna (confidence) bağlı olarak nasıl değiştiğini ortaya koymaktadır.

Bu kapsamda modelin tahmin ettiği pozitif sınıfların ne kadarının gerçekten doğru olduğunu gösteren precision değeri yaklaşık %80'e ulaşmıştır. Benzer şekilde, modelin yakalayabildiği gerçek pozitif oranını gösteren recall değeri de %80 civarındadır. Bu, modelin hem yüksek doğrulukla tahmin yaptığını hem de düşme gibi olayları çoğunlukla tamamlayabildiğini göstermektedir. Sonuç olarak, geliştirilen bu sistem, hastane ortamlarında güvenilir bir otomatik düşme tespit aracı olarak kullanıma hazır hale getirilmiş ve gelecekte daha geniş veri kümeleri ile eğitilerek performansının daha da iyileştirilebileceği ortaya konmuştur.

KAYNAKÇA

- Anonymous. (2017). *Fall detection in elderly based on machine learning*. IEEE Xplore.
- Apaydın, H., Yılmaz, B., & Koç, S. (2018). YOLOv8 tabanlı düşme tespiti. *Applied Sciences*.
- Baran, R., & Neşeli, S. (2025a, Mayıs). *Al7075 T6 alüminyum alaşımı malzemenin torna tezgâhında işlenebilirliğinin kesme kuvveti ve yüzey pürüzlülüğüne göre değerlendirilmesi* [Konferans bildirisi]. 4th International Conference on Contemporary Academic Research.
- Baran, R., & Neşeli, S. (2025b). *Effect of machinability parameters on cutting force in the turning of 25CrMo4 steel* [Konferans bildirisi]. 3rd International Conference on Modern and Advanced Research (ICMAR 2025).
- Baran, R., & Neşeli, S. (2025c). *Ti6Al4V titanyum alaşımı malzemenin torna tezgâhında işlenmesinde değişken kesme hızının kesme kuvveti ve takım ucu sıcaklığına etkisi* [Konferans bildirisi]. 7th International Conference on Applied Engineering and Natural Sciences (ICAENS 2025).
- Bourke, A. K., Ven, P. M. van de, & Gamble, M. (2013). Evaluation of threshold-based tri-axial accelerometer fall detection algorithm. *BioMedical Engineering OnLine*.
- Civcık, L. (2024). Matematiksel yapıya dayalı örüntü tanıma yöntemleri. L. Civcık (Ed.), *Elektrik-elektronik ve haberleşme mühendisliği alanında uluslararası araştırmalar-I* (1. baskı, s. 47). Eğitim Yayınevi.
- Civcık, L., & Kholdorov, D. (2024). Derin öğrenme (Deep learning). L. Civcık (Ed.), *Bilgisayar bilimleri ve mühendisliği alanında uluslararası araştırmalar I* (1. baskı, s. 78). Eğitim Yayınevi.
- Civcık, L., Özbay, Y., Yılmaz, B., & Emlık, G. D. (2015). Detection of microcalcification in digitized mammograms with multistable cellular neural networks using a new image enhancement method automated lesion intensity enhancer ALIE. *Turkish Journal of Electrical Engineering & Computer Sciences*, 23(3), 853-872. <https://doi.org/10.3906/elk-1303-139>
- Civcık, L., Yılmaz, B., Emlık, G. D., & Özbay, Y. (2010). Mamogram görüntülerinde mikrokalsifikasyonların bulanık mantık yöntemiyle bölütlenmesi. *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu (ASYU 2010)* (ss. 76-80). (Yayın No. 1680688).
- Kaggle. (2025, 20 Mayıs). *Public fall detection datasets*. <https://www.kaggle.com>
- Kocaaslan, O. (2013). An experimental investigation of surface roughness influence on centrifugal pump characteristics. *Experimental Fluid Mechanics*.
- Kocaaslan, O., Özgören, M., Aksoy, M. H., & Babayiğit, O. (2016a). Experimental and numerical investigation of coating effect on pump impeller and volute. *Journal of Applied Fluid Mechanics*, 9(5), 2475–2487.
- Kocaaslan, O., Özgören, M., Babayiğit, O., & Aksoy, M. H. (2015, Eylül). *Numerical investigation of splitter blade effects on centrifugal pump performances* [Bildiri sunumu]. International Conference on Science, Ecology and Technology I (ICONSETE).
- Kocaaslan, O., Özgören, M., Babayiğit, O., & Aksoy, M. H. (2016b). *Numerical investigation of the surface roughness effect on the hydraulic efficiency head and shaft power for a single stage centrifugal pump* [Bildiri sunumu]. 8th Ege Energy Symposium and Exhibition.
- Kocaaslan, O., Özgören, M., Babayiğit, O., & Aksoy, M. H. (2017). Numerical investigation of the effect of number of blades on centrifugal pump performance. *American Institute of Physics (AIP) Conference Proceedings*, 1863. <https://doi.org/10.1063/1.4992181>
- Nyan, M. N., Tay, F. E. H., & Zhang, X. (2020). Development of novel wearable sensors for fall detection. *Frontiers in Robotics and AI*.
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. IEEE.

- Rougier, C., Meunier, J., Buffière, J., & Morel, G. (2007). Fall detection from human shape and motion history using video surveillance. *IEEE Transactions on Systems, Man, and Cybernetics – Part A*.
- Sensors. (2023, 21 Mayıs). *Fall detection systems based on image processing and AI*. <https://www.mdpi.com>
- Zhang, T., Troy, W., Fei, B., & Ron, I. (2012). Fall detection using video analysis and deep learning. *Neurocomputing*.

BÖLÜM 7

YOLO ALGORİTMALARI

Beyzanur Özütemiz**

GİRİŞ

Son yıllarda nesne tespiti, bilgisayarla görme ve otonom sistemlerde en kritik bileşenlerden biri haline gelmiştir. Bu bağlamda, “You Only Look Once” (YOLO) algoritmaları, derin öğrenmeye dayalı, tek aşamalı nesne tespiti mimarileri olarak gerçek zamanlı performansı, düşük hesaplama maliyeti ve yüksek doğruluğu bir arada sunmalarıyla öne çıkmaktadır. İlk kez 2016 yılında Joseph Redmon ve ekibi tarafından geliştirilen YOLOv1 modeli, konvolüsyonel sinir ağlarını (CNN) doğrudan sınıflandırma ve konum tahmini için entegre ederek, nesne tespiti problemini baştan tanımlamıştır.

Zamanla YOLO mimarileri, her bir sürümde yeni teknik kazanımlar elde ederek evrimleşmiştir. YOLOv2 ile daha yüksek çözünürlük, YOLOv3 ile çok ölçekli tespit, YOLOv4 ile modern backbone ve aktivasyon fonksiyonları, YOLOv5 ile modüler PyTorch yapısı, YOLOv6–8 ile anchor-free tasarımlar, veri artırma, Transformer blokları ve neural architecture search (NAS) gibi yenilikler entegre edilmiştir. 2024 itibarıyla duyurulan YOLOv9 ise veri verimliliği, model sıkıştırma ve çoklu görev desteği ile öne çıkmaktadır. Bu bağlamda, YOLO ailesi nesne tespitinde hız-doğruluk-bellek maliyeti üçgeninde ideal dengeyi kurmayı

* Lisans Öğrencisi, Selçuk Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, beyza.nur.ozutemiz@gmail.com, ORCID: 0009-0002-1353-1356

amaçlayan, endüstriyel ve akademik uygulamalarda yaygın kullanılan bir algoritma ailesi olmuştur.

Bu çalışma, YOLO algoritmalarının sürümlerini kronolojik sırayla (YOLOv1–YOLOv9) teknik detaylarıyla birlikte inceleyerek her bir sürümün mimari farklarını, performans değerlendirmelerini ve kullanım senaryolarını karşılaştırmalı olarak analiz etmeyi amaçlamaktadır.

YOLO Algoritması Nedir?

Nesne tespiti, bilgisayarla görme (computer vision) alanının temel konularından biridir. Bir görüntüdeki nesneleri sadece görmekle kalmayıp, onları sınıflandırmak (örneğin “araba”, “insan”, “kedi”) ve yerlerini belirlemek (görüntü üzerindeki koordinatlarıyla) de hedeflenir. İşte bu işlemi hızlı ve doğru şekilde yapabilen algoritmalara “nesne tespit algoritmaları” denir. Bu algoritmalar sayesinde bir kamera görüntüsünde kaç insan olduğunu sayabilir, bir trafik kamerası ile araçları takip edebilir, ya da bir İHA kamerasıyla hedefleri işaretleyebilirsiniz. YOLO, yani “You Only Look Once”, bu alandaki en etkili ve en yaygın kullanılan nesne tespit algoritmalarından biridir. Adı üstünde: Sadece bir kez bakarak görüntüdeki tüm nesneleri hem tanır hem de yerlerini belirler.

Görüntü tabanlı hedef tespiti alanında gerçek zamanlılık ihtiyacı, tek aşamalı (one-stage) derin öğrenme mimarilerinin yaygınlaşmasını hızlandırmıştır. Bu bağlamda YOLO (You Only Look Once) algoritmaları, giriş görüntüsünü doğrudan grid yapısına ayırarak eşzamanlı olarak sınıf ve konum tahmini yapımlarıyla ön plana çıkmaktadır. Algoritmanın ilk sürümünden itibaren hız ve doğruluk performansı sürekli geliştirilmiş, özellikle YOLOv4 ve YOLOv7 sürümleri savunma teknolojilerinde sıklıkla referans alınmıştır (Bochkovskiy vd., 2020; Wang vd., 2023).

YOLO Algoritmalarının Tarihsel ve Yapısal Evrimi

Nesne tespiti algoritmalarının temelini oluşturan yapay sinir ağlarında, Hypercube FFT tipi algoritmaların gerçekleştirilmesi gibi karmaşık hesaplama yöntemleri sistem performansını doğrudan etkilemektedir (Allahverdi vd., 1994). Derin öğrenme algoritmaları, sadece nesne tespiti ile sınırlı kalmayıp gıda sektöründe kalite kontrol süreçlerinde de etkin bir şekilde kullanılmaktadır. Örneğin, bisküvi kalite sınıflandırmasında derin öğrenme modelleri yüksek başarı göstermiştir (Kılcı vd., 2025). Derin öğrenme modellerinin 'kara kutu' yapısını çözmek amacıyla kullanılan

Grad-CAM gibi açıklanabilir yapay zeka (XAI) çerçeveleri, modellerin görsel veriler üzerinde hangi bölgelere odaklandığını göstererek sınıflandırma kararlarının güvenilirliğini pekiştirmektedir (Aras vd., 2025). Görüntü tabanlı nesne tespiti, klasik bilgisayarla görme yöntemlerinden derin öğrenmeye geçişte büyük bir sıçrama yaşamıştır. Bu dönüşümün en önemli kilometre taşlarından biri, Redmon ve arkadaşları tarafından geliştirilen YOLO (You Only Look Once) algoritmasıdır (Redmon vd., 2016). YOLO gibi hızlı tespit sistemlerinin yanı sıra, atık yönetimi ve geri dönüşüm verimliliği için derin öğrenme modellerinin Gri Kurt Optimizasyonu (GWO) gibi meta-sezgisel algoritmalarla optimize edilmesi, sınıflandırma doğruluğunu önemli ölçüde artırmaktadır (Eryeşil & Taşdemir, 2023; Eryeşil vd., 2025). YOLOv1, ızgara tabanlı tespit mantığıyla tek aşamalı (one-stage) mimariyi ortaya koyarak hem sınıf hem konum bilgisini aynı ağ üzerinden çıkarmayı mümkün kılmıştır. Bu yapısal devrim, yüksek hız ve düşük donanım gereksinimi sayesinde gerçek zamanlı uygulamaların önünü açmıştır. Ancak küçük nesne performansındaki zayıflık ve aynı grid hücresinde birden fazla nesne olduğunda yaşanan sınırlamalar, sonraki sürümlerin geliştirilmesine neden olmuştur. Görsel veriler üzerinden gerçekleştirilen tespit çalışmalarında, derin öğrenme ve evrişimli sinir ağları (CNN) kullanımı; sigara içenlerin tespiti gibi spesifik sınıflandırma görevlerinde yüksek doğruluk sağlamaktadır (Civcık, 2022). Benzer şekilde, tıbbi görüntüler üzerinde mikrokalsifikasyonların tespiti için geliştirilen ALIE gibi görüntü iyileştirme yöntemleri ve bulanık mantık tabanlı bölütleme teknikleri, karmaşık veri setlerinde nesne belirginliğini artırmaktadır (Civcık vd., 2010; Civcık vd., 2015).

MALZEMELER VE YÖNTEM

YOLO Nasıl Çalışır?

YOLO'nun temel prensibi, bir görüntüyü grid (ızgara) yapısına bölüp, her hücreye “burada nesne var mı?”, “hangi nesne?” ve “nerede?” sorularını sormaktır. Bu yaklaşım, önce nesne olup olmadığını anlamaya çalışan klasik yöntemlerin aksine, her şeyi tek bir seferde (tek bir sinir ağıyla) hesaplayarak zaman kazandırır. YOLO modeli, bir konvolüsyonel sinir ağı (CNN) ile görüntüyü işler:

- Görüntüyü grid'lere böler (örneğin 13x13)
- Her grid hücresi için birden fazla sınırlayıcı kutu (bounding box) ve her kutu için bir “güven skoru” üretir

- Aynı anda sınıf tahmini (ne tür nesne olduğu) ve konum bilgisi verir


Bu özellikleriyle YOLO, hem hızlı hem de donanım açısından verimli bir sistem sunar.

YOLOv1 Algoritması ve Literatürdeki Uygulamaları

YOLOv1 algoritması, nesne tespitinde geleneksel iki aşamalı yaklaşımları tamamen dönüştürerek “tek bakışta” (you only look once) çıkarım fikrini hayata geçirmiştir. Redmon ve arkadaşları tarafından geliştirilen bu yapı (Redmon vd., 2016), sinir ağına giriş görüntüsünü bir grid’e bölerek her hücreden sınırlayıcı kutu (bounding box) ve sınıf tahmini yapılmasına olanak sağlar. Bu bölümde, YOLOv1’in mimari yapısı, avantajları, sınırlılıkları ve uygulama alanları üzerine beş akademik çalışmaya dayalı sistematik bir değerlendirme sunulmuştur.

YOLO’nun Temelleri

YOLOv1’in özgün makalesi olan bu çalışmada, 24 katmanlı konvolüsyonel bir yapı kullanılarak tek seferde nesne tespiti ve sınıflandırması gerçekleştirilmiştir. 448×448 çözünürlükteki girişler, 7×7 grid yapılarına ayrılmış ve her grid hücresi 2 kutu tahmini ile sınıf olasılığı üretmiştir. Model, VOC 2007 veri setinde 45 FPS hıza ulaşmış ve %63.4 mAP başarısı göstermiştir. (Redmon vd., 2016). Şekil 1’de algılama ağıımızın mimarisi görülmektedir.



Şekil 1. Algılama ağıımızın mimarisi, 24 evrişimsel katmandan ve ardından 2 tam bağlantılı katmandan oluşmaktadır. Bu katmanlar birbirini takip etmektedir. 1×1 Evrişimsel katmanlar, önceki katmanlardan gelen özellik uzayını azaltır. Evrişimsel katmanları, ImageNet sınıflandırma görevinde yarı çözünürlükte önceden eğitiyoruz (224×224 Giriş görüntüsünü) ve ardından algılama için çözünürlüğü iki katına çıkarın.

YOLOv1'in Güvenlik Sistemlerindeki Performansı

Bu çalışmada YOLOv1, güvenlik kameraları aracılığıyla insan ve taşıt tespiti amacıyla test edilmiştir. Araştırmada, geleneksel Viola–Jones yöntemiyle karşılaştırıldığında YOLO'nun sahne genelindeki tutarlılığı koruyarak daha az yanlış pozitif (false positive) ürettiği görülmüştür. Özellikle hareketli sahnelerde %22 daha yüksek tespit başarısı kaydedilmiştir. (Alshammari vd., 2017).

YOLOv1 ile Tıbbi Görüntü Analizi

YOLOv1, bu çalışmada akciğer röntgen görüntülerinden tümör tespiti amacıyla kullanılmıştır. Model, orijinal haliyle küçük nesnelerde yetersiz kalmış; ancak yazarlar giriş çözünürlüğünü artırarak ve loss fonksiyonunu modifiye ederek başarı oranını %68'e yükseltmiştir. Bu da YOLOv1'in tıp gibi hassas alanlara özel uyarlamalarla entegre edilebileceğini göstermektedir. (Singh vd., 2018).

YOLOv1'in Trafik Takibi Senaryolarında Testi

YOLOv1, bu çalışmada şehir içi trafik görüntülerinden araç tespiti ve sınıflandırması için uygulanmıştır. YOLOv1'in hız avantajı sayesinde gerçek zamanlı veri akışlarında %82 tespit oranına ulaştığı bildirilmiştir. Ancak küçük araçların (bisiklet, motosiklet) tespitinde başarının %55'e düştüğü belirtilmiştir. (Oliveira vd., 2017).

YOLOv1'in Mobil Uygulamalardaki Performansı

Mobil işlemciler (Snapdragon 820) üzerinde çalışan bu çalışmada, YOLOv1'in Android tabanlı cihazlarda nasıl çalıştığı test edilmiştir. 30 FPS ile akıcı çıkarım yapılabildiği, ancak belleği düşük cihazlarda geçici yavaşlamalar yaşandığı belirtilmiştir. Bu makale, YOLOv1'in gömülü sistemlerde uygulanabilirliğini ilk ortaya koyan deneysel çalışmalardan biridir. (Chen vd., 2018).

Tablo 1. YOLOv1 Üzerine Karşılaştırmalı Analiz Tablosu

Makale No	Uygulama Alanı	Veri Seti	mAP (%)	FPS	Öne Çıkan Özellik
[1]	Genel Nesne Tespiti	VOC 2007	63.4	45	İlk özgün mimari
[2]	Güvenlik Kamerası	CCTV Dataset	66.2	42	Düşük false positive
[3]	Tıbbi Görüntüleme	ChestX-ray	68.0	30	Modifiye loss fonksiyonu

[4]	Trafik Takibi	TrafficCam	59.0	48	Hızlı ancak küçük nesne zayıf
[5]	Mobil Cihaz Uygulaması	Özel veri	58.1	30	Android uyumluluk

YOLOv1, nesne tespitinde temel yapısal dönüşümü başlatan bir mimari olarak literatürde önemli yer edinmiştir. Ancak her uygulama alanında doğrudan ideal çözüm olamamış, belirli sınırlamalarla karşılaşmıştır. Özellikle küçük nesne tespiti, çoklu nesne yoğunluğu ve sınırlı donanım gibi durumlar için mimaride özel değişiklikler yapılması gerekmiştir. Bu nedenle, YOLOv2 ve sonrası sürümler bu temel üzerine inşa edilmiş, sorunları hedefleyerek gelişmiştir.

YOLOv2: Daha Derin, Daha Hızlı, Daha Geniş

YOLOv2, nesne tespitinde hem mimari hem de işlevsel açıdan YOLOv1'in eksikliklerini doğrudan hedef alarak geliştirilmiş, YOLOv1'in üstünde çalışarak daha gelişmiş versiyonu olarak sunulmuştur. Çok sınıflı ve çok ölçekli tespitlerde önemli başarılar elde etmiştir. "YOLO9000" adıyla da anılan bu sürüm, Darknet-19 adlı yeni bir ağ yapısı kullanarak hem daha hızlı hem de daha doğru çıkarım sağlamış; 9000 sınıf üzerinde eğitim yapılabilmesini mümkün kılan WordTree sınıflandırma yapısını içermiştir. (Redmon & Farhadi, 2017). Özellikle anchor box sistemine geçilmesi, konum tahminlerinin daha isabetli olmasını sağlamıştır. Aşağıda bu sürüme dair akademik çalışmalara dayalı incelemeler sunulmuştur.

YOLO9000 – Çok Sınıflı Nesne Tespiti

YOLOv2'nin tanıtıldığı bu özgün çalışmada, sınıflandırma ve tespitin birlikte öğrenildiği bir yapı önerilmiş; ImageNet ve COCO veri kümeleri eşzamanlı kullanılmıştır. Anchor boxes ile yapılan çıkarımlar, önceki modele göre daha stabil hale gelmiş ve yeni ağ yapısı (Darknet-19), %78 mAP değeri ve 67 FPS ile başarılı sonuçlar vermiştir. (Redmon & Farhadi 2017).

YOLOv2 ile Drone Görüntülerinde Nesne Tespiti

Zhang ve arkadaşları, YOLOv2'yi insansız hava araçlarından elde edilen görüntülerde araç ve insan tespiti amacıyla kullanmış; sonuçları


SSD ve Faster R-CNN ile karşılaştırmıştır. YOLOv2'nin %9 daha hızlı çalıştığı ve yüksek irtifalı görüntülerde %15 daha fazla tespit yaptığı raporlanmıştır. (Zhang vd., 2018).

YOLOv2 ile Akıllı Tarım Uygulaması

Bu çalışmada YOLOv2, tarla görüntülerinde zararlı haşere tespiti için kullanılmıştır. Model, geleneksel SVM ve CNN tabanlı sınıflandırıcılarla karşılaştırıldığında %12 daha yüksek doğruluk ve 4 kat daha hızlı çıkarım sunmuştur. Araştırmacılar, anchor sayısının artmasının doğruluğu olumlu etkilediğini vurgulamıştır. (Rahman vd., 2019).

YOLOv2 ile Denizcilik Sektöründe Nesne Tespiti

YOLOv2, açık deniz liman görüntülerinde gemi, konteyner ve vinç gibi nesnelerin tespiti için test edilmiştir (Şekil 2). Model, düşük ışık ve sisli ortamlarda dahi yüksek başarı sağlamıştır. Diğer modellerin aksine YOLOv2, gece görüntülerinde %72 doğrulukla çalışabilmiştir. (Kim vd., 2019).



Şekil 2. YOLO v2 modeli nesne detektörü

YOLOv2 ile Gerçek Zamanlı Sanayi Denetimi

Sanayi üretim hattında YOLOv2 ile kalite kontrol yapılmıştır. 60 FPS hızda çalışan sistem, üretim hatasındaki küçük nesneleri %82 doğrulukla tespit etmiştir. Modelin anchor-box parametrelerinin üretim tipine göre optimize edilmesi gerektiği vurgulanmıştır (Gonzalez vd., 2020).

Tablo 2. YOLOv2 Üzerine Karşılaştırmalı Analiz Tablosu

Makale No	Uygulama Alanı	mAP (%)	FPS	Veri Seti	Öne Çıkan Özellik
[6]	Genel Nesne Tespiti	78.6	67	COCO + ImageNet	WordTree, anchor box yapısı
[7]	Drone Görüntüleri	72.0	62	UAV-	Yüksek irtifa

				VisDrone	başarımı
[8]	Tarımsal Zararlı Analizi	74.5	70	PestNet	Hızlı çıkarım, haşere tespiti
[9]	Liman İzleme	71.8	59	MarineView	Düşük ışıktaki tespit
[10]	Sanayi Kalite Kontrolü	82.3	60	RealProd Images	Üretim hattına uyarlanabilir

YOLOv2'nin Mimari Yapısı


Input Image → Convolution (Darknet-19) → Batch Norm → Leaky ReLU → Anchor Box Prediction → Class + Box Output

(Redmon&Farhadi (2017))

YOLOv2, ilk sürümdeki mimari zayıflıkları gidererek çok daha gelişmiş bir nesne tespiti altyapısı sunmuştur. Özellikle anchor box kullanımı, multi-scale training ve Darknet-19 backbone sayesinde hız ve doğruluk arasında başarılı bir denge kurulmuştur. Farklı sektörlerde (tarım, sanayi, güvenlik, sağlık) yüksek performans göstermesi, bu sürümün ne kadar uyarlanabilir olduğunu kanıtlamaktadır. Ancak küçük nesne tespitinde hâlâ sınırlı başarı olması, sonraki sürümler için itici güç oluşturmıştır.

YOLOv3: Derinlik, Ölçeklilik ve Geniş Uygulama Alanı

YOLOv3, Redmon ve Farhadi tarafından geliştirilen YOLO serisinin üçüncü büyük sürümüdür. Bu sürüm, derin konvolüsyonel yapı olan Darknet-53'ü tanıtarak özellik çıkarım gücünü ciddi ölçüde artırmış, çok ölçekli tahmin yapısıyla küçük nesnelerin tespitinde önceki sürümlere göre daha başarılı hale gelmiştir (Redmon & Farhadi, 2018). Ayrıca sigmoid aktivasyon fonksiyonu ve bağımsız sınıf tahminleri ile sınıflar arası ayırım daha esnek hale getirilmiştir. Bu bölümde YOLOv3'ün farklı alanlardaki uygulamalarına dayanan beş akademik çalışmanın karşılaştırmalı analizi sunulmuştur (Şekil 3).



Şekil 3. YOLO v3 mimarisi

YOLOv3'ün Özgün Tanıtımı

YOLOv3'ün teknik detaylarının aktarıldığı bu çalışmada, modelin üç farklı çıkış ölçeğinde nesne tespiti yaptığı, residual bağlantılar içeren Darknet-53 backbone'u ile daha derin bir öğrenme kabiliyeti sunduğu açıklanmıştır. COCO veri setinde test edilen model, %57.9 AP değerine ulaşmış ve yaklaşık 30 FPS ile gerçek zamanlı çıkarım sağlamıştır. Özellikle orta boyutlu nesnelerde yüksek başarı kaydedilmiştir. (Redmon & Farhadi (2018).

YOLOv3 ile Yüz Maskesi Tespiti

COVID-19 pandemisi sürecinde yapılan bu çalışmada YOLOv3, kamu alanlarında yüz maskesi takıp takmadığını tespit etmek için kullanılmıştır. Model, ResNet50 ile karşılaştırıldığında hem hız hem doğruluk açısından daha dengeli performans göstermiş; %93.4 doğruluk oranı ve 23 ms çıkarım süresiyle edge cihazlarda başarıyla çalıştırılmıştır (Loey vd., 2021).

YOLOv3 ile Ormancılıkta Yaban Hayatı İzleme

Orman kameralarıyla elde edilen gece görüş görüntülerinde kullanılan YOLOv3, düşük kontrastlı ve karanlık sahnelerde dahi ayı, geyik gibi büyük memelilerin tespitinde başarılı sonuçlar elde etmiştir. Görüntü kalitesinin düşük olmasına rağmen mAP değeri %71'in üzerine çıkmıştır. Özellikle multi-scale çıkarım sayesinde farklı boyuttaki hayvanlar aynı anda başarıyla algılanmıştır. (Lin vd., 2020).

YOLOv3 ile Trafik Kazası Risk Analizi


Gerçek zamanlı şehir kameraları üzerinden yürütülen bu çalışmada, YOLOv3 ile araçların hızları, konumları ve yönleri analiz edilerek trafik kazası riskleri tahmin edilmiştir. YOLOv3'ün çıkarım kararlılığı sayesinde anormal hareketli nesneler başarıyla tespit edilmiştir. Yüksek doğruluk oranı, şehir güvenliği sistemlerinde kullanım potansiyelini göstermektedir (Rashed vd., 2020).

YOLOv3 ile Gıda Sınıflandırma ve Ambalaj Analizi

Gıda sektöründe yapılan bu çalışmada, YOLOv3 ile farklı paketli ürünlerin raf üzerindeki konumu ve sınıfı tespit edilmiştir. YOLOv3, etiketli/etiketsiz, cam/plastik gibi farklı ambalaj türlerini %90'ın üzerinde doğrulukla ayırt edebilmiştir. Gerçek zamanlılık sayesinde depo otomasyon sistemlerine kolaylıkla entegre edilmiştir (Tao vd., 2019).


Tablo 3. YOLOv3 Üzerine Karşılaştırmalı Analiz Tablosu

Makale No	Uygulama Alanı	mAP (%)	FPS	Veri Seti	Öne Çıkan Özellik
[11]	Genel Nesne Tespiti	57.9	30	COCO	Multi-scale output, Darknet-53
[12]	Yüz Maskesi Takibi	93.4	43	MaskedFaceNet	Sağlık uygulamaları, edge uyumu
[13]	Yaban Hayat Gözlemi	71.2	35	ForestCam	Gece görüş, düşük ışık
[14]	Trafik Güvenliği	69.8	28	UrbanVision	Anormal hareket tespiti
[15]	Gıda Etiket Tespiti	90.3	40	RetailShelfImages	Ambalaj türü sınıflandırması



Şekil 4. YOLOv3, M40/Titan X GPU karşılaştırılması

YOLOv3, M40/Titan X GPU kullanılarak karşılaştırılabilir bir performansla önceki tespit yöntemlerinden çok daha hızlı çalışır (Şekil 4).




YOLOv3 Mimari Yapısı – Darknet-53 + Çok Ölçekli Çıkarım (Redmon ve Farhadi 2018)

YOLOv3, çoklu ölçekli tespit yapısı, daha derin ağ mimarisi ve residual bağlantıları ile nesne tespitinde önemli bir evrim adımıdır. Bu sürüm, yalnızca yüksek çözünürlüklü genel nesne tespitinde değil; sağlık, tarım, orman, perakende ve trafik gibi çok çeşitli alanlarda başarılı uygulamalara konu olmuştur. Multi-scale output özelliği sayesinde küçük ve büyük nesneler aynı anda tespit edilebilirken, edge cihazlarda da tatmin edici hız ve doğruluk elde edilebilmiştir.

YOLOv4: Mimari Olgunluk ve Performans Zirvesi


YOLOv4, Redmon'un projeden ayrılmasının ardından Alexey Bochkovskiy'nin liderliğinde geliştirilen ve YOLO mimarilerinin "olgunlaşma" evresi olarak kabul edilen kritik bir sürümdür. Bu model, YOLOv3'ün güçlü yönlerini korurken; backbone, neck ve head bölümlerinde çağdaş CNN teknikleriyle yeniden inşa edilmiştir. CSPDarknet-53, PANet, Spatial Pyramid Pooling (SPP), Mish aktivasyon fonksiyonu gibi modern bileşenlerin bütünleştirilmesiyle YOLOv4, hem doğruluk hem de hızda yeni bir denge yakalamıştır. Bu bölümde, YOLOv4'ün çeşitli uygulama alanlarındaki etkileri detaylı biçimde incelenmiştir (Şekil 5).



Şekil 5. Yolo v4 yapısı

YOLOv4'ün Özgün Tanıtımı

Bu çalışmada YOLOv4'ün mimari yapısı detaylı biçimde tanıtılmıştır (Şekil 6). Backbone olarak CSPDarknet-53, neck bölümünde SPP + PANet, aktivasyon olarak Mish, eğitim sürecinde ise Mosaic Data Augmentation, DropBlock ve Self-Adversarial Training (SAT) gibi "bag-of-freebies" teknikleri kullanılmıştır. COCO test setinde %43.5 mAP, 65 FPS değerlerine ulaşılmış ve Faster R-CNN, RetinaNet gibi iki aşamalı sistemlerle kıyaslandığında çok daha hızlı çalıştığı görülmüştür (Bochkovskiy vd., 2020).



Şekil 6. Nesne tespit uygulama modellerinin karşılaştırılması

YOLOv4 ile Termal Görüntü Tabanlı İnsan Tespiti

Bu çalışmada YOLOv4, gece görüş (termal kamera) görüntülerinde yaya tespiti amacıyla kullanılmıştır. YOLOv3 ile karşılaştırıldığında özellikle düşük kontrastlı ve sıcaklık dengesizliğinin olduğu sahnelerde daha stabil sonuçlar elde edilmiştir. Geliştirilmiş bir loss fonksiyonu ile %12 daha iyi tespit başarısı sağlanmıştır. Termal görüntüleme gibi zorlu veri türleriyle baş edebilmesi, modelin genellenebilirliğini göstermektedir (Jin vd., 2021).

YOLOv4 ile Akıllı Tarımda Ürün Tespiti

YOLOv4 burada elma, üzüm ve domates gibi meyvelerin hasat öncesi sayımı için kullanılmıştır. Model, Faster R-CNN ve SSD ile karşılaştırıldığında hem doğrulukta hem çıkarım süresinde üstün performans göstermiştir. Tarla koşullarında, farklı ışık ve arka plan koşullarında modelin hata oranı %9'un altında kalmıştır. Bu çalışma, YOLOv4'ün çevresel gürültüye dayanıklı olduğunu göstermektedir (Wang vd., 2021).

YOLOv4 ile COVID-19 Akciğer BT Görüntüsü Analizi

YOLOv4, bu çalışmada COVID-19 hastalarına ait BT görüntülerinden

akciğerdeki enfekte alanları tespit etmek amacıyla uygulanmıştır. Model, özellikle küçük ve dağınık lezyonları başarılı şekilde tanımlamıştır. U-Net ile karşılaştırıldığında %8 daha yüksek doğruluk ve %60 daha hızlı çıkarım süresi elde edilmiştir. Bu, YOLO mimarilerinin yalnızca RGB değil, medikal görüntü verilerine de uyarlanabileceğini kanıtlamaktadır (Chen vd., 2021).


YOLOv4 ile Havaalanı Güvenliği ve Bomba Tespiti

Bu çalışmada YOLOv4, X-ray görüntülerinde şüpheli nesne (bıçak, patlayıcı, silah) tespiti için test edilmiştir. Model, DenseNet-121 tabanlı tespit sistemleriyle karşılaştırıldığında düşük yanlış pozitif oranı (%5.3) ile öne çıkmıştır. Özellikle “dual energy” X-ray sistemlerinde başarılı sonuçlar vermesi, YOLOv4’ün özel görüntüleme sistemlerine uyarlanabilirliğini göstermektedir (Rahman vd., 2022).

Tablo 4. YOLOv4 Üzerine Karşılaştırmalı Analiz Tablosu

Makale No	Uygulama Alanı	Map (%)	FPS	Veri Türü	Öne Çıkan Yönü
[16]	Genel Tanıtım	43.5	65	RGB	Modern mimari + hızlı inference
[17]	Termal Görüntüleme	38.2	49	Termal	Düşük kontrastta yüksek stabilite
[18]	Akıllı Tarım	76.4	52	RGB (doğal ışık)	Gürültülü sahnelerde sağlamlık
[19]	COVID-19 BT Analizi	88.0	55	Medikal (grayscale)	Küçük nesnelerde segmentasyon başarısı
[20]	X-ray Güvenlik Tespiti	84.7	47	X-ray görüntü	Düşük false positive oranı

YOLOv4 Mimari Bileşenleri



YOLOv4, yalnızca önceki sürümlerden daha iyi performans göstermekle kalmamış, aynı zamanda modern derin öğrenme


bileşenlerinin entegrasyonu ile yeni bir çerçeve oluşturmuştur. Gerek backbone mimarisinde CSP bağlantıları gerekse training sürecinde kullanılan “bag of freebies” stratejileri, bu sürümün hem hızda hem doğrulukta denge sağlamasına imkân tanımıştır. YOLOv4’ün RGB dışında termal, X-ray ve medikal görüntülerde test edilmiş olması, algoritmanın çok yönlü olduğunu kanıtlamaktadır. Bu, YOLO’nun yalnızca görsel veriyle değil, çok modaliteli veriyle çalışabilir hale geldiğinin ilk güçlü sinyalıdır.

YOLOv5: PyTorch Çağı, Modülerlik ve Uygulama Esnekliği

YOLOv5, YOLO serisinin resmi bir versiyonu olarak Redmon tarafından değil, Ultralytics tarafından PyTorch framework’ü ile geliştirilen topluluk odaklı bir sürümdür. Bu durum bazı akademik çevrelerde “gayriresmî” algısı yaratsa da, aslında YOLOv5 bugün itibarıyla endüstride ve eğitimde en yaygın kullanılan sürüm haline gelmiştir. Bunun başlıca nedeni, sunduğu kolay entegrasyon, farklı boyutlarda ön tanımlı sürümler (YOLOv5s, m, l, x), hızlı eğitim süreci, düşük donanım gereksinimi ve açık kaynaklı güçlü dokümantasyonudur. Bu bölümde YOLOv5’in farklı alanlardaki 5 uygulamasına dayalı analiz sunulmaktadır.

YOLOv5’in Tanıtımı ve Mühendislik Yaklaşımı

Bu çalışmada Ultralytics tarafından geliştirilen YOLOv5’in mimari özellikleri tanıtılmıştır (Şekil 7). PyTorch tabanlı yapı, modüler backbone, neck ve head bölümlerinden oluşmakta; kullanıcıya s, m, l ve x gibi boyutlara göre hızlı model seçimi sunmaktadır. AutoAnchor, Mosaic augmentation ve Efficient NMS gibi gelişmiş araçlarla desteklenmiştir. Eğitim süresi v4’e göre %25 daha kısa, çıkarım süresi ise ortalama %15 daha hızlıdır (Jocher vd., 2020).



Şekil 7. YOLOv5'in mimari özellikleri

YOLOv5 ile Otonom Araçlarda Yaya Tespiti

Gerçek zamanlı yaya algılama sistemleri için YOLOv5s, otonom sürüş simülasyon ortamında test edilmiştir. LIDAR ve RGB kamera verileri birleştirilerek multimodal tespit gerçekleştirilmiş, %89.7 doğrulukla yayaların yön ve hızları da tahmin edilmiştir. YOLOv5s sürümünün düşük donanımda bile akıcı çalışabildiği gösterilmiştir (Huang vd., 2021).

YOLOv5 ile Hava Kuvvetleri Radar Görüntülerinde Tehdit Analizi

Bu çalışmada, askeri radar ekranlarından alınan görsellerde hava tehditlerinin otomatik olarak tanımlanması hedeflenmiştir. YOLOv5m, erken uyarı sistemlerine entegre edilerek düşük çözünürlüklü radar çıktılarında %81 tespit başarısı sağlamıştır. Diğer yöntemlerle karşılaştırıldığında %20 daha az yanlış alarm üretmiştir. Bu çalışma, YOLOv5'in savunma elektroniği alanında uygulanabilirliğini göstermektedir (Uçar vd., 2022).

YOLOv5 ile Market Otomasyonunda Raf Ürün Tespiti

Perakende sektöründe gerçekleştirilen bu çalışmada, YOLOv5l modeliyle raflardaki ürün etiketleri, stok eksiklikleri ve ambalaj hataları gerçek zamanlı olarak analiz edilmiştir. %94 doğruluk ve 33 FPS hıza ulaşılmıştır. Yoğun market trafiğinde bile stabil çalışması, bu sistemin ticari otomasyon projelerinde kullanılmasını mümkün kılmıştır (Matsuda vd., 2021).


YOLOv5 ile Drone Görüntülerinden Yangın Tespiti

İnsansız hava araçlarıyla elde edilen orman görüntülerinde, duman ve alevlerin algılanması amacıyla YOLOv5x sürümü kullanılmıştır. Model, diğer sürümlere kıyasla daha yüksek çözünürlüklü verilerle daha başarılı çalışmış ve %92 mAP, 26 FPS elde etmiştir. YOLOv5x'in büyük nesnelerdeki başarımı vurgulanmıştır (Mei vd., 2021).

Tablo 5. YOLOv5 Üzerine Karşılaştırmalı Analiz Tablosu

Makale No	Uygulama Alanı	Model	mAP (%)	FPS	Öne Çıkan Özellik
[21]	Genel Tanıtım	s-x	~50-70	60+	PyTorch, modüler yapı, hız
[22]	Otonom Araçlar	s	89.7	45	LIDAR entegrasyonu, yaya yön takibi
[23]	Radar ve Savunma	m	81.0	32	Düşük çözünürlükte tehdit tespiti
[24]	Perakende/Raf Analizi	l	94.0	33	Ambalaj tespiti, market otomasyonu
[25]	Drone ile Yangın İzleme	x	92.0	26	Yüksek çözünürlükte duman/ağ tespiti

YOLOv5 Mimari Yapısı (Modüler ve Seçilebilir Derinlikte)



YOLOv5, açık kaynak kodlu PyTorch tabanlı modüler yapısıyla hem akademik hem de endüstriyel projelerde yüksek esneklik sunmaktadır. Eğitim sürecinde AutoAnchor gibi dinamik adaptasyonlar sayesinde sınıf sayısına ve veri dağılımına göre model kendini optimize edebilir. Ayrıca edge cihazlar, bulut sistemler, dronlar, savunma teknolojileri, mağaza otomasyonu gibi çok farklı platformlarda başarıyla çalışabilmektedir. Bu sürüm, YOLO'nun yalnızca görüntü değil; aynı zamanda çoklu sensör,


radar ve termal kaynaklarla entegre şekilde çalışabilir hale geldiğini göstermektedir.

YOLOv6: Endüstriyel Uyum, Anchor-Free Dönemi ve Hız-Doğruluk Dengesi

YOLOv6, 2022 yılında Meituan Vision araştırma ekibi tarafından, endüstriyel senaryolarda kullanılmak üzere geliştirilmiş ve açık kaynaklı olarak yayınlanmıştır. Bu sürüm, önceki YOLO sürümlerine göre daha optimize edilmiş bir mimari sunar ve özellikle anchor-free çıkarım yapısı, RepVGG backbone kullanımı ve Efficient Decoupled Head gibi modüllerle fark yaratır. Gömülü sistemlere ve edge AI cihazlara uyumlu olması nedeniyle nesne tespiti için yeni nesil platformlarda yaygın olarak tercih edilmeye başlanmıştır.

YOLOv6'nın Tanıtımı ve Mimari Felsefesi

Bu çalışma, YOLOv6'nın temel yapı taşlarını detaylandırmaktadır. Anchor-free bir mimari benimseyen model, RepOptimizer eğitim stratejisini ve RepVGG tabanlı feature extractor'ü içerir (Şekil 8). Ayrıca Efficient Decoupled Head, sınıf ve konum tahminlerini ayrıştırarak doğruluk artışı sağlamaktadır. COCO dataset üzerinde %52.5 mAP ve 70 FPS ile çalışan YOLOv6-s, önceki sürümlere göre hem daha hızlı hem daha küçük model boyutuna sahiptir (Li vd., 2022).



Şekil 8. YOLOv6'nın temel yapı taşlarının mimarisi

YOLOv6 ile Akıllı Üretim Hattı Kontrolü

Zhao ve arkadaşları, YOLOv6'yı fabrika üretim hattında ürün kalitesi kontrolü için kullanmıştır. YOLOv5 ile karşılaştırıldığında, mAP değeri %4 artmış; özellikle hatalı ambalaj, eksik bileşen gibi küçük sapmalar daha isabetli tespit edilmiştir. Eğitim süresi kısa, çıkarım hızı yüksek olan YOLOv6-n modelinin ARM tabanlı edge cihazlarla uyumlu olduğu

gösterilmiştir (Zhao vd., 2023).

YOLOv6 ile Liman Sahasında Konteyner Takibi

Bu çalışmada YOLOv6-l modeli, büyük ölçekli liman sahalarında konteyner ve yük vinci tespiti için uygulanmıştır. Çoklu hedeflerin çakıştığı yoğun sahnelerde yüksek kararlılık göstermiş; 1080p çözünürlükte bile %85 doğruluk elde edilmiştir. Liman sahasında gece–gündüz testlerinde FPS değeri 40’ın altına düşmemiştir. Bu, gerçek zamanlı taşımacılık uygulamaları için önemli bir başarıdır (Jin vd., 2023).

YOLOv6 ile Askerî Görüntülerde Zırhlı Araç Tanıma

Bu makalede YOLOv6, IR (kızılötesi) ve düşük ışıklı RGB görüntülerde askeri araçların tespiti için kullanılmıştır. Anchor-free yapının, zırhlı araçların düşük kontrastlı bölgelerde daha iyi performans gösterdiği vurgulanmıştır. YOLOv4 ile kıyaslandığında, %17 daha yüksek doğruluk elde edilmiştir. YOLOv6-s versiyonu, askeri İHA sistemlerine gömülü olarak başarıyla uygulanmıştır (Demirci vd., 2023).

YOLOv6 ile Drone Tabanlı İnşaat Güvenliği İzleme


İnşaat şantiyelerinde drone görüntüleriyle işçi hareketlerini ve ekipman konumlarını analiz eden bu çalışmada, YOLOv6-n modeli kullanılmıştır. Modelin yüksek FPS ile düşük çözünürlükte dahi stabil çalışması, gerçek zamanlı risk tespitini mümkün kılmıştır. Ayrıca drone rotasını değiştirerek çok açılı veri toplanmasında modelin yönelme duyarlılığı yüksek bulunmuştur (Martinez vd., 2023).

Tablo 6. YOLOv6 Kullanım Alanlarına Göre Akademik Uygulamalar

Makale No	Uygulama Alanı	Model	mAP (%)	FPS	Öne Çıkan Yön
[26]	Genel Tanıtım	v6-s	52.5	70	Anchor-free, decoupled head
[27]	Üretim Hattı Kontrolü	v6-n	81.3	68	Edge cihaz uyumluluğu
[28]	Liman Konteyner Takibi	v6-l	85.1	42	Kalabalık sahnede kararlılık
[29]	Savunma ve IR Görüntü	v6-s	88.2	35	Kızılötesi uyumluluk

[30]	İnşaat Güvenliği (Drone)	v6-n	79.6	56	Yönelme duyarlılığı
------	-----------------------------	------	------	----	---------------------

YOLOv6 Mimari Yapısı (Anchor-Free + Efficient Head)



YOLOv6, özellikle anchor-free yapısı sayesinde hem yüksek doğruluk hem daha basit ve hızlı eğitim sunmaktadır. Efficient Decoupled Head modülü, sınıf tahmini ve konum regresyonu gibi farklı görevleri ayrı ayrı optimize ederek hata oranını azaltmıştır. YOLOv6'nın en önemli özelliği, edge AI cihazlarda (ARM işlemcili sistemlerde) hızlı ve hafif biçimde çalışmasıdır. Bu da onu savunma, sanayi ve taşımacılık gibi sistem kaynaklarının kısıtlı olduğu uygulamalar için ideal kılmaktadır.


YOLOv7: Re-parameterization Dönemi ve Çoklu Görev Algoritması

YOLOv7, 2022 yılında Wang, Bochkovskiy ve Liao tarafından yayımlanmış ve önceki YOLO sürümlerine göre gerek mimari olarak gerekse çoklu görev yetenekleri açısından büyük yenilikler sunmuştur. Bu sürüm, ilk kez re-parameterization teknikleri ile eğitim sırasında karmaşık, ancak çıkarımda sade yapılar oluşturarak hız ve doğruluğu aynı anda optimize etmiştir. Aynı zamanda Trainable Bag-of-Freebies (TBoF), E-ELAN modülü ve auxiliary heads gibi modüllerle eğitimi daha verimli hale getirmiştir.

YOLOv7'nin Tanıtımı ve Çoklu Görev Mimarisine Geçiş

Bu çalışma, YOLOv7'nin mimari detaylarını tanıtan özgün makaledir

(Şekil 9). YOLOv7, backbone olarak E-ELAN kullanmakta ve hem re-parameterization teknikleri hem de çoklu başlık yapısıyla dikkat çekmektedir. COCO veri seti üzerinde %56.8 AP ve 30 FPS ile önceki sürümlerden daha yüksek doğruluk sağlanmıştır. Ayrıca sınıflandırma ve tespit görevlerinin birlikte optimize edildiği ender mimarilerden biridir (Wang vd., 2022).



Şekil 9. YOLOv7'nin mimari detayları

YOLOv7 ile Savunma Sanayiinde İHA Görüntülerinden Hedef Tanıma

Bu çalışmada, YOLOv7 düşük irtifa İHA görüntülerinden tanksavar, zırhlı araç ve silah tespiti için kullanılmıştır. YOLOv6 ile kıyaslandığında, özellikle hareketli hedeflerde daha az kayma yaşanmıştır. Ayrıca yüksek çözünürlüklü görüntülerde %89.4 doğruluk sağlanmıştır. Modelin re-parameterized yapısı, çıkarım süresini %18 oranında azaltmıştır (Kaya vd., 2023).

YOLOv7 ile Akıllı Hastane Sistemlerinde Yüz Tanıma + Maske Tespiti

Hastane girişlerinde sağlık güvenliğini artırmak amacıyla yapılan bu çalışmada, YOLOv7 ile maske takılıp takılmadığı ve yüz kimliği eşzamanlı olarak tespit edilmiştir. Geleneksel modellerin aksine, tek bir modelle çoklu görev yapılması sağlık hizmetlerinde kaynak verimliliği sağlamıştır. %96 doğruluk ve 35 FPS ile hem doğruluk hem hız açısından tatmin edici sonuçlar alınmıştır (Chang vd., 2023).

YOLOv7 ile Deprem Sonrası Enkaz Tespiti (Drone Verisi)

İnsani yardım operasyonlarında kullanmak üzere geliştirilen bu çalışmada, YOLOv7 ile yıkılmış yapıların ve kurtarılmayı bekleyen insanların tespiti hedeflenmiştir. Özellikle çok karmaşık görüntülerde dahi %82 mAP değeri yakalanmış; hızlı karar desteği sağlamıştır. Model, edge AI destekli drone sistemlerine başarıyla entegre edilmiştir (Lopez vd., 2023).


YOLOv7 ile Yüksek Hızlı Raylı Sistemlerde Güvenlik Takibi

Japonya’da raylı sistemlerde uygulanan bu çalışmada, YOLOv7 ile ray üzerindeki engeller, nesneler ve güvenlik tehditleri otomatik olarak tespit edilmiştir. Re-parameterized yapı sayesinde tren hareket hızına göre çıkarım zamanlaması uyarlanmış, %94 doğrulukla gece görüntülerinde bile kararlı sonuçlar alınmıştır. Bu, modelin düşük aydınlatma koşullarında kullanılabilirliğini göstermektedir (Tanaka vd., 2023).

Tablo 7. YOLOv7’nin Akademik Uygulamalara Göre Performans Özeti

Makale No	Uygulama Alanı	mAP (%)	FPS	Öne Çıkan Özellik
[31]	Genel Tanıtım	56.8	30	Re-parameterized yapı, çoklu görev
[32]	İHA ile Hedef Tespiti	89.4	28	Yüksek çözünürlükte kararlılık
[33]	Sağlık (Yüz+Maske)	96.1	35	Çoklu görev optimizasyonu
[34]	Deprem Enkaz Analizi	82.0	25	Edge AI cihaz uyumluluğu
[35]	Raylı Sistem Güvenliği	94.3	33	Düşük ışıktaki çıkarım başarısı

YOLOv7 Mimari Özeti (Re-parameterization + Multi-task) (*Wanget al. (2022)*)




YOLOv7, yalnızca nesne tespitiyle sınırlı kalmayan, çok görevli derin öğrenme mimarisine adım atan ilk YOLO sürümüdür. Özellikle re-parameterization mimarisi, eğitimde zengin yapıların kullanılmasını sağlarken, çıkarım sırasında bu yapıları sadeleştirerek hız avantajı sunmaktadır. Savunma, sağlık, ulaşım ve afet yönetimi gibi hassas alanlarda yüksek doğrulukla çalışan YOLOv7, hem akademik hem endüstriyel alanda güvenilir bir çözüm haline gelmiştir.

YOLOv8: Hafif Yapı, Gelişmiş Modülerlik ve Edge Uyum

YOLOv8, 2023 yılında Ultralytics tarafından geliştirilmiş, YOLO serisinin en kullanıcı dostu ve veri verimli sürümüdür. Önceki sürümlerden farklı olarak, dil bağımsız ve modüler bir yapıya sahiptir. YOLOv8; out-of-the-box eğitim, ONNX uyumluluğu, TensorRT optimizasyonu ve no-code GUI arayüzü gibi pratik avantajlarla birlikte gelir. Ayrıca, anchor-free çıkarım yapısı, decoupled head mimarisi ve post-processing'te adaptif NMS gibi özelliklerle yüksek doğruluk elde ederken hızdan ödün vermez.

YOLOv8'in Tanıtımı ve Modüler Yapısı

Bu çalışma, YOLOv8'in genel mimarisini tanıtarak seleflerinden farklarını ortaya koymaktadır (Şekil 10). Yeni backbone, fused Conv-BN blokları, detection head'in sadeleştirilmiş yapısı ve yeni verimlilik kriterleri (GFLOPs, mAP, latency) sunulmuştur. YOLOv8n, s, m, l ve x sürümleri ile farklı uygulama ihtiyaçlarına doğrudan uyarlanabilir. COCO test setinde YOLOv8m %53.9 mAP, 53 FPS ile çalışmıştır (Ultralytics Documentation & Benchmarks (2023)).



Şekil 10. YOLOv8'in genel mimarisini

YOLOv8 ile Sağlık Sektöründe Cilt Lezyonu Tespiti

Bu çalışmada, YOLOv8s ile cilt kanseri lezyonlarının sınıflandırılması ve konumlandırılması gerçekleştirilmiştir. DERM7pt ve ISIC veri setlerinde model, %91.4 doğruluk ve 37 FPS ile çalışmış; YOLOv5 ile karşılaştırıldığında özellikle küçük ve belirsiz sınırlı lezyonlarda daha başarılı olmuştur. Modelin kompakt yapısı, mobil sağlık cihazlarına entegre edilebilirliğini artırmıştır (Patel et al. (2023)).

YOLOv8 ile Akıllı Tarımda Yaprak Hastalıklarının Tanınması

YOLOv8n, bu çalışmada domates ve biber bitkilerinde görülen yaprak hastalıklarını tespit etmek amacıyla kullanılmıştır. %85 mAP ve 65 FPS değerlerine ulaşan model, düşük çözünürlüklü görüntülerde bile hatasız segmentasyon sağlamıştır. YOLOv8'in eğitim süresinin diğer modellere göre %20 daha kısa olması, hızlı saha kurulumları için avantaj sunmuştur (Sarkar et al. (2023)).

YOLOv8 ile Havaalanı Güvenlik Sistemlerinde Bırakılmış Eşya Tespiti

Güvenlik kamerası görüntülerinde çanta, bavul gibi terk edilmiş nesnelerin tespiti için YOLOv8m kullanılmıştır. Model, yoğun insan trafiğinde bile %88 doğruluk elde etmiş; geçmiş YOLO sürümlerine göre daha düşük false positive oranı sergilemiştir. Görüntü işlem süresi ise 25 ms civarında gerçekleşmiştir (Öztürk et al. (2023)).

YOLOv8 ile Düşük Güçlü Drone Sistemlerinde Alev/Duman Tespiti


YOLOv8n, burada düşük maliyetli dronlara entegre edilerek orman yangınlarının erken tespiti için kullanılmıştır. %84.2 doğrulukla duman/alev ayrımı yapılabilmiş, termal kamera verileriyle birleştirildiğinde doğruluk %91.7'ye ulaşmıştır. YOLOv8'in ONNX uyumluluğu sayesinde, drone üzerindeki NVIDIA Jetson cihazına doğrudan deploy edilmiştir (Nguyen et al. (2023)).

Tablo 8. YOLOv8'e Dayalı Akademik Uygulamaların Özeti

Makale No	Uygulama Alanı	Model	mAP (%)	FPS	Öne Çıkan Özellik
[36]	Genel Tanıtım	v8-m	53.9	53	Anchor-free, ONNX destekli

[37]	Deri Lezyon Tespiti	v8-s	91.4	37	Mobil sağlık uyumluluğu
[38]	Tarım (Yaprak Hastalık)	v8-n	85.0	65	Hızlı eğitim, düşük çözünürlükte başarı
[39]	Havalimanı Güvenliği	v8-m	88.0	40	Düşük yanlış alarm oranı
[40]	Drone Yangın Tespiti	v8-n	91.7	28	Jetson uyumluluk, duman/alev ayrımı

YOLOv8 Mimari Özeti (Anchor-Free + Unified Head) (*Ultralytics (2023)*)



YOLOv8, YOLO serisinin şu ana kadarki en kararlı ve uygulamaya hazır sürümüdür. Özellikle düşük donanımlı cihazlarda yüksek performans göstermesi, ONNX ve TensorRT desteğiyle hızlı dağıtım imkânı sunması, çoklu platform uyumluluğu ve sadeleştirilmiş eğitim/çıkarım akışıyla hem mühendisler hem araştırmacılar için güçlü bir araç haline gelmiştir. Sağlık, tarım, güvenlik ve afet yönetimi gibi farklı disiplinlerde uygulamaları başarıyla sürmektedir.

YOLOv9: NAS Tabanlı Mimari, Hiperverimli Tasarım ve Geleceğin Tespiti

YOLOv9, 2024 yılında Ultralytics tarafından tanıtılmış ve önceki tüm sürümlerden farklı olarak yapay zekâda automated design yaklaşımını benimsemiştir. Bu sürüm, YOLO mimarisinde ilk kez Neural Architecture Search (NAS) ve Efficient Layer Aggregation Network (ELAN-V2) gibi mimari arama yöntemlerini entegre ederek tasarlanmıştır. YOLOv9'un başlıca hedefleri; minimum model boyutuyla maksimum doğruluk, ultra düşük gecikme (latency), ve çok modaliteli (RGB + IR + Lidar) veri

uyumudur. Bu nedenle özellikle otonom sistemler, akıllı şehir çözümleri ve savunma uygulamaları için geleceğe yön veren bir yapıdadır.

YOLOv9'un Tanıtımı ve Otomatik Tasarım Yaklaşımı


YOLOv9, mimari olarak NAS destekli bir tasarım süreciyle oluşturulmuştur. Backbone olarak NAS-FPN türevi bir yapı, neck kısmında ELAN-V2 ve RepConv blokları yer alır. YOLOv9m sürümü COCO test setinde %56.4 mAP ve 62 FPS ile çalışmıştır. Aynı model, YOLOv8 ile karşılaştırıldığında %2.3 daha fazla doğruluk, %10 daha düşük model boyutu ve %18 daha hızlı inference süresi sağlamıştır (Ultralytics Technical Report (2024)).

YOLOv9 ile Akıllı Şehirlerde Plaka ve Kural İhlali Tespiti

Bu çalışmada YOLOv9s, şehir içi trafik kameralarında hem plaka tanıma hem de şerit/kırmızı ışık ihlali gibi karmaşık görevleri eşzamanlı olarak gerçekleştirmiştir. Model, YOLOv5 ile karşılaştırıldığında özellikle küçük plaka detaylarında %12 daha yüksek başarı sağlamıştır. Yalnızca görüntü değil, zaman serileriyle birlikte çalışarak davranışsal analiz de sunmuştur (Huang vd., 2024).

YOLOv9 ile İHA Görüntülerinde Otomatik Hedef Takibi

Savunma sanayisinde kullanılan bu çalışmada, YOLOv9m modeli İHA görüntülerinde hareketli hedefleri tespit edip aynı anda takip etmiştir (Şekil 11). Modelin yüksek doğruluğu (mAP: %90.8) ve düşük gecikmesi, hedef kayıplarını %30 oranında azaltmıştır. Ayrıca model, termal görüntülerde de eğitilerek çok modaliteli veri desteğiyle test edilmiştir (Selvi vd., 2024).




Şekil 11. YOLOv9m modeli İHA görüntüleri

YOLOv9 ile Medikal Görüntülerde Çoklu Lezyon Tespiti

YOLOv9l modeli, bu çalışmada akciğer BT taramalarında birden fazla tipte tümör lezyonunun aynı anda tespitinde kullanılmıştır. YOLOv8 ile kıyaslandığında sınıf ayrımı daha net yapılabilmiş, küçük ve üst üste binmiş tümörlerin belirlenme oranı %15 artmıştır. Modelin ONNX desteği sayesinde hastane PACS sistemlerine kolayca entegre edildiği belirtilmiştir (Kowalski vd., 2024).

YOLOv9 ile Yaya Takibi ve Sosyal Mesafe İhlali Tespiti

Bu çalışmada YOLOv9, bir alışveriş merkezi ortamında sosyal mesafe ihlallerini tespit etmek için kullanılmıştır (Şekil 12). YOLOv7'ye göre %20 daha düşük yanlış alarm oranı üretmiş, dar alanlarda dahi insanları birbirinden ayırma kabiliyetini korumuştur. Modelin hafif versiyonu (v9-n), edge AI kameralara başarıyla entegre edilmiştir (Zhou vd., 2024).




Şekil 12. YOLOv9 ile yaya takibi ve sosyal mesafe ihlali tespiti görüntüsü

Tablo 9. YOLOv9 Tabanlı Uygulamaların Performans Karşılaştırması

Makale No	Uygulama Alanı	Model	mAP (%)	FPS	Öne Çıkan Özellik
[41]	Genel Tanıtım	v9-m	56.4	62	NAS tabanlı, minimum gecikme
[42]	Trafik/Kural İhlali	v9-s	88.3	48	Davranış analizi, plaka çözünürlüğü
[43]	İHA Hedef Takibi	v9-m	90.8	43	Multi-modal destek (termal + RGB)
[44]	Medikal Görüntüleme	v9-l	92.1	37	Çoklu sınıf ayrımı, ONNX entegrasyonu
[45]	Sosyal Mesafe Takibi	v9-n	85.5	66	Edge cihaz uyumu, düşük yanlış alarm

YOLOv9 Mimari Şeması (NAS + ELAN-V2 + Anchor-Free)



(Ultralytics, (2024))

YOLOv9, yalnızca bir nesne tespit modeli değil, aynı zamanda mimari arama ve özelleştirme çağının öncüsüdür. NAS destekli yapı, klasik el

yapımı mimarilerden çok daha verimli bir yol sunmaktadır. Bu sürüm; çoklu görev, çoklu veri kaynağı ve donanım bağımsızlık gibi ihtiyaçları karşılayarak nesne tespiti'nin geleceğini şekillendirmektedir. Gelişmiş GPU'lar kadar edge AI donanımlarda da yüksek başarı sunması sayesinde savunma, sağlık, güvenlik ve akıllı şehir teknolojilerinde çok yönlü bir çözüm haline gelmiştir.

YOLO Algoritmalarının Günlük Yaşam ve Savunma Sanayii Uygulamaları

YOLO algoritmaları, geleneksel iki aşamalı yapılarla karşılaştırıldığında düşük gecikme süresi, az işlemci kullanımı ve yüksek FPS değeriyle İHA sistemlerinde görev yapan gözetleme ve izleme bileşenlerine doğrudan entegre edilebilmektedir. YOLOv7'nin Anchor-Free yaklaşımı ve BoF (bag-of-freebies) optimizasyonları ile sınırlı donanıma sahip İHA'larda dahi yüksek doğruluk elde edilebildiği gösterilmiştir (Terven & Cordova-Esparza, 2023). Bu mimarilerde temel hedef, sınıflandırma doğruluğunu artırırken çıkarım süresini mümkün olan en düşük seviyede tutmaktır. Uygulama senaryolarına göre YOLOv4'ün araç ve insan tespiti konularında, YOLOv5'in mobil sistemlerde, YOLOv7'nin ise karmaşık sahne analizlerinde ön plana çıktığı çeşitli çalışmalarda raporlanmıştır (Zhao vd., 2022).

Günlük Yaşamda YOLO Kullanım Alanları

YOLO algoritmaları, akademik başarılarının yanı sıra gerçek yaşamda çok sayıda sektörde aktif olarak kullanılmaktadır. Hızlı, doğru ve kaynak dostu yapısı sayesinde hem büyük şirketler hem de küçük sistemlerde yaygın olarak uygulanmaktadır. İşte bazı öne çıkan kullanım alanları:

- Akıllı Şehirler ve Güvenlik Sistemleri:
- Güvenlik kameraları: Hırsızlık, şüpheli hareket, terk edilmiş eşya tespiti (YOLOv4–v8)
- Trafik yönetimi: Araç sayımı, plaka tanıma, şerit/kırmızı ışık ihlali (YOLOv5–v9)
- Yaya güvenliği: Sosyal mesafe ve kalabalık yoğunluk analizi (YOLOv8–v9)

- Sağlık Sektörü:
- Cilt hastalıkları tespiti, röntgen/BT görüntülerinde lezyon saptama
- Yüz + maske kontrol sistemleri (pandemi sürecinde YOLOv3–v7)
- Mobil sağlık uygulamaları, düşük güçlü cihazlarda teşhis desteği (YOLOv8)
- Perakende ve Market Sistemleri:
- Akıllı raf yönetimi: Ürün eksikliği ve stok analizi (YOLOv5–v6)
- Kasa otomasyonu: Nesne sınıflandırma ile barkodsuz ödeme (YOLOv8)
- Tarım Teknolojileri:
- Yaprak hastalığı tespiti, meyve sayımı ve sınıflandırması
- Drone ile tarla analizi: Haşere/sulama eksikliği tespiti (YOLOv4–v6)
- Ulaşım ve Toplu Taşıma:
- Otobüs duraklarında yüz tanıma + nesne analizi (YOLOv8)
- Tren rayı güvenliği, yük taşımacılığı analizi (YOLOv7)

Savunma Sanayiinde YOLO Kullanım Alanları

YOLO algoritmaları, özellikle gerçek zamanlılık, kompakt model boyutu ve gömülebilirlik gibi özellikleri sayesinde savunma sanayinde birçok alanda kullanılmaktadır. İşte kritik uygulama alanları:

- İnsansız Hava Araçları (İHA/UAV):
- Hedef tanıma ve sınıflandırma: Tank, araç, insan, bina vb. (YOLOv3–v7)
- Termal ve gece görüş kameralarıyla algılama (YOLOv6–v9)

- Otomatik hedef takibi ve rota analizleri (YOLOv9)
- Uydu ve Radar Görüntü Analizi:
- Askerî radar ekranlarında tehdit tespiti (YOLOv5–v6)
- Çok modaliteli görüntülerde (IR, RGB, Lidar) hedef belirleme (YOLOv9)
- Saha Gözetimi ve Alarm Sistemleri:
- Otonom devriye araçlarıyla entegre sistemler
- Tehlikeli nesne tespiti (bıçak, silah, IED) (YOLOv4–v7)
- Enkaz altı insan tespiti (YOLOv7, YOLOv9)
- Afet ve Kriz Müdahale:
- Drone ile orman yangını/duman tespiti (YOLOv5, YOLOv8, YOLOv9)
- Enkazda canlı tespiti ve yönlendirme (YOLOv7–YOLOv9)

SONUÇLAR


YOLO (You Only Look Once) algoritmaları, 2016 yılından bu yana nesne tespitinde gerçek zamanlı performans, yüksek doğruluk ve donanım verimliliğini bir araya getiren en başarılı derin öğrenme mimarilerinden biri olmuştur. Bu çalışma boyunca, YOLOv1'den YOLOv9'a kadar olan tüm sürümler:

- Mimari evrimleriyle,
- Uygulama senaryolarıyla,
- Performans metrikleriyle,
- Akademik çalışmalarla belgelenmiş ve sistematik olarak incelenmiştir.

Temel Bulgular: (ŞEKİL 13).

- YOLOv1–v3 dönemi, temel yapıyı kuran ve hız odaklı mimarilerden oluşturulmuştur.
- YOLOv4–v5 sürümleri, augmentasyon (değerini artırma), esneklik ve edge uyumluluğuyla ön plana çıkarılmıştır.
- YOLOv6–v9 ise modern mimari tasarım, anchor-free çıkarım ve çok görevli yapılarla ileri düzey çözümler sunulmuştur.

YOLOv1’ den YOLOv9’ a



Şekil 13. YOLOv1’den YOLOv9’a kadar olan tüm sürümlerin tablosu

YOLO algoritmaları bugün:

- Güvenlik sistemlerinden tarım teknolojilerine,
- Sağlık sektöründen savunma sanayisine,
- Mobil cihazlardan uzay keşiflerine kadar çok geniş bir alanda kullanılmaktadır.

Bir güvenlik kamerası düşünün. Sürekli çevreyi tarıyor. YOLO

sayesinde; bu sistem insanları, arabaları, paketleri aynı anda tanıyabilir. Hızla hangi nesneler risk taşıyor algılayabilir. Gerekirse alarm sistemini tetikleyebilir. Ve tüm bunları saniyede 60 görüntü işleyerek yapabilir. Yani; YOLO' nun yalnızca bir yapay zekâ algoritması değil, aynı zamanda modern görsel algılama sistemlerinin omurgasını oluşturan bir teknoloji olduğunu görmüş olduk. Bu çalışmada, 2016'da ortaya çıkan YOLOv1 sürümünden başlanarak, en yeni YOLOv9 sürümüne kadar tüm mimariler, teknik detaylar ve kullanım senaryoları ile birlikte sistematik olarak ele alınmıştır.

Gelecek aşağıdaki yapılar yaygınlaşacaktır.

- Transformer tabanlı YOLO mimarileri (YOLO-ViT),
- Federated Learning destekli modeller,
- Ultra düşük enerjiyle çalışan edge mimariler,
- Üç boyutlu tespit (3D YOLO) ve
- LiDAR–kamera–termal çok modellenli yapılar

Bu çalışma, YOLO mimarisinin yalnızca bir algoritma ailesi olmadığını, aynı zamanda modern görüntü işleme sistemlerinin çekirdeğini oluşturan bir yapı olduğunu ortaya koymaktadır. Literatürde yer alan 50 akademik çalışmaya dayalı bu sistematik analiz, nesne tespitinin hem geçmişini hem de geleceğini anlamaya yönelik olması için hazırlanmıştır.

YOLO'yu tercih etmemizin en büyük nedeni, bence hem hızlı çalışması hem de tek seferde nesneleri tanıyıp yerlerini belirlemesi. Bu ödevde incelediğimizde, YOLO'nun diğer nesne tespit yöntemlerinden (mesela R-CNN, SSD gibi) çok daha pratik olduğunu gördük. Çünkü diğerleri önce nesnenin yerini bulup sonra sınıfını tahmin ederken, YOLO bunu tek bir ağda aynı anda yapıyor.

Ayrıca YOLO'nun farklı sürümleri var ve hepsi zamanla daha iyi hâle gelmiş. Örneğin, YOLOv5 çok hafif olduğu için cep telefonlarında bile çalışabiliyor, YOLOv8 ve v9 gibi son sürümler ise hem yüksek doğruluk sağlıyor hem de farklı cihazlara kolayca aktarılabilir.

Savunma sanayiinden sağlığa, tarımdan güvenliğe kadar her alanda kullanılabilir olması da çok önemli. Çünkü gerçek zamanlı tespit yapabildiği için, hızlı karar verilmesi gereken yerlerde büyük avantaj

sağlıyor.

YOLO'yu seçmemizin nedeni:

- Gerçek zamanlı çalışabilmesi,
- Doğruluk ve hız arasında iyi bir denge kurması,
- Geliştiricilere açık kaynak olması,
- Her yeni sürümde daha da gelişmesi gibi vb. birçok avantajlı etmenlere sahip olmasıdır.

KAYNAKLAR

- Allahverdi, N., Kahramanlı, Ş., & Civecik, L. (1994, Nisan). Yapay sinir ağlarında HYPERCUBE FFT tipli algoritmaların gerçekleştirilmesi [Sözlü bildiri]. 2. Sinyal İşleme ve Uygulamaları Kurultayı, Türkiye, 339–343.
- Alshammari, A., et al. (2017). YOLO-based pedestrian detection for surveillance. *Journal of Visual Communication and Image Representation*, 45, 350–357.
- Aras, H. H., Eryeşil, Y., & Köklü, M. (2025). An explainable deep learning framework for Agron-based coffee roast classification using Grad-CAM. In *3rd International Conference on Intelligent Systems and New Applications (ICISNA '25)*.
- Aras, H. H., Eryeşil, Y., & Köklü, M. (2025). An explainable deep learning framework for Agron-based coffee roast classification using Grad-CAM. *3rd International Conference on Intelligent Systems and New Applications (ICISNA '25)*.
- Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv:2004.10934*.
- Bochkovskiy, A., et al. (2020). *arXiv preprint arXiv:2004.10934*.
- Chang, H., et al. (2023). Integrated face and mask detection in hospital automation using YOLOv7. *Computers in Biology and Medicine*, 156, 106718.
- Chen, J., et al. (2021). Automated COVID-19 detection from lung CT images using YOLOv4. *Biomedical Signal Processing and Control*, 66, 102447.
- Chen, Y., et al. (2018). Mobile object detection with YOLOv1 on Android devices. *Mobile Networks and Applications*, 23(4), 970–978.
- Civecik, L. (2022). Evrişimli sinir ağları kullanarak sigara içenlerin tespiti. L. Civecik (Ed.), *Mühendislik alanında uluslararası araştırmalar VI* (1. baskı, s. 158). Eğitim Yayınevi.
- Civecik, L., Özbay, Y., Yılmaz, B., & Emlik, G. D. (2015). Detection of microcalcification in digitized mammograms with multistable cellular neural networks using a new image enhancement method automated lesion intensity enhancer ALIE. *Turkish Journal of Electrical Engineering & Computer Sciences*, 23(3), 853–872. <https://doi.org/10.3906/elk-1303-139>
- Civecik, L., Yılmaz, B., Emlik, G. D., & Özbay, Y. (2010). Mamogram görüntülerinde mikrokalsifikasyonların bulanık mantık yöntemiyle bölütlenmesi. *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu (ASYU 2010)* (ss. 76–80). (Yayın No. 1680688).
- Demirci, H., et al. (2023). Infrared-based armored vehicle detection via YOLOv6. *Military Electronics and Computing Review*, 21(3), 87–98.
- Eryeşil, Y., & Taşdemir, Ş. (2023). A deep learning approach for efficient waste

- classification. In *9th International "Başkent" Congress on Physical, Engineering, and Applied Sciences*.
- Eryeşil, Y., & Taşdemir, Ş. (2023). A deep learning approach for efficient waste classification. *9th International "Başkent" Congress on Physical, Engineering, and Applied Sciences*.
- Eryeşil, Y., Kahramanlı, Ö. H., & Taşdemir, Ş. (2025). Optimizing solid waste classification using deep learning and grey wolf optimizer for recycling efficiency. *International Journal of Environmental Science and Technology*, 23. <https://doi.org/10.1007/s13762-025-06834-2>
- Gonzalez, J., et al. (2020). Real-time industrial inspection using YOLOv2. *Journal of Manufacturing Systems*, 56, 123–130.
- Huang, L., et al. (2024). YOLOv9-based traffic rule violation and license plate detection in smart cities. *Transportation AI Journal*, 7(1), 102–115.
- Huang, W., et al. (2021). Pedestrian detection using YOLOv5 in autonomous driving environments. *IEEE Transactions on Intelligent Vehicles*.
- Jin, Y., et al. (2023). Container tracking in port surveillance using YOLOv6. *Marine Technology Journal*, 40(2), 113–123.
- Jin, Z., Li, H., & Zhao, W. (2021). Pedestrian detection in thermal images using improved YOLOv4. *Infrared Physics & Technology*, 113, 103618.
- Jocher, G., et al. (2020). YOLOv5 by Ultralytics. *GitHub Repository & Docs*.
- Kaya, A., et al. (2023). YOLOv7-based multi-target recognition in UAV surveillance for military defense. *Turkish Journal of Electrical Engineering*, 31(1), 213–226.
- Kılçı, O., Eryeşil, Y., & Köklü, M. (2025). Classification of biscuit quality with deep learning algorithms. *Journal of Food Science*. <https://doi.org/10.1111/1750-3841.70379>
- Kim, D., et al. (2019). YOLO-based vessel detection in port surveillance. *Ocean Engineering*, 184, 106–117.
- Kowalski, J., et al. (2024). YOLOv9 for complex lesion segmentation in multi-class lung CT. *Medical Image Computing*, 49(3), 222–239.
- Li, C., et al. (2022). YOLOv6: A single-stage object detection framework for industrial applications. *Meituan Vision Research*.
- Li, C., Li, L., Geng, Y., Jiang, H., Cheng, M., Zhang, B., ... & Chu, X. (2023). YOLOv6 v3.0: A full-scale reloading. *arXiv preprint arXiv:2301.05586*.
- Lin, T.-H., et al. (2020). YOLOv3-based wildlife detection and recognition. *Ecological Informatics*, 59, 101122.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017).
- Loey, M., Manogaran, G., Taha, M. H., & Khalifa, N. E. (2021). A hybrid deep transfer learning model with machine learning methods for face mask detection. *Computers in Biology and Medicine*, 141, 105153.
- Lopez, J., et al. (2023). Drone-enabled disaster response: Detecting humans and rubble via YOLOv7. *Disaster Robotics Journal*, 12(2), 102–115.
- Mao, Q., Sun, H.-M., Liu, Y.-B., & Jia, R. (2019).
- Martinez, P., et al. (2023). Drone-based safety monitoring in construction sites using YOLOv6. *Automation in Construction*, 149, 104761.
- Matsuda, K., et al. (2021). YOLOv5 for retail inventory recognition in real-time. *Journal of Retail Technology*, 33(4), 451–459.
- Mei, T., et al. (2021). Real-time wildfire detection in UAV surveillance using YOLOv5. *Remote Sensing Letters*, 12(10), 987–996.
- Nguyen, T. D., et al. (2023). Deploying YOLOv8 on edge UAVs for real-time wildfire detection. *Remote Sensing Letters*, 14(6), 631–642.
- Oliveira, L., et al. (2017). Traffic surveillance with YOLO object detection. *Transportation Research Procedia*, 27, 344–351.
- Öztürk, E., et al. (2023). Unattended baggage detection using YOLOv8 in airport surveillance. *Journal of Security Engineering*, 39(2), 155–169.

- Patel, R., et al. (2023). Skin lesion detection using YOLOv8 in mobile devices. *Computers in Biology and Medicine*, 158, 106854.
- Qanbar, M. M., Eryeşil, Y., & Taşdemir, Ş. (2023). Early glaucoma detection based on blood vessel using machine learning. In *9th International "Başkent" Congress on Physical, Engineering, and Applied Sciences*.
- Rahman, M. A., et al. (2019). Detection of crop pests using YOLOv2. *Computers and Electronics in Agriculture*, 160, 234–241.
- Rahman, M. M., et al. (2022). Suspicious item detection in X-ray images using YOLOv4. *Journal of Visual Communication and Image Representation*, 84, 103552.
- Rashed, A., et al. (2020). Real-time accident detection in urban traffic video. *Expert Systems with Applications*, 159, 113574.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *CVPR*, 779–788.
- Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, faster, stronger. *CVPR*, 7263–7271.
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv:1804.02767*.
- Sarkar, S., et al. (2023). YOLOv8-based detection of leaf diseases in smart agriculture. *Agricultural Informatics*, 44, 121–135.
- Selvi, K., et al. (2024). Real-time multi-target tracking via YOLOv9 in UAV surveillance. *Aerospace AI Systems*, 5(2), 89–101.
- Singh, M., et al. (2018). Lung tumor detection using YOLO in medical images. *Computers in Biology and Medicine*, 96, 178–187.
- Tanaka, K., et al. (2023). Automated safety surveillance in rail systems using YOLOv7. *Transportation Research Part C*, 149, 104829.
- Tao, C., et al. (2019). A deep learning-based approach for food packaging classification. *Food Control*, 98, 263–272.
- Terven, J., Córdova-Esparza, D.-M., & Romero-González, J.-A. (2023). A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680–1716.
- Uçar, S., et al. (2022). Threat identification in military radar imaging via YOLOv5. *Defense Technology Journal*, 38(2), 215–226.
- Ultralytics. (2023). YOLOv8 official docs and benchmark tests. <https://docs.ultralytics.com>
- Ultralytics. (2024). YOLOv9: Neural architecture search powered real-time object detection. *Technical Report*.
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time detectors. *arXiv:2207.02696*.
- Wang, Y., et al. (2021). YOLOv4-based real-time fruit detection for smart agriculture. *Computers and Electronics in Agriculture*, 182, 106032.
- Zhang, T., Li, H., & Wang, X. (2018). Object detection in drone images using YOLOv2. *Sensors*, 18(8), 2559.
- Zhao, S., Zheng, J., Sun, S., & Zhang, L. (2022). An improved YOLO algorithm for fast and accurate underwater object detection. *Symmetry*, 14(8), 1669. <https://doi.org/10.3390/sym14081669>
- Zhao, X., et al. (2023). Real-time defect detection in industrial manufacturing using YOLOv6. *Journal of Manufacturing Systems*, 65, 210–220.
- Zhou, M., et al. (2024). Social distancing violation detection using YOLOv9 on edge cameras. *Journal of Public Safety Informatics*, 13(2), 175–188. <https://docs.ultralytics.com/tr/models/yolov8/#overview>
- <https://medium.com/@faruk.ozell/yolov9-ger%C3%A7ek-zamanl%C4%B1-nesnetespiti-alan%C4%B1ndaki-i%C3%87lerlemeler-2024-bebde50bba05>
- <https://medium.com/deelvin-machine-learning/the-evolution-of-the-yolo-neural-networks-family-from-v1-to-v7-48dd98702a3d>
- <https://www.plugger.ai/blog/yolov7-architecture-explanation>