



HARRAN ÜNİVERSİTESİ MÜHENDİSLİK DERGİSİ

HARRAN UNIVERSITY JOURNAL of ENGINEERING

e-ISSN: 2528-8733 (ONLINE)

URL: <https://dergipark.org.tr/tr/pub/humder>

Güneş Panellerindeki Arıza Tespiti için Derin Öğrenmeye Dayalı Bir Yaklaşım: YOLOv8 Uygulaması

A Deep Learning-Based Approach for Fault Detection in Solar Panels: Application of YOLOv8

Yazar(lar) (Author(s)): Hussein YOUSEFALTURK¹, Yurdağül Benteşen YAKUT²

¹ORCID ID: 0000-0002-5237-4448

²ORCID ID: 0000-0003-3236-213X

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Yousefalturk H. ve Yakut Y. B., “Güneş Panellerindeki Arıza Tespiti için Derin Öğrenmeye Dayalı Bir Yaklaşım: YOLOv8 Uygulaması”, *Harran Üniversitesi Mühendislik Dergisi*, 11(1): 54-68, (2026).

Erişim linki (To link to this article): [10.46578/humder.1821648](https://dergipark.org.tr/tr/pub/humder/10.46578/humder.1821648)



Güneş Panellerindeki Arıza Tespiti için Derin Öğrenmeye Dayalı Bir Yaklaşım: YOLOv8 Uygulaması

Hussein YOUSEFALTURK^{1*}, Yurdagül Benteşen YAKUT¹

¹Elektrik Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye

Öz

Makale Bilgisi

Başvuru: 11/11/2025
Düzeltilme: 12/01/2026
Kabul: 03/03/2026
Yayınlanma: 31/03/2026

Alıntı

Yousefalturk H. ve Yakut Y. B., "Güneş Panellerindeki Arıza Tespiti için Derin Öğrenmeye Dayalı Bir Yaklaşım: YOLOv8 Uygulaması", Harran Üniversitesi Mühendislik Dergisi, 11(1): 54-68, (2026).

Güneş panellerinde oluşan kuş pisliği, tozlanma, fiziksel/elektriksel hasarlar ve kar örtüsü gibi faktörler, enerji üretim verimliliğini ciddi biçimde düşürmektedir. Bu çalışmada, söz konusu arıza türlerinin tek bir işlem hattı içerisinde, düşük hesaplama maliyetiyle ve yüksek doğrulukla tespit ve sınıflandırılmasını hedefleyen, YOLOv8 tabanlı bütünleşik bir derin öğrenme yaklaşımı önerilmektedir. Kaggle platformundan temin edilen 887 adet yüksek çözünürlüklü görüntü, Roboflow ortamında etiketlenmiş; veri setinin çeşitliliğini ve genelleme yeteneğini artırmak amacıyla döndürme, çevirme ve parlaklık ayarı gibi veri artırma teknikleri uygulanmıştır. Model eğitimi, %70 eğitim, %20 doğrulama ve %10 test veri bölünmesiyle, önceden eğitilmiş ağırlıklar kullanılarak Google Colab ortamında gerçekleştirilmiştir. Deneysel sonuçlar, önerilen modelin %94.3 mAP@0.5, %89 Top-1 doğruluk ve %99.1 Top-5 doğruluk değerlerine ulaştığını göstermektedir. Çalışmanın özgün katkısı, YOLOv8'in birleşik mimarisinden yararlanarak nesne tespiti ve sınıflandırma görevlerini ayrı modeller kullanmaksızın tek bir yapı altında optimize etmesidir. Elde edilen bulgular, geliştirilen yaklaşımın büyük ölçekli güneş enerjisi santrallerinde (GES) gerçek zamanlı izleme ve otonom bakım sistemlerine entegre edilebilir, ölçeklenebilir ve güvenilir bir çözüm sunduğunu ortaya koymaktadır. Bu yönüyle çalışma, saha uygulamalarına yönelik pratik bir çerçeve sunarak literatüre katkı sağlamaktadır.

Anahtar Kelimeler: Derin öğrenme, YOLOv8, Güneş paneli, Arıza tespiti, Görüntü sınıflandırma

A Deep Learning-Based Approach for Fault Detection in Solar Panels: Application of YOLOv8

Article Information

Received: 11/11/2025
Revised: 12/01/2026
Accepted: 03/03/2026
Published: 31/03/2026

Citation

Yousefalturk H. ve Yakut Y. B., "A Deep Learning-Based Approach for Fault Detection in Solar Panels: Application of YOLOv8" Harran University Journal of Engineering, 11(1): 54-68, (2026).

Abstract

Factors such as bird droppings, dust accumulation, physical/electrical faults, and snow coverage significantly reduce the energy production efficiency of photovoltaic panels. This study proposes an integrated YOLOv8-based deep learning framework that enables high-accuracy detection and classification of multiple fault types within a single processing pipeline and with low computational cost. A total of 887 high-resolution images obtained from the Kaggle platform were annotated using Roboflow, and data augmentation techniques including rotation, flipping, and brightness adjustment were applied to enhance dataset diversity and generalization. The model was trained in the Google Colab environment using pre-trained weights with a 70% training, 20% validation, and 10% test split. Experimental results indicate that the proposed approach achieves a 94.3% mAP@0.5, along with 89% Top-1 accuracy and 99.1% Top-5 accuracy. The key contribution of this study lies in leveraging the unified architecture of YOLOv8 to jointly optimize object detection and classification tasks without employing separate models. The findings demonstrate that the proposed framework can be effectively integrated into real-time monitoring and autonomous maintenance systems for large-scale solar power plants, offering a scalable, reliable, and application-oriented solution that contributes to the existing literature.

Keywords: Deep learning, YOLOv8, Solar panel, Fault detection, Image classification

*İletişim yazarı, e-mail: huseyin90alturk@gmail.com

*Corresponding author, e-mail: huseyin90alturk@gmail.com

DOI: 10.46578/humder.1821648

1. GİRİŞ (INTRODUCTION)

Yenilenebilir enerji kaynakları, küresel enerji talebinin karşılanmasında ve çevresel sürdürülebilirlik hedeflerine ulaşılmasında giderek daha önemli bir rol oynamaktadır. Bu bağlamda güneş enerjisi, düşük karbon ayak izi, yaygın erişilebilirliği ve uzun vadeli ekonomik avantajları sayesinde enerji üretiminde stratejik bir konuma sahiptir [1]. Güneş enerjisi santralleri, yüksek başlangıç yatırım maliyetlerine rağmen, düşük işletme maliyetleri ve çevre dostu yapıları sayesinde enerji sektöründe önemli bir yer edinmiştir [2]. Ancak güneş panellerinin enerji üretim kapasitesi; üretim, kurulum veya çevresel faktörlerden kaynaklanan arızalardan ciddi şekilde etkilenebilmektedir. Kuş pisliği, toz birikimi, fiziksel hasarlar (çatlaklar, kırık cam), elektrik arızaları ve kar örtüsü gibi arızalar, panellerin verimliliğini düşürerek enerji kayıplarına ve ekonomik maliyetlere yol açmaktadır [3]. Bu arızaların erken ve doğru şekilde tespit edilmesi; enerji üretiminin sürekliliğini sağlamak, bakım süreçlerini optimize etmek ve işletme maliyetlerini azaltmak açısından kritik bir gerekliliktir [4].

Geleneksel arıza tespit yöntemleri genellikle manuel incelemelere dayanır ve bu süreç, özellikle büyük ölçekli güneş enerjisi santrallerinde zaman alıcı ve maliyetli olmaktadır. Ayrıca, insan gözüne dayalı denetimler subjektif hatalara açık olup tutarlılık ve doğruluk açısından çeşitli sınırlamalar içermektedir. Buna karşılık, derin öğrenme tabanlı teknolojiler, otomatik arıza tespiti için yenilikçi ve etkili bir çözüm sunmaktadır. Derin öğrenme, karmaşık desenleri ve özellikleri öğrenme yeteneği sayesinde, geleneksel görüntü işleme yöntemlerine kıyasla daha yüksek doğruluk ve genelleme kapasitesi sağlamaktadır [5]. Özellikle konvolüsyonel sinir ağları (CNN), görüntü sınıflandırma ve nesne algılama görevlerinde üstün performans sergilemektedir [6]. Nesne algılama alanında YOLO (You Only Look Once) algoritması, tek aşamalı algılama yaklaşımıyla hız ve doğruluk arasında optimal bir denge sunarak öne çıkmaktadır [7]. YOLO'nun bir versiyonu olan YOLOv8, geliştirilmiş mimarisi, optimize edilmiş eğitim süreçleri ve transfer öğrenme yetenekleri sayesinde endüstriyel uygulamalarda yüksek performans sergilemektedir [8]

YOLOv8 mimarisi, bu serinin en güncel sürümlerinden biri olarak; değişken dış ortam koşullarına sahip trafik denetimi senaryolarında (%88.6 mAP) [9, 10], hassas tarım uygulamalarında ve yüksek hassasiyet gerektiren PCB hata tespitinde (%93.5 mAP) başarıyla kullanılmıştır [11]. Söz konusu çalışmalar, YOLOv8'in gürültülü arka planlar ve değişken ışık koşulları altındaki ayırt edici gücünü kanıtlamaktadır.

Güneş paneli denetimine yönelik literatür incelendiğinde, araştırmaların temel modelleri spesifik modifikasyonlarla geliştirme eğiliminde olduğu görülmektedir. Gu ve Chen [12], YOLOv3 mimarisine Koordinat Dikkat (CAM) ve Öz-Dikkat (SAM) modülleri ekleyerek (YOLOv3-MSSA) düşük çözünürlüklü hata tespitinde yüksek başarı elde etmişlerdir. Di Tommaso ve ark. [13] ise İHA tabanlı çok aşamalı bir modelle termal ve görünür spektrumu birleştirmiş, ancak görünür ışık spektrumunda ulaşılan %70 mAP değeri, bu spektrumdaki karmaşık anomalileri ayrıştırmada daha gelişmiş mimarilere ihtiyaç duyulduğunu ortaya koymuştur. Bu kısıtlamaları aşmak adına Zhang ve Yin [14] "deformable convolution" tekniklerini, Lei ve ark. [15] ise segmantasyon ve tespiti birleştiren "Deeplab-YOLO" modellerini önermişlerdir.

Güncel çalışmalar, YOLOv8'in yapısal esnekliğinden faydalanarak daha rafine çözümler sunmaya odaklanmıştır. Batool ve ark. [16], Sıkıştır-ve-Uyar (Squeeze-and-Excitation- SE) bloğu mekanizmalarıyla özellik haritalarını dinamik olarak yeniden ağırlıklandıran YOLOv8-SEB modeli ile %94.1 mAP değerine ulaşmıştır. Vaghela ve ark. [17], hiperparametre optimizasyonunun ve model ölçeklerinin (nano, küçük, orta) sınıflandırma kararlılığı üzerindeki etkisini vurgularken; Zhang ve ark. [18], ESD-YOLOv8 modeliyle P5 katmanını kaldırıp küçük nesnelere duyarlı P2 katmanını sisteme entegre ederek mikro kusurlara yönelik bir hassasiyet geliştirmişlerdir. Ayrıca Ye ve Xue [19], SIoU kayıp fonksiyonunu kullanarak regresyon maliyetini azaltmış ve yakınsama hızında %50 iyileşme sağlamışlardır. Saha operasyonları açısından Haeruman ve ark. [20] tarafından gerçekleştirilen drone tabanlı YOLOv7 uygulaması, otonom sistemlerin gerçek dünya koşullarındaki operasyonel verimliliğini doğrulamaktadır.

Bu çalışmanın temel motivasyonu, literatürdeki çok aşamalı veya mimari açıdan ağırlaştırılmış modellerin aksine, standart YOLOv8 mimarisini optimize edilmiş bir eğitim stratejisi ve özelleştirilmiş bir veri seti ile

kullanarak; 6 farklı arıza sınıfında (kar, toz, fiziksel hasar, kuş pisliği vb.) yüksek hassasiyetli bir tespit çerçevesi sunmaktadır. Elde edilen %94.3 mAP sonucu, literatürdeki modifiye edilmiş güncel modellerin performansını geride bırakarak, YOLOv8'in bütünleşik yapısının fotovoltaiik (FV) panel denetimindeki üstün genelleme kabiliyetini ispatlamaktadır. Bu bölümde ele alınan teknik yaklaşımların ve performans çıktılarının karşılaştırmalı analizi Tablo 1'de sunulmuştur.

Tablo 1. Nesne tespiti ve görüntü sınıflandırması için YOLO algoritması ile yapılan örnek çalışmalar

Kaynak	Kullanılan Mimari	Çalışma Alanı / Nesne Tipi	Temel Metodolojik Yaklaşım	mAP / (Doğruluk)
[11]	YOLOv8	PCB / Endüstriyel Kusur	Karmaşık üretim hatalarının tespiti.	%93.50 mAP
[12]	YOLOv3-MSSA	FV Panel / Sıcak Nokta	CAM ve SAM dikkat modülleri.	%98.86 (Doğruluk)
[13]	YOLOv3	FV Panel / Görünür ve IR	Çok aşamalı denetim sistemi.	%70.0 mAP
[14]	Gelişmiş YOLOv5	Güneş Hücresi / EL	Deformable Conv. ve 4. kafa.	%89.64 mAP
[15]	Deeplab-YOLO	FV Panel / Termal Hata	Segmantasyon + Tespit birleşimi.	+%0.7 mAP
[16]	YOLOv8-SEB	FV Panel / Çoklu Hata	SEB blokları ile dinamik ağırlıklandırma.	%94.10 mAP
[17]	YOLOv8 (n, s, m)	Uzaktan Algılama / Arazi	Hiperparametre ve varyant analizi.	%99.0 (Doğruluk)
[18]	ESD-YOLOv8	Güneş Hücresi / Mikro Kusur	P2 katmanı ekleme / P5 kaldırma.	%91.80 mAP
[19]	YOLOv8	Genel Nesne / Atık	SIoU kayıp fonksiyonu kullanımı.	%94.0 (Doğr.)
[20]	YOLOv7	FV Panel / Termal	İHA tabanlı termal video denetimi.	%85.90 mAP
Önerilen Yöntem	YOLOv8	FV Panel / 6 Arıza Sınıfı	Bütünleşik Optimize Mimari	%94.30 mAP

2. MATERYAL ve YÖNTEM (MATERIAL and METHOD)

2.1 Veri Seti (Data Set)

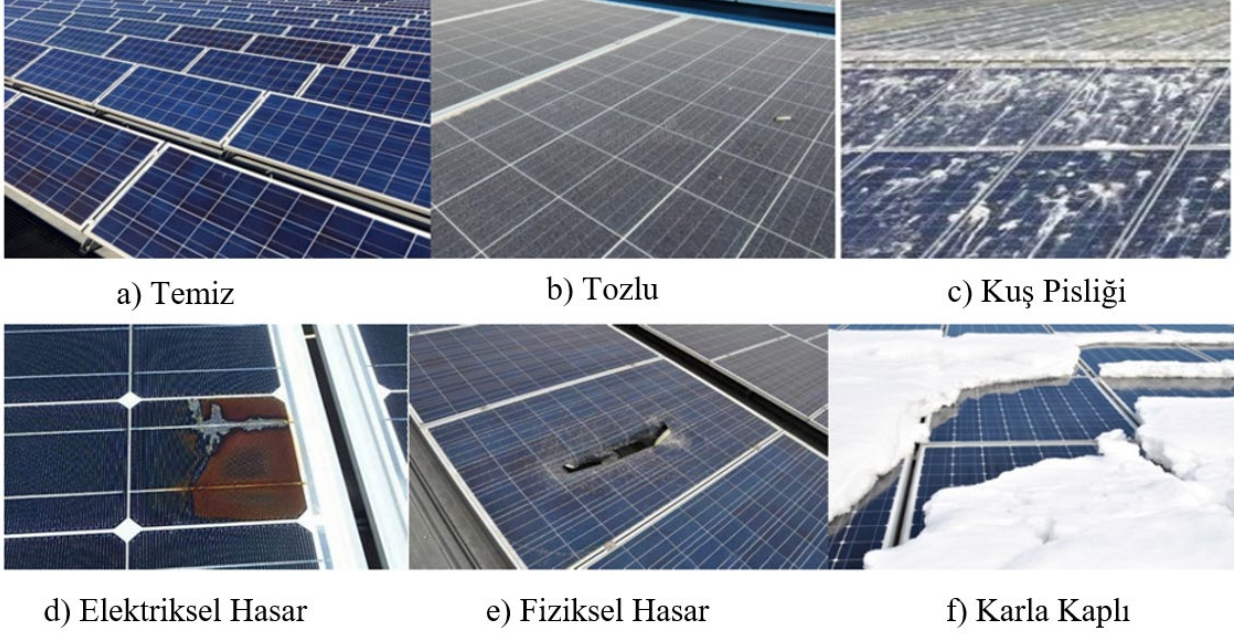
Bu çalışmada, Kaggle platformu üzerinden erişime sunulan [21] ve 887 adet yüksek çözünürlüklü güneş paneli görüntüsünden oluşan hazır bir veri seti kullanılmıştır. Veri seti; kuş pisliği, temiz, tozlu, elektriksel hasar, fiziksel hasar ve karla kaplı paneller olmak üzere toplam altı sınıfa ayrılmış görselleri içermektedir. Bu sınıflara ait örnek görüntüler Şekil 1'de sunulmuştur. Veri seti üzerinde analiz aşamasında kolaylık sağlaması adına Kaggle'daki orijinal sınıflandırma yapısı korunmuş, ancak metin içerisinde bu sınıfların Türkçe karşılıkları kullanılmıştır.

Görüntülerin etiketlenmesi ve veri seti yönetimi ROBOFLOW platformu [22] üzerinden gerçekleştirilmiştir. Veri seti; %70 eğitim, %20 doğrulama ve %10 test kümesi olacak şekilde üç bölüme ayrılmıştır. Bu ayırmda kullanılan kümelerin işlevleri şu şekildedir:

- **Eğitim Kümesi:** Modelin ağırlıklarını güncellediği ve güneş panellerindeki hasar özniteliklerini doğrudan öğrendiği ana veri grubudur.
- **Doğrulama Kümesi:** Modelin eğitim süreci devam ederken, daha önce görmediği veriler üzerindeki performansının anlık olarak izlendiği kümedir. Bu küme sayesinde modelin eğitim esnasındaki

hiperparametreleri optimize edilmekte ve aşırı öğrenme (overfitting) durumu kontrol altında tutulmaktadır.

- **Test Kümesi:** Model eğitimi ve optimizasyon işlemleri tamamen bittikten sonra kullanılan verilerdir. Bu küme, modelin daha önce hiç karşılaşmadığı örnekler üzerindeki nihai başarısını ve gerçek dünya senaryolarına karşı genelleme yeteneğini tarafsız bir şekilde ölçmek için kullanılır.



Şekil 1. Fotovoltaik Panellerde Karşılaşılan Çeşitli Arızalar (Various Faults Encountered in Photovoltaic Panels)

- a) Temiz (Clean): Panellerde herhangi bir kir veya hasar gözlenmeyen, normal çalışma koşullarını yansıtan bir durum.
- b) Tozlu (Dusty): Panellerin yüzeyinde biriken toz nedeniyle performans kaybına yol açabilecek bir arıza türü.
- c) Kuş Pisiği (Bird-Drop): Paneller üzerinde kuş pisliklerinin birikmesiyle oluşan ve verimliliği düşürebilen bir durum.
- d) Elektriksel Hasar (Electrical-Damage): Panellerde yanma veya kısa devre gibi elektriksel problemlerden kaynaklanan hasar.
- e) Fiziksel Hasar (Physical-Damage): Panellerde çatlaklar veya kırıklar gibi mekanik hasar türleri.
- f) Karla Kaplı (Snow-Covered): Panellerin kar birikimiyle örtülmesi sonucu enerji üretiminin kesintiye uğraması.

2.2 Veri Ön İşleme (Data Preprocessing)

Bu çalışmada kullanılan görüntüler, YOLOv8 modelinin giriş katmanına uyum sağlamak amacıyla 224×224 piksel boyutuna yeniden ölçeklendirilmiştir. Yeniden boyutlandırma işlemi sırasında görüntülerin en-boy oranı korunarak olası geometrik bozulmaların önüne geçilmiştir. Bu adım, modelin eğitim sürecinde tutarlı ve kararlı özellikler öğrenbilmesi açısından önem taşımaktadır.

Modelin genelleme yeteneğini artırmak ve aşırı öğrenme (overfitting) problemini azaltmak amacıyla çeşitli veri artırma teknikleri uygulanmıştır. Bu kapsamda görüntülere belirli açılarda döndürme, parlaklık ayarlamaları ile yatay ve dikey çevirme işlemleri gerçekleştirilmiştir. Uygulanan bu yöntemler sayesinde veri setinin çeşitliliği artırılmış ve modelin farklı çevresel koşullar, kamera açıları ve aydınlatma değişimlerine karşı daha dayanıklı olması hedeflenmiştir. Etiketleme süreci başlangıçta görüntüler

üzerindeki nesnelerin konumlarını ve sınıf bilgilerini içerecek şekilde XML formatında gerçekleştirilmiştir. Daha sonra bu etiketler, YOLOv8 modelinin eğitim gereksinimlerine uygun olacak biçimde YOLO formatına dönüştürülmüştür. Bu aşamada her bir nesne için sınıf etiketi ile birlikte normalize edilmiş sınırlar kutusu (bounding box) koordinatları düzenlenmiştir.

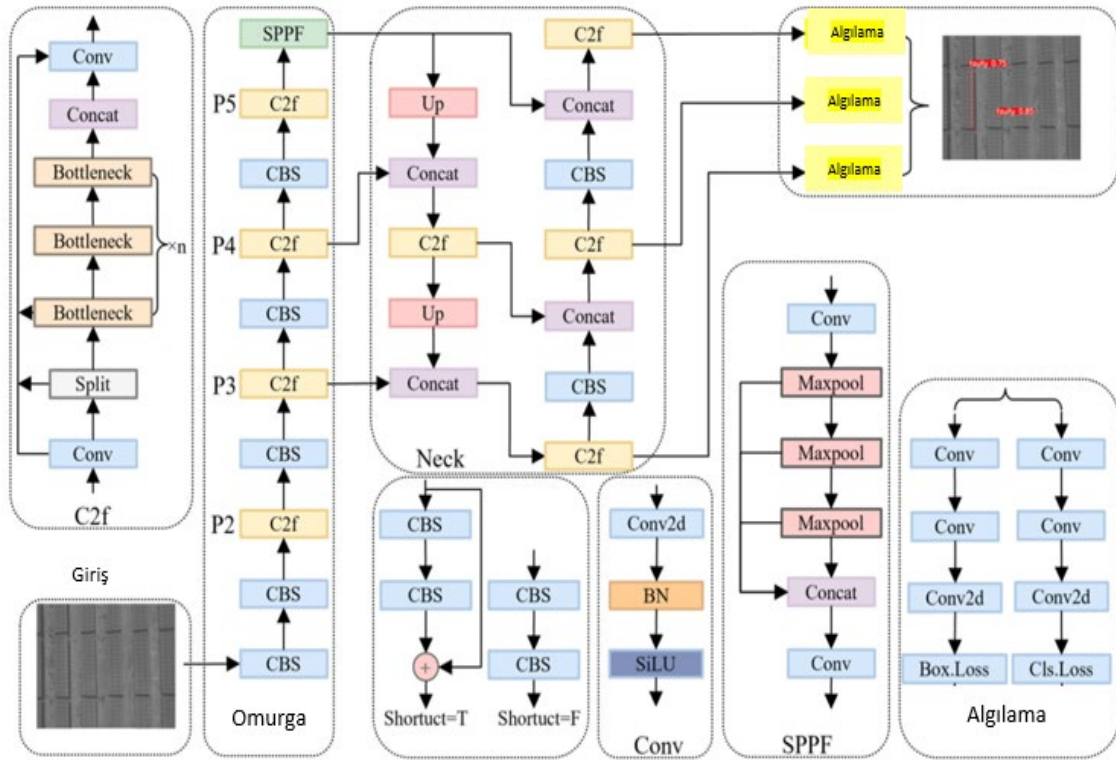
Sonuç olarak, gerçekleştirilen veri ön işleme adımları sayesinde veri seti, hem giriş boyutu, hem etiketleme yapısı hem de örnek çeşitliliği açısından YOLOv8 modelinin etkin bir şekilde eğitilmesine uygun hâle getirilmiştir.

2.3 YOLOv8 Modeli (YOLOv8 Model)

YOLO modeli, bilgisayarla görme alanında önemli bir dönüm noktasını temsil etmektedir. Üstün performansı ve verimliliği sayesinde kapsamlı araştırmalara ve uygulamalara konu olmuştur. Araştırmacılar, YOLO yöntemini sürekli olarak optimize etmiş; yeni modüller ekleyerek birçok klasik varyant modelin ortaya çıkmasına öncülük etmişlerdir. 2023 yılında Ultralytics tarafından tanıtılan YOLOv8, modelin en güncel sürümünü temsil etmekte olup YOLOv5 ve YOLOv7 gibi önceki modellere kıyasla önemli yenilikler ve güncel en iyi (SOTA) performans sunmaktadır [23].

YOLOv8 modeli; YOLOv8-n, YOLOv8-s, YOLOv8-m, YOLOv8-l ve YOLOv8-x olmak üzere beş farklı ağ yapısından oluşmaktadır. Şekil 2’de gösterildiği üzere YOLOv8 mimarisi, nesne tespiti, örnek düzeyinde bölütleme (instance segmentasyonu) ve görüntü sınıflandırma görevleri için bütünlük bir çerçeve sunmaktadır. YOLOv8 çerçevesi dört temel bileşenden oluşmaktadır: giriş katmanı, omurga (backbone) ağ katmanı, boyun (neck) yapı katmanı ve çıkış katmanı. Giriş katmanı, işleme sürecini başlatmakta; mozaik veri artırma, uyarlanabilir çapa (anchor) kutu hesaplaması ve gri tonlamalı dolgu gibi teknikleri uygulayarak görüntüyü sonraki işlem aşamaları için hazırlamaktadır [24].

Omurga ağ katmanı, Conv, C2f ve SPPF gibi modüller aracılığıyla özellik çıkarımından sorumludur. Omurga ağ katmanını çıkış katmanına bağlayan boyun yapı katmanı ise Özellik Piramit Ağı (Feature Pyramid Network – FPN) ve Yol Birleştirme Ağı (Path Aggregation Network – PAN) yapıları aracılığıyla farklı ölçeklerdeki özellikleri birleştirmekte ve bütünleştirmektedir. Bu sayede bağlamsal bilginin yakalanması güçlenmekte, farklı boyut ve konumlarda bulunan hedeflerin özellik temsili iyileştirilmektedir. Çıkış katmanı, nesne tespitine ilişkin tahmin sonuçlarını üretmekte ve fazla tespit kutularını ortadan kaldırmak amacıyla Maksimum Olmayan Bastırma (Non-Maximum Suppression – NMS) tekniğini kullanarak güvenilir ve hassas tahminlerin elde edilmesini sağlamaktadır. YOLOv8’in derin sinir ağı mimarisi, evrişimli sinir ağlarının (CNN) güçlü yeteneklerinden yararlanarak bir görüntüyü kapsamlı biçimde analiz edebilmekte; tespit edilen nesnelere sınırlayıcı kutular içerisinde sunmakta ve ilgili sınıf etiketleri ile güven skorlarını üretmektedir [25].



Şekil 2. YOLOv8 Modelinin Yapısı [18] (Structure of the YOLOv8 Model)

Tablo 2’de, kullanılan veri setinin sınıf dağılımı ve YOLOv8-s modelinin temel eğitim ayarları özetlenmiştir. Görsellerin boyutu, artırma teknikleri ve eğitim parametreleri, modelin performansını ve genelleme başarısını destekleyecek şekilde seçilmiştir. Tablo 2’de yer alan veri seti, XML formatında yapılan etiketlerin YOLO formatına dönüştürülmesiyle hazırlanarak modele sunulmuştur.

Tablo 2. Veri seti özellikleri ve model eğitim parametreleri (Dataset characteristics and model training parameters)

Kategori	Bilgi
Toplam Görsel Sayısı	887
Sınıflar ve Görsel Sayısı	Clean (147), Dusty (153), Bird-Drop (140), Electrical-Damage (132), Physical-Damage (170), Snow-Covered (145)
Görsel Boyutu	224 × 224 piksel
Veri Artırma Teknikleri	±30° döndürme, %25 parlaklık değişimi, yatay/çift eksenli çevirme
Artırma Amacı	Genelleme yeteneğini artırmak
Model	YOLOv8-s
Epoch Sayısı	50
Batch Size	16
Öğrenme Oranı	0.001
Optimizasyon Yöntemi	Adam
Eğitim Ortamı	Google Colab + Tesla T4 GPU

2.4 Performans Değerlendirme Metrikleri (Performance Evaluation Metrics)

Önerilen YOLOv8 tabanlı modelin güneş paneli arızalarını tespit ve sınıflandırma başarısını nicel olarak değerlendirmek amacıyla, literatürde nesne tespiti ve görüntü sınıflandırma görevleri için standart kabul edilen metrikler kullanılmıştır. Bu metriklerin hesaplanmasında kullanılan temel bileşenler; Doğru Pozitif

(TP: Modelin mevcut arızayı doğru sınıflandırması), Yanlış Pozitif (FP: Sağlam bölgenin hatalı şekilde arıza olarak sınıflandırılması) ve Yanlış Negatif (FN: Mevcut bir arızanın model tarafından tespit edilememesi) değerleridir [26].

Çalışmada kullanılan temel başarı kriterleri ve matematiksel modelleri aşağıda sunulmuştur:

Hassasiyet (Precision): Modelin pozitif olarak tahmin ettiği tüm örnekler içerisindeki gerçek pozitiflerin oranını ifade eder. Bu metrik, sistemin yanlış alarm (FP) verme eğilimini ölçer [27]:

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

Duyarlılık (Recall): Veri setinde yer alan tüm gerçek arızaların model tarafından başarıyla tespit edilme oranını temsil eder. Bakım süreçlerinde kritik olan "arıza gözden kaçırma" (FN) durumunu minimize etmeyi hedefler [27]:

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

Ortalama Hassasiyet (mAP): Nesne tespiti modellerinin başarısını değerlendirmede kullanılan en kapsamlı gösterge Ortalama Hassasiyet (mAP) metriğidir. Bu metrik, her bir sınıf için hesaplanan Hassasiyet-Duyarlılık (Precision-Recall) eğrisinin altında kalan alanın (AP) tüm sınıflar üzerindeki ortalamasını ifade eder. Bu çalışmada, modelin nesne konumlandırma ve sınıflandırma yeteneğini dengeli bir şekilde ölçmek amacıyla, Kutu Çakışma Oranı (IoU) eşliğinin 0.5 olduğu senaryoyu temsil eden mAP@0.5 metriği temel alınmıştır [28].

N toplam sınıf sayısını belirtmek üzere, mAP değeri aşağıdaki formül ile hesaplanmaktadır:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

Burada AP_i , i . sınıfa ait ortalama hassasiyeti temsil eder ve şu şekilde formülize edilir:

$$AP = \int_0^1 p(r) dr \quad (4)$$

Burada $p(r)$, duyarlılığın (r) bir fonksiyonu olarak hassasiyeti (p) ifade etmektedir. Bu metrik, özellikle güneş panellerindeki farklı ölçeklerdeki arızaların (örneğin; geniş alan kaplayan kar örtüsü ile küçük ölçekli fiziksel hasarlar) tespit edilme başarısının standartlaştırılmasını sağlamaktadır.

Sınıflandırma Metrikleri: Top-1 ve Top-5 Doğruluk

Modelin tahmin başarısını sadece nesne konumu bazlı değil, aynı zamanda etiket doğruluğu açısından da değerlendirmek amacıyla Top-1 ve Top-5 Doğruluk (Accuracy) metrikleri kullanılmıştır. Bu metrikler, özellikle güneş paneli arızaları gibi birbirine görsel olarak benzeyen (örneğin; tozlanma ve hafif gölgelenme) sınıfların ayırt edilmesindeki hassasiyeti ölçmektedir [29].

- **Top-1 Doğruluk:** Modelin en yüksek olasılık puanını verdiği ilk tahmininin, gerçek (ground truth) etiket ile tam olarak eşleşme oranını ifade eder. Bu, modelin "kesinlik" performansını gösteren en katı metriktir.

- **Top-5 Doğruluk:** Gerçek etiketin, modelin en yüksek olasılık atadığı ilk beş tahmin arasında yer alma oranını temsil eder. Bu metrik, modelin genel kategori bilgisini ve sınıflandırma kapasitesinin genişliğini ölçer.

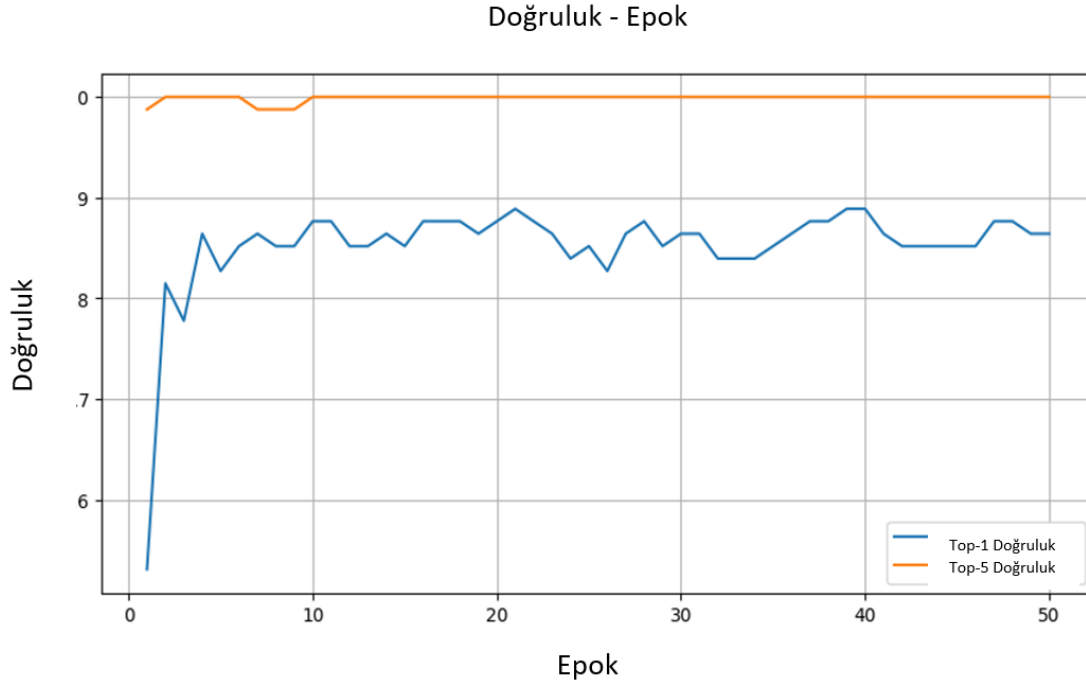
Sınıflandırma doğruluğu (Acc), I gösterge fonksiyonu (doğru tahminde 1, yanlışta 0) ve n örnek sayısı olmak üzere aşağıdaki şekilde formülize edilir:

$$Acc = \frac{1}{n} \sum_{i=1}^n I(\hat{y}_i = y_i) \quad (5)$$

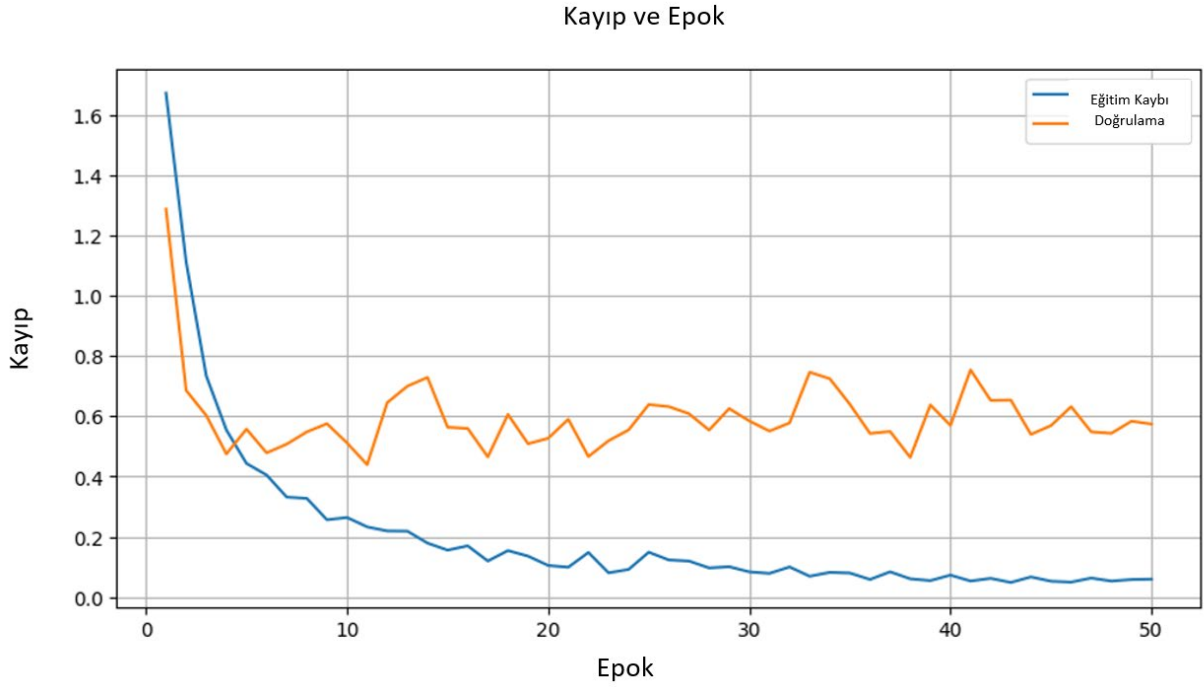
Burada \hat{y}_i tahmin edilen etiketi, y_i ise gerçek etiketi temsil etmektedir.

3. BULGULAR ve TARTIŞMA (RESULTS and DISCUSSIONS)

Bu makale çalışmasında, YOLOv8 modelinin güneş paneli görüntülerini tespit etme ve sınıflandırma performansına yönelik kapsamlı analizler gerçekleştirilmiştir. Çalışma, yenilenebilir enerji kaynaklarının etkin kullanımı ve arıza tespit süreçlerinin optimizasyonu amacıyla derin öğrenme tekniklerinin uygulanabilirliğini değerlendirmeyi amaçlamıştır. Şekil 3'te sunulan eğitim sürecinde doğruluk değişimi detaylı bir şekilde incelenmiştir; grafikte, Top-1 doğruluk oranı mavi çizgi ile temsil edilmekte ve eğitim boyunca yaklaşık 0.8-0.9 aralığında dalgalanmalar göstererek stabilize olmaktadır. Top-5 doğruluk oranı ise turuncu çizgi ile gösterilmiş ve başlangıçta 1.0'a yakın bir değere ulaşarak eğitim boyunca bu seviyenin üstünde sabit kalmıştır, bu da modelin çoklu sınıflandırma yetkinliğini ortaya koymaktadır.

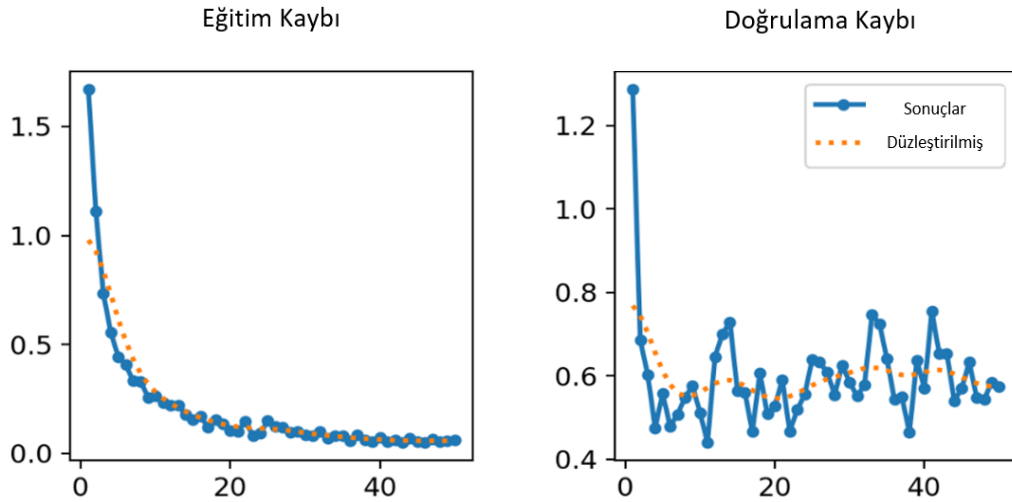


Şekil 3. Eğitim Süresince Doğruluk Değişimi (Accuracy Changes During Training)



Şekil 4. Eğitim Süresince Kayıp Değişimi (Loss and Change During Training)

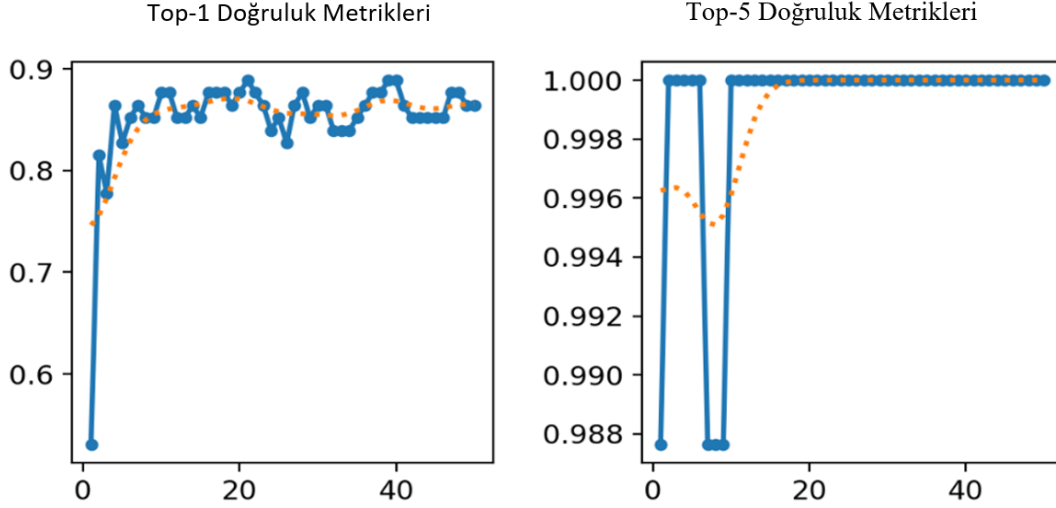
Şekil 4'te ise, eğitim (Train Loss) ve doğrulama (Val Loss) kayıpları epoch sayısına göre değerlendirilmiştir; Train Loss mavi çizgi ile temsil edilmekte ve ilk epochlardan itibaren hızlı bir düşüş göstererek yaklaşık 0.1 seviyesinde stabilize olmaktadır. Val Loss ise turuncu çizgi ile gösterilmiş ve başlangıçta 1.2 civarında seyrederek 0.5-0.7 aralığında dalgalanmalarla devam etmektedir, bu da modelin genelleme kabiliyetinde bazı iyileştirmelere ihtiyaç duyduğunu işaret etmektedir.



Şekil 5. Eğitim ve Doğrulama Kaybı Eğilimleri (Trends in Training and Validation Loss)

Şekil 5, eğitim (train/loss) ve doğrulama (val/loss) kayıplarının 40 epoch boyunca değişimini göstermektedir. Eğitim kaybı (mavi) başlangıçta yüksek bir değerden (yaklaşık 1.5) keskin bir düşüşle azalmakta ve daha sonra istikrarlı bir şekilde düşük seviyelere (yaklaşık 0.2) ulaşmaktadır. Düzleştirilmiş veri (turuncu) bu düşüşün genel trendini doğrulamaktadır. Öte yandan, doğrulama kaybı (mavi) başlangıçta 1.2 civarından düşse de, 20. epoch sonrasında dalgalanmalarla birlikte 0.4-0.8 aralığında seyretilmektedir;

düzleştirilmiş veri bu dalgalanmaların ortalamasını yansıtmaktadır. Bu durum, modelin eğitim verisine iyi uyum sağladığını, ancak doğrulama kaybındaki dalgalanmaların genelleme yeteneğinde sınırlamalar olabileceğini işaret etmektedir.



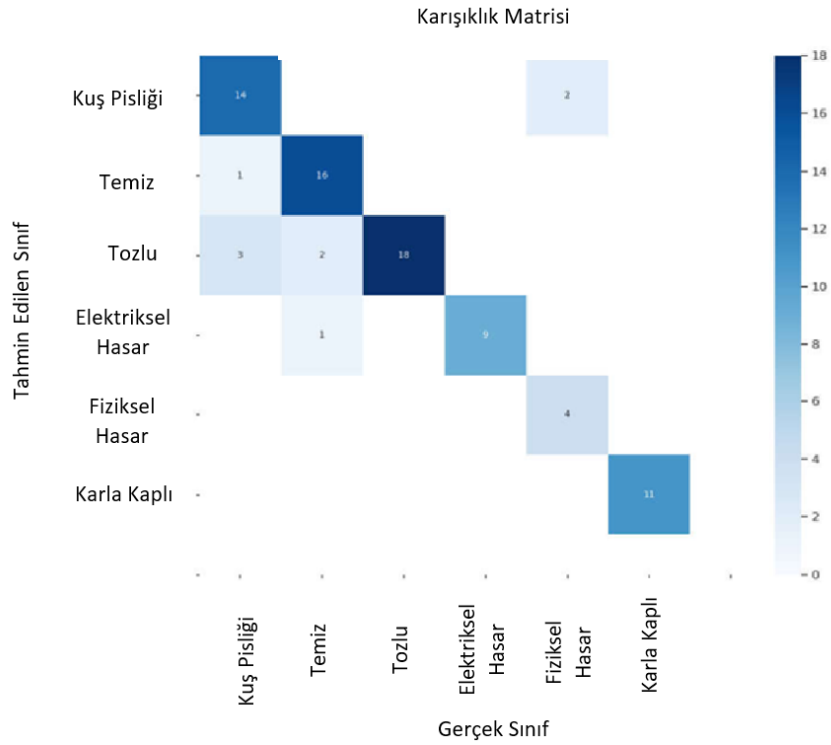
Şekil 6. Top-1 ve Top-5 Doğruluk Metrikleri (Top-1 and Top-5 Accuracy Metrics)

Şekil 6, modelin Top-1 ve Top-5 doğruluk metriklerini 40 epoch boyunca göstermektedir. Top-1 doğruluk (sol grafik), başlangıçta yaklaşık 0.6 seviyesinden yükselerek 0.9 civarına ulaşmış, ancak dalgalanmalarla birlikte bu seviye civarında sabitlenmiştir; düzleştirilmiş veri (turuncu) bu trendi yumuşatarak doğrulamaktadır. Top-5 doğruluk (sağ grafik) ise başlangıçta 0.988 civarından hızla artarak 1.0'a yaklaşmış ve 20. epoch sonrasında neredeyse sabit bir şekilde yüksek performans sergilemiştir; düzleştirilmiş veri bu yüksek doğruluk oranını desteklemektedir. Bu sonuçlar, modelin Top-5 tahminlerinde oldukça başarılı olduğunu, Top-1'de ise daha fazla iyileştirme potansiyeli olabileceğini göstermektedir.

Şekil 7'de verilen karışıklık matrisi, YOLO v8 modelinin test aşamasındaki sınıflandırma performansını göstermektedir. Matriste köşegen üzerinde yer alan değerler modelin doğru sınıflandırmalarını, köşegen dışındaki hücreler ise yanlış sınıflandırmaları ifade etmektedir. Model genel olarak başarılı sonuçlar vermiştir. Özellikle Snow-Covered ve Physical-Damage sınıflarında hatasız veya minimum hata ile tahminler yapılmıştır. Ancak bazı sınıflar arasında karışıklık gözlenmiştir. Örneğin, Bird-drop sınıfındaki bazı örnekler Dusty veya background sınıflarıyla karıştırılmıştır. Benzer şekilde Clean ve Dusty sınıfları arasında da kısmi bir karışıklık mevcuttur. Bu durum, ilgili sınıfların görsel benzerliklerinden veya verisetindeki örnek sayılarının dengesizliğinden kaynaklanıyor olabilir. Modelin doğruluk oranlarının daha da iyileştirilmesi için veri artırma (data augmentation) teknikleri veya örnek dağılımının dengelenmesi önerilmektedir.

3.1 Görsel Tahmin Analizi (Visual Prediction Analysis)

Modelin görsel başarımı Şekil 8 ve Şekil 9'da sunulan örnek çıktılarıyla desteklenmiştir. Her iki örnekte de modelin hedef sınıfa odaklanma başarısı ve diğer sınıfları dışlama yeteneği (0.00 olasılık değerleri) dikkat çekicidir.




Şekil 7. YOLO V8 Modelinin Test Aşamasındaki Karışıklık Matrisi (Confusion Matrix During the Testing Phase of the YOLO V8 Model)



Şekil 8. Temiz Sınıfı İçin Model Tahmin Çıktısı (Model Prediction Output for Clean Class)

Şekil 8'de görüldüğü üzere model, üzerinde herhangi bir hata veya kirlilik bulunmayan panel yüzeyini %97 (0.97) gibi yüksek bir güven skoruyla doğru bir şekilde sınıflandırmıştır. Panel üzerindeki ızgara çizgilerinin ve yansımaların karmaşıklığına rağmen modelin "Temiz" sınıfına odaklanması, yanlış pozitif (hatasız paneli hatalı görme) oranının düşük olduğunu ve modelin sağlam bir öznelik çıkarımı gerçekleştirdiğini göstermektedir.



Şekil 9. Fiziksel Hasar Sınıfı İçin Model Tahmin Çıktısı (Model Prediction Output for the Physical Damage Class)

Şekil 9, panel camındaki çatlak ve kırılmaları içeren bir görüntünün model tarafından analizini göstermektedir. Model, bu fiziksel hasar %99 (0.99) güven skoruyla "Physical-Damage" olarak tanımlamıştır. Karmaşık kırık desenleri ve cam yüzeydeki düzensiz ışık yansımalarına rağmen elde edilen bu yüksek kesinlik oranı, modelin mimari kapasitesinin ciddi hasarları ayırt etmede ne kadar hassas olduğunu tescil etmektedir.

3.2 Sınıf Bazlı Performans Analizi ve Değerlendirme (Class-Based Performance Analysis and Evaluation)

YOLOv8-s modelinin farklı arıza türlerini ayırt etme başarısını detaylandırmak amacıyla gerçekleştirilen sınıf bazlı performans analizleri Tablo 3'te sunulmuştur. Elde edilen veriler ışığında modelin başarısı şu şekilde değerlendirilmektedir.

Tablo 3. YOLOv8-s modelinin sınıf bazlı performans metrikleri (Class-based performance metrics of the YOLOv8-s model)

Sınıf	Hassasiyet (Precision)	Duyarlılık (Recall)	F1-Skoru
Temiz (Clean)	0.91	0.88	0.89
Tozlu (Dusty)	0.84	0.79	0.81
Kuş Pıslığı (Bird-Drop)	0.87	0.83	0.85
Elektriksel Hasar (Electrical-Damage)	0.93	0.90	0.91
Fiziksel Hasar (Physical-Damage)	0.95	0.94	0.94
Karla Kaplı (Snow-Covered)	0.98	0.97	0.97

Tablo 3 incelendiğinde, önerilen modelin özellikle Fiziksel Hasar ve Elektriksel Hasar sınıflarında sırasıyla %94 ve %91 F1-Skoru değerlerine ulaşarak oldukça yüksek bir başarı sergilediği görülmektedir. Bu bulgular, modelin güneş panelleri üzerindeki yapısal deformasyonları ve elektriksel anomali belirtilerini yüksek doğrulukla lokalize edebildiğini kanıtlamaktadır. En yüksek başarı ise görsel kontrastın en belirgin olduğu Karla Kaplı sınıfında (%97 F1-Skoru) elde edilmiştir.

Buna karşılık, Tozlu sınıfında diğer kategorilere kıyasla daha düşük bir performans gözlemlenmiş ve F1-Skoru değeri %81 olarak kaydedilmiştir. Bu durumun temel nedeni, düşük yoğunluklu toz birikintilerinin panel yüzeyinde oluşturduğu görsel dokunun, belirli ışık açılarında Temiz panel yüzeyi ile spektral benzerlik göstermesidir. Nitekim modelin doğruluk oranları genel ortalamada yüksek olsa da; Temiz, Tozlu ve Kuş Pıslığı sınıfları arasında sınırlı düzeyde bir karışıklık saptanmıştır. Söz konusu durum, sınıflar arasındaki morfolojik benzerliklerin yanı sıra veri seti içerisindeki sınıf dağılım dengesizliklerine de işaret etmektedir.

Genel bir değerlendirme yapıldığında, geliştirilen modelin farklı arıza türlerini ayırt etme yeteneğinin saha operasyonları için oldukça güçlü ve güvenilir olduğu görülmektedir. Modelin daha geniş kapsamlı ve sınıf dengesi optimize edilmiş veri setleriyle desteklenmesi, gerçek dünya senaryolarındaki genelleme kabiliyetini daha da ileriye taşıyacaktır.

4. SONUÇ (CONCLUSION)

Bu çalışma, YOLOv8 algoritmasının güneş paneli yüzeyinde oluşan arızaların tespiti ve sınıflandırılmasında etkili ve güvenilir bir derin öğrenme yöntemi olduğunu açıkça ortaya koymuştur. Elde edilen deneysel sonuçlar; yaklaşık %89 Top-1 doğruluğu, %99,1 Top-5 doğruluğu ve %94,3 mAP@0.5 değeri ile modelin yüksek başarı sergilediğini ve düşük kayıp oranlarına sahip olduğunu göstermektedir. Bu performans göstergeleri, güneş enerjisi santrallerinde yürütülen denetim süreçlerinin otomatikleştirilmesi açısından yüksek hassasiyetli bir çözüm sunmaktadır.

Çalışma kapsamında elde edilen bulgular, YOLOv8 modelinin güneş panellerindeki hataların otomatik sınıflandırılmasında umut vadeden bir performansa sahip olduğunu ortaya koymaktadır. Algoritmanın nesne tespiti, segmentasyon ve sınıflandırma görevlerini tek ve bütünleşik bir mimari içerisinde gerçekleştirebilmesi, özellikle enerji sektöründeki büyük ölçekli tesisler için ölçeklenebilir ve sürdürülebilir bir denetim yaklaşımı sağlamaktadır.

Gelecek çalışmalar kapsamında, modelin performansını ve saha uygulanabilirliğini artırmaya yönelik olarak aşağıdaki adımlar önerilmektedir: Daha geniş ölçekli ve sınıf dengesi gözetilerek oluşturulmuş veri setleriyle eğitim süreçlerinin desteklenmesi; YOLOv8-n (nano) gibi hafif modeller kullanılarak düşük donanım kapasitesine sahip kenar cihazlar ve insansız hava araçları (İHA) üzerinde gerçek zamanlı saha testlerinin gerçekleştirilmesi; ayrıca modelin genelleme yeteneğini artırmak amacıyla Vision Transformer (ViT) tabanlı mimarilerle hibrit yaklaşımların araştırılması.

Bu iyileştirmelerin, geliştirilen sistemin endüstriyel güneş enerjisi tesislerine daha hızlı, güvenilir ve maliyet etkin bir şekilde entegre edilmesine katkı sağlayacağı öngörülmektedir. Sonuç olarak bu çalışma, yapay zekâ tabanlı otonom denetim sistemlerinin güneş enerjisi santrallerinde işletme ve bakım maliyetlerini düşürme potansiyeline sahip olduğunu hem akademik hem de uygulamalı açıdan doğrulamaktadır.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

ARAŞTIRMA ve YAYIN ETİĞİ BEYANI (STATEMENT OF PUBLICATION ETHICS)

Çalışmanın tüm süreçlerinin araştırma ve yayın etiğine uygun olduğunu, etik kurallara ve bilimsel atıf gösterme ilkelerine uyduğunu beyan ederim.

YAZAR KATKISI (AUTHOR STATEMENT)

Araştırma tasarımı, literatür taraması ve değerlendirilmesi, veri toplama, veri analizi, verilerin ve analizlerin doğrulanması, bulguların yorumlanması ve makalenin yazılması süreçlerinin tamamı **Hussein Yousefalturk** tarafından gerçekleştirilmiştir. Çalışma sürecinde danışmanlık, yönlendirme ve denetleme faaliyetleri **Yurdagül Benteşen Yakut** tarafından yürütülmüştür.

KAYNAKLAR (REFERENCES)

- [1] REN21, Renewables 2023 Global Status Report, Renewable Energy Policy Network for the 21st Century, 2023.

- [2] Kannan, R., Leong, K. C., Osman, R., Ho, H. K., & Tso, C. P. (2006). Life cycle assessment study of solar PV systems: An example of a 2.7 kWp distributed solar PV system in Singapore. *Solar energy*, 80(5), 555-563.
- [3] Mekhilef, S., Saidur, R., & Kamalisarvestani, M. (2012). Effect of dust, humidity and air velocity on efficiency of photovoltaic cells. *Renewable and sustainable energy reviews*, 16(5), 2920-2925.
- [4] Li, B., Delpha, C., Diallo, D., & Migan Dubois, A. (2021). Application of artificial neural networks to photovoltaic fault detection and diagnosis: A review. *Renewable & Sustainable Energy Reviews*, 138, 110512. <https://doi.org/10.1016/j.rser.2020.110512>
- [5] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- [6] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- [7] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- [8] Ultralytics, YOLOv8: A New State-of-the-Art in Object Detection, [Online] (2023). Erişim: <https://docs.ultralytics.com>.
- [9] Önder, Ö., & Karan, Y. (2024). Çay ve Eğrelti Otunun YOLOv5 ve YOLOv8 Algoritmaları ile Karşılaştırmalı Tespiti. *Recep Tayyip Erdogan University Journal of Science and Engineering*, 5(1), 74-88.
- [10] Alemdar, K. D. (2024). Çift Sıra Parklanma Durumunun Nesne Tespit Algoritması YOLOv8 ile Tespit Edilmesi. *Journal of the Institute of Science and Technology*, 14(3), 1164-1176.
- [11] Budak, İ., Bal, S., & Korkmaz, H. (2025). PCB Üretiminde Çok Sınıflı Kusur Tespiti için YOLO Tabanlı Derin Öğrenme Modeli. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 25(4), 816-826.
- [12] Gu, K., & Chen, Y. (2024). YOLOv3-MSSA based hot spot defect detection for photovoltaic power stations. *Journal of Measurements in Engineering*, 12(1), 23-39.
- [13] Di Tommaso, A., Betti, A., Fontanelli, G., & Michelozzi, B. (2022). A multi-stage model based on YOLOv3 for defect detection in PV panels based on IR and visible imaging by unmanned aerial vehicle. *Renewable energy*, 193, 941-962.
- [14] Zhang, M., & Yin, L. (2022). Solar cell surface defect detection based on improved YOLO v5. *IEEE access*, 10, 80804-80815.
- [15] Lei, Y., Wang, X., An, A., & Guan, H. (2024). Deeplab-YOLO: A method for detecting hot-spot defects in infrared image PV panels by combining segmentation and detection. *Journal of Real-Time Image Processing*, 21(2), 52.
- [16] Batool, A., Kim, Y. W., & Byun, Y. C. (2025). Improved YOLOv8 framework for efficient solar panel defect detection. *Journal of Building Engineering*, 111, 113031.
- [17] Vaghela, R., Vaishnani, D., Srinivasu, P. N., Popat, Y., Sarda, J., Woźniak, M., & Ijaz, M. F. (2025). Land cover classification for identifying the agriculture fields using versions of yolo v8. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- [18] Zhang, L., Wu, X., Liu, Z., Yu, P., & Yang, M. (2024). ESD-Yolov8: an efficient solar cell fault detection model based on Yolov8. *IEEE Access*, 12, 138801-138815.
- [19] Ye, K., & Xue, Y. (2023, November). Image recognition of garbage classification based on YOLOv8. In *7th International Conference on Vision, Image and Signal Processing (ICVISIP 2023)* (Vol. 2023, pp. 145-149). IET.
- [20] Haeruman, A., Haq, S. U., Mohandes, M., Rehman, S., & Mitu, S. S. I. (2024). Ai-based pv panels inspection using an advanced yolo algorithm. *Materials Research Proceedings*, 43.
- [21] Kaggle, Kaggle Datasets, [Çevrimiçi]. (2025). Erişim: <https://www.kaggle.com/datasets>.
- [22] Roboflow, Roboflow Universe, [Çevrimiçi].(2025) Erişim: <https://universe.roboflow.com>.
- [23] G. Jocher, A. Chaurasia, J. Qiu, Ultralytics YOLO, [Online]. (2023). Erişim: <https://github.com/ultralytics/ultralytics>.
- [24] Li, Y., Fan, Q., Huang, H., Han, Z., & Gu, Q. (2023). A modified YOLOv8 detection network for UAV aerial image recognition. *Drones*, 7(5), 304.
- [25] Reis, D., Kupec, J., Hong, J., & Daoudi, A. (2023). Real-time flying object detection with YOLOv8. *arXiv preprint arXiv:2305.09972*.
- [26] Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.

- [27] Powers, D. M. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. arXiv preprint arXiv:2010.16061.
- [28] Everingham, M., Van Gool, L., Williams, C. K., Winn, J., & Zisserman, A. (2010). The pascal visual object classes (voc) challenge. International journal of computer vision, 88(2), 303-338.
- [29] Kılıç, K., Özcan, U., Kılıç, K., & Dogru, İ. (2024). Using deep learning techniques furniture image classification. Politeknik Dergisi, 27(5), 1903-1911.



© Author(s) 2026. This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>