

**T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**FOTOVOLTAİK ENERJİ SANTRALLERİNDE
YOLO TABANLI GÖRÜNTÜ İŞLEME
ALGORİTMALARI İLE SICAK NOKTA
ANOMALİLERİNİN TESPİTİ**

Mustafa DANACI

Danışman: Doç. Dr. Ahmet ÇİFCİ

BURDUR, 2025

ETİK KURALLARA UYGUNLUK BEYANI

Burdur Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca **Yüksek Lisans Tezi** olarak sunduğum “**Fotovoltaik Enerji Santrallerinde YOLO Tabanlı Görüntü İşleme Algoritmaları ile Sıcak Nokta Anomalilerinin Tespiti**” başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

11/08/2025

(İmza)

Mustafa DANACI

ÖNSÖZ

Bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan değerli Danışman Hocam Doç. Dr. Ahmet ÇİFCİ'ye teşekkürlerimi sunarım. Tezimi tamamlayabilmem için benimle bilgi ve deneyimlerini paylaşan araştırmalarım süresince hiçbir yardımı esirgemeyen değerli hocam Prof. Dr. İsmail KIRBAŞ'a da teşekkür ederim.

Makine öğrenmesi algoritmalarında kullanmak üzere paylaştığı veri seti için Aydıncan KARANACAKOĞLU'na teşekkür ederim.

Araştırmalarım sırasında yardımlarını gördüğüm arkadaşlarıma teşekkür ederim.

Eğitim hayatımın her aşamasında beni her anlamda destekleyen kıymetli babam, annem ve ablama sonsuz sevgi ve saygılarımı sunarım.

Kerem Ege'ye...

Ağustos, 2025

Mustafa DANACI

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
ÇİZELGELER DİZİNİ	vi
SİMGELER VE KISALTMALAR DİZİNİ	vii
ÖZET.....	viii
ABSTRACT.....	ix
1. GİRİŞ.....	1
1.1. Kaynak Taraması	2
1.2. Tezin İçeriği ve Amacı.....	7
1.3. Tezin Organizasyonu	8
2. GENEL BİLGİLER.....	10
2.1. Fotovoltaik Güneş Panelleri.....	10
2.2. Güneş Panellerinde Görülen Arıza Türleri ve Nedenleri.....	12
2.3. Kızılötesi Görüntüleme Teknikleri ile Tespit Edilebilecek Arıza Türleri	13
2.3.1. Dizi Anomalileri	14
2.3.2. Diyot Arızaları	14
2.3.3. Kuş Pisliği	16
2.3.4. Gölgeleme	17
2.3.5. Tozlanma.....	19
2.3.6. Sıcak Nokta (Hotspot).....	20
2.4. YOLO Algoritması ve Sürümlerinin Gelişim Süreci.....	21
2.5. YOLO Algoritması Sıcak Nokta Tespiti.....	23
3. MATERYAL VE YÖNTEM	24
3.1. Çalışma Alanı.....	24
3.2. Veri Toplama ve Hazırlık Süreci	25
3.3. Veri Setinin İçeriği.....	27
3.4. Çalışmada Kullanılan YOLO Algoritmaları	28
3.4.1. YOLOv9.....	28
3.4.2. YOLOv10.....	29
3.4.3. YOLOv11.....	30
3.4.4. YOLOv12.....	32
3.5. Performans Değerlendirme Metrikleri	34
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	37
5. SONUÇ VE ÖNERİLER	69
KAYNAKLAR	71

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Teknolojiye göre yenilenebilir elektrik üretiminin payı, 2000-2030	1
Şekil 2.1. Bir güneş enerji sisteminin bileşenleri	10
Şekil 2.2. Bir fotovoltaiik panele ait güneş hücrelerinin modellemesi	11
Şekil 2.3. Güneş hücresi bileşenleri	11
Şekil 2.4. Termal görüntüleme ile tespit edilen birkaç arıza örneği.....	13
Şekil 2.5. Termal kamera ile tespit edilen dizi anomalileri.....	14
Şekil 2.6. Bypass diyotlarının paneldeki gölgeli alanı devreden çıkarışı.....	15
Şekil 2.7. Termal kamera ile tespit edilen diyot arızaları.....	15
Şekil 2.8. Kuş pisliği görüntüsü (a) RGB kamerada, (b) Termal kamerada	16
Şekil 2.9. FV panel üzerine düşen (a) direk gölgesi, (b) yabancı otların gölgeleri.....	17
Şekil 2.10. Yabancı ot kaynaklı termal kamera ile tespit edilen gölgelenmeler	18
Şekil 2.11. (a) Hayvan otlatma metodu ile vejetasyon bakımı, (b) Gölge sorunu oluşturmayacak şekilde köşk yeri seçimi örneği	19
Şekil 2.12. Tozlanma sorununun tespiti; (a) RGB kamerada, (b) kızılötesi kamerada	19
Şekil 2.13. Termal kamera ile tespit edilen sıcak nokta arızaları.....	20
Şekil 2.14. YOLO algoritma ailesinin kronolojik gelişim zaman çizelgesi (2015-2025).....	22
Şekil 2.15. (a) Sıcak nokta verisi, (b) veri etiketlenmesi, (c) YOLO'nun tespiti.....	23
Şekil 3.1. 2004-2021 yılları ortalama küresel güneş radyasyonu dağılım haritası	24
Şekil 3.2. GEPA'ya göre Manisa ilinin; (a) Global radyasyon değerleri (kWh/m ² -gün), (b) Güneşlenme süreleri (saat)	25
Şekil 3.3. İHA'nın santral sahasındaki uçuş güzergahı.....	25
Şekil 3.4. Çalışmanın temel adımları	26
Şekil 3.5. Çalışmada kullanılan veri setinin dağılımı.....	27
Şekil 3.6. YOLOv9 algoritmasının mimarisi	29
Şekil 3.7. YOLOv10 algoritmasının mimarisi	30
Şekil 3.8. YOLOv11 algoritmasının mimarisi	31
Şekil 4.1. YOLO modellerinin eğitimi için takip edilen adımlar	38
Şekil 4.2. EXIF verileri ile konumları belirlenen sıcak nokta arızalarının ısı haritası	39
Şekil 4.3. Modellerin karışıklık matrisi değerleri.....	39
Şekil 4.4. Modellerin karışıklık matrisi değerleri.....	42

Şekil 4.5. Modellerin sıcak nokta tespitleri; (a) görselin aslı, (b) YOLOv9, (c) YOLOv10, (d) YOLOv11, (e) YOLOv12.....	43
Şekil 4.6. YOLOv9 t modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri	45
Şekil 4.7. YOLOv9 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri	46
Şekil 4.8. YOLOv9 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	47
Şekil 4.9. YOLOv9 c modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri	48
Şekil 4.10. YOLOv9 e modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	49
Şekil 4.11. YOLOv10 n modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	50
Şekil 4.12. YOLOv10 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	51
Şekil 4.13. YOLOv10 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	52
Şekil 4.14. YOLOv10 b modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	53
Şekil 4.15. YOLOv10 l modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	54
Şekil 4.16. YOLOv10 x modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	55
Şekil 4.17. YOLOv11 n modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	56
Şekil 4.18. YOLOv11 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	57
Şekil 4.19. YOLOv11 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	58
Şekil 4.20. YOLOv11 l modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	59
Şekil 4.21. YOLOv11 x modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	60

Şekil 4.22. YOLOv12 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	62
Şekil 4.23. YOLOv12 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	63
Şekil 4.25. YOLOv12 l modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	64
Şekil 4.26. YOLOv12 x modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri.....	65



ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. YOLO modellerine ait özellikler ve farklar.....	34
Çizelge 4.1. Modellerin eğitim parametreleri	37
Çizelge 4.2. YOLO modellerinin karşılaştırmalı performans metrikleri.....	41



SİMGELER VE KISALTMALAR DİZİNİ

A2	: Alan Dikkat Modülü
AC	: Alternatif Akım
ACF	: Uyarlanabilir Tamamlayıcı Füzyon
AP	: Ortalama Hassasiyet
C2PSA	: Paralel Mekânsal Dikkatli Evrişim Bloğu
C3k2	: Çekirdek Boyutu 2 Olan Aşamalar Arası Kısmi Bağlantı Bloğu
CBAM	: Evrişimsel Blok Dikkat Modülü
CBS	: Evrişimsel Normalleştirme Bloğu
CNN	: Evrişimli Sinir Ağı
CO₂	: Karbondioksit
COCO	: Bağlam İçindeki Yaygın Nesneler Veri Seti
DC	: Doğru Akım
EVA	: Etilen Vinil Asetat
EXIF	: Değiştirilebilir Görüntü Dosyası Biçimi
F1	: F1 Skoru
Faster R-CNN	: Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağı
FBG	: Fiber Bragg Izgarası
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
FPS	: Saniye Başına Kare Sayısı
FV	: Fotovoltaik
GELAN	: Genelleştirilmiş Etkin Katman Toplama Ağı
GEPA	: Güneş Enerjisi Potansiyeli Atlası
GES	: Güneş Enerjisi Santrali
GPU	: Grafik İşlem Birimi
İHA	: İnsansız Hava Aracı
IEA	: Uluslararası Enerji Ajansı (International Energy Agency)
IoU	: Birleşim Üzerinden Kesişim
mAP	: Ortalama Hassasiyet
MGM	: Meteoroloji Genel Müdürlüğü
n tipi	: Negatif Tip

NMS	: Maksimum Olmayanları Bastırma
p tipi	: Pozitif Tip
PGI	: Programlanabilir Gradyan Bilgisi
PV-YOLO	: Fotovoltaik YOLO
PVTv2	: Piramidal Görsel Dönüştürücü Sürüm 2
R	: Duyarlılık (Recall)
R-ELAN	: Artık Verimli Katman Toplama Ağları
RGB	: Kırmızı, Yeşil, Mavi
SDS-YOLO	: Ölçek Bağımlı Anlamsal YOLO
Si	: Silisyum
SK-FRCNN	: Seçici Çekirdek Dikkat Mekanizmalı Hızlı R- Evrişimli Sinir Ağı
SPPF	: Hızlı Mekânsal Piramit Havuzlama
ST-YOLO	: Mekânsal-Zamansal YOLO Algoritması
TN	: Doğru Negatif
TP	: Doğru Pozitif
YEGM	: Yenilenebilir Enerji Genel Müdürlüğü
YOLO	: Sadece Bir Kez Bak Algoritması (You Only Look Once)
YOLO-ACF	: Uyarlanabilir Tamamlayıcı Birleşim Modüllü YOLO Varyantı
ΔT	: Sıcaklık Farkı

ÖZET

Yüksek Lisans Tezi

Fotovoltaik Enerji Santrallerinde YOLO Tabanlı Görüntü İşleme Algoritmaları ile Sıcak Nokta Anomalilerinin Tespiti

Mustafa DANACI

Burdur Mehmet Akif Ersoy Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ahmet ÇİFCİ

Ağustos, 2025

Fotovoltaik (FV) enerji santrallerinin verimliliği ve operasyonel güvenliği, panellerde meydana gelen sıcak nokta gibi anomalilerin erken tespitiyle doğrudan ilişkilidir. Bu tez çalışmasının temel amacı, derin öğrenme tabanlı nesne tespiti algoritmalarından olan YOLO'nun (You Only Look Once) dört farklı versiyonunu (YOLOv9, YOLOv10, YOLOv11 ve YOLOv12) kullanarak FV panellerdeki sıcak nokta anomalilerinin tespit performansını karşılaştırmalı olarak analiz etmektir. Çalışma kapsamında, bir güneş enerji santralinden İnsansız Hava Aracı (İHA) ile toplanan termal görüntülerden oluşan bir veri seti kullanılmıştır. Modellerin performansı; kesinlik, duyarlılık, F1 skoru, mAP50 ve mAP50-95 gibi standart metrikler kullanılarak nesnel bir biçimde değerlendirilmiştir. Yapılan analizler neticesinde, özellikle YOLOv9 m ve YOLOv11 s modellerinin, diğer modellere kıyasla sıcak nokta tespiti görevinde daha istikrarlı ve yüksek doğrulukta sonuçlar ürettiği gözlemlenmiştir. YOLOv11 s modeli, yüksek duyarlılık ve F1 skoru ile öne çıkarken; YOLOv9 m modeli ise özellikle zorlu tespit koşullarını yansıtan mAP50-95 metriğinde en yüksek başarıyı göstermiştir. Bu bulgular, söz konusu modellerin FV santrallerinin bakım ve denetim süreçlerinde pratik olarak etkin bir şekilde kullanılabileceğini ortaya koymaktadır. Ayrıca, tez kapsamında geliştirilen ve tespit edilen anomalilerin coğrafi koordinatlarla haritalandırılmasına dayalı metodoloji, bakım operasyonlarının otomasyonu ve optimizasyonu için önemli bir potansiyel sunmaktadır.

Anahtar Kelimeler: derin öğrenme, fotovoltaik panel, sıcak nokta tespiti, termal görüntüleme, YOLO

ABSTRACT

M.Sc. Thesis

Detection of Hot Spot Anomalies in Photovoltaic Power Plants Using YOLO-Based Image Processing Algorithms

Mustafa DANACI

**Burdur Mehmet Akif Ersoy University
Graduate School of Natural and Applied Sciences
Department of Electrical-Electronics Engineering**

Supervisor: Assoc. Prof. Dr. Ahmet ÇİFCİ

August, 2025


The efficiency and operational safety of photovoltaic (PV) power plants are directly related to the early detection of anomalies such as hotspots on the panels. The primary objective of this thesis is to conduct a comparative analysis of the performance of four different versions of the You Only Look Once (YOLO) algorithm (YOLOv9, YOLOv10, YOLOv11, and YOLOv12), a deep learning-based object detection method, for detecting hotspot anomalies in PV panels. Within the scope of this study, a dataset consisting of thermal images collected by an Unmanned Aerial Vehicle (UAV) from a solar power plant was utilized. The performance of the models was objectively evaluated using standard metrics, including precision, recall, F1-score, mAP50, and mAP50-95. The analyses revealed that the YOLOv9 m and YOLOv11 s models, in particular, produced more stable and highly accurate results in the hotspot detection task compared to the other models. The YOLOv11s model stood out with its high recall and F1-score, while the YOLOv9m model demonstrated the best performance in the mAP50-95 metric, which reflects challenging detection conditions. These findings indicate that the aforementioned models can be effectively and practically implemented in the maintenance and inspection processes of PV power plants. Furthermore, the methodology developed in this thesis, which involves mapping detected anomalies with their geographical coordinates, offers significant potential for the automation and optimization of maintenance operations.

Keywords: deep learning, photovoltaic panel, hot spot detection, thermal imaging, YOLO

1. GİRİŞ

Küresel ısınma ve iklim değişikliği, gezegenimizin karşı karşıya kaldığı en acil sorunlardan biridir. 2023 itibarıyla sanayi öncesi seviyenin yaklaşık 1,2 °C üzerinde seyreden küresel sıcaklık artışı, aşırı hava olaylarını ve çevresel felaketleri daha sık ve daha şiddetli hâle getirmektedir (Soukharev, 2025; Banu ve Fazal, 2025). Bu durum, atmosferdeki karbondioksit (CO₂) emisyonlarının hızla artmasıyla doğrudan ilişkilendirilmekte olup, Uluslararası Enerji Ajansı'nın (International Energy Agency - IEA) raporuna göre 2023 yılında da küresel CO₂ salınımında artış gözlenmiştir (IEA, 2023; IEA, 2024a). Ancak bu artışın hızı, yenilenebilir enerji kaynaklarının kullanımının yaygınlaşmasıyla önemli ölçüde yavaşlatılabilmektedir.

Yenilenebilir enerji, dünya genelinde elektrik üretiminin dönüşümünde kilit rol oynamaktadır. IEA verilerine göre, 2030 yılına kadar elektrik üretiminde yenilenebilir enerji kaynaklarının payının %45'e ulaşması öngörülmekte olup, bu artışta en önemli itici güçlerden birinin güneş enerjisi olması beklenmektedir (Islam vd., 2014; Obaideen vd., 2023; IEA, 2024c). Enerji üretiminde mevcut ve öngörülen kaynakların dağılımı, IEA verileri doğrultusunda Şekil 1.1'de sunulmuştur (IEA, 2024c).



Şekil 1.1. Teknolojiye göre yenilenebilir elektrik üretiminin payı, 2000-2030 (IEA, 2024c kaynağından düzenlenerek oluşturulmuştur.)

Güneş enerji sistemlerinin karbon emisyonunu azaltmadaki payı, hem üretim aşamasında ortaya çıkan sera gazı miktarının görece düşük olması hem de işletme ömrü

boyunca karbon salınımının neredeyse sıfıra yakın olması sebebiyle kritik önem taşımaktadır (Jordan vd., 2017). Türkiye de son yıllarda güneş enerjisi alanında ciddi yatırımlar yapmış ve 2017-2027 yılları arasında 10 GW ek solar kapasite kurmayı hedeflemiştir (IEA, 2021).

Güneş enerji santrallerinin verimli ve sürdürülebilir çalışması, sahada kurulan panellerin bakım ve izleme süreçlerinin etkin bir şekilde yürütülmesine bağlıdır (Santhakumari ve Sagar, 2019; Al Mahdi vd., 2024). Zira uzun ömürlü olarak tasarlanan panellerde üretici firmalar 20-25 yıla kadar yüksek performans garantisi verse de, zaman içinde ortaya çıkan arızalar ve performans kayıpları kaçınılmazdır (Goudelis vd., 2022). Söz konusu arızalar arasında hücre çatlakları, delaminasyon, bağlantı kutusu kaynaklı problemler, diyot arızaları, dizi uyumsuzlukları ve sıcak nokta (hotspot) olarak adlandırılan sıcaklık anomalileri öne çıkmaktadır (Balachandran vd., 2024; Belhachat vd., 2024; Jalal vd., 2024). Özellikle sıcak nokta arızaları, gölgelenme ya da hücreler arasındaki hatalı bağlantılar sonucu panelin belli bölgelerinde aşırı ısınmaya sebep olarak hem enerji üretiminde kayıplara hem de yangın riski gibi ciddi güvenlik sorunlarına yol açabilmektedir (Wu vd., 2020; Lamb vd., 2022).

Bu tür arızaların erken tespiti ve önlenmesi, güneş enerjisi sistemlerinin performansını iyileştirmede kritik bir adımdır (Ghanbari, 2017). Geleneksel tespit yöntemleri, kızılötesi görüntüleme, elektrolüminans ve ultrasonik inceleme gibi çeşitli tekniklere dayanmaktadır (Han vd., 2025). Bununla birlikte, teknolojinin ilerlemesiyle beraber nesne tespiti alanında popülerliği artan Sadece Bir Kez Bak (You Only Look Once - YOLO) algoritmaları, görüntü işleme temelli hataların tanısında ve teşhisinde önemli avantajlar sunmaya başlamıştır (Bochkovskiy vd., 2020; Hussain, 2024). YOLO algoritmaları, düşük gecikme süreleri ve yüksek doğruluk oranları sayesinde gerçek zamanlı izleme ve arıza saptama uygulamalarında tercih edilmektedir (Hussain, 2024).

1.1. Kaynak Taraması

Duranay, farklı fotovoltaik (FV) panel kusurlarını (sıcak noktalar dahil) %89 doğrulukla tespit etmek için bir artık evrişimli sinir ağı kullanırken, aynı çalışmada atıfta bulunulan Açıkgoz, AlexNet mimarisini kullanarak sıcak nokta sınıflandırmasında %98.65'lik bir doğruluk bildirmiştir. Bu gelişmeler, yapay zekanın FV bakım uygulamalarına artan entegrasyonunu göstermektedir (Açıkgoz vd., 2022; Duranay, 2023).

Li vd., dağıtılmış fiber Bragg ızgara (FBG) sensör tabanlı bir yöntem ile FV panellerde sıcak nokta tespiti gerçekleştirmiştir. Bu çalışmada, FV panel üzerine yerleştirilen sensörler vasıtasıyla Bragg dalga boyu kaymaları tespit edilmiş ve bu yolla sıcaklık değişimleri incelenmiştir. Araştırma sonucunda, sıcak noktalı hücrelerin normal hücrelere göre daha fazla termal kararsızlık sergilediği gösterilmiştir. Yöntemin, değişken çevresel koşullarda ve gerçek zamanlı uygulamalarda sağlam bir performans sergilemesine rağmen, büyük ölçekli sahalarda ölçeklenebilirlik zorlukları ortaya çıkardığı ve potansiyel olarak maliyeti yükselttiği tartışılmıştır (Li vd., 2022a).

Pruthviraj vd., ortomozaik haritalama için açık kaynaklı WebODM ve PyQGIS yazılımları ile entegre edilmiş dijital ve termal kameralı insansız hava araçları (İHA) kullanarak Güney Hindistan'daki bir güneş tarlasında sıcak nokta denetimi ve otomatik kusur haritalama çalışması gerçekleştirmiştir. Maliyet ve hızlı veri toplama açısından avantajlı olan bu çalışmada, makine öğrenme algoritması olarak YOLOv5 kullanılmış ve %97'lik bir doğruluk oranı elde edilmiştir (Pruthviraj vd., 2023).

Xie vd. tarafından tasarlanmış olan yeni bir varyant olan ST-YOLO, geleneksel tespit yöntemleriyle ilişkili yüksek işçilik maliyetleri ve yanlış alarmlar gibi zorlukların üstesinden gelmek üzere geliştirilmiştir. Bu geliştirilmiş model, FV modüllerindeki kusurları etkili bir şekilde tanımlamak için kızılötesi termal görüntülemeye dayanmaktadır (Xie vd., 2024).

Naeem vd., İHA ile çekilen Kırmızı-Yeşil-Mavi (Red-Green-Blue – RGB) renk bileşenlerinden oluşan görüntüler kullanarak güneş panellerindeki kirliliği (toz ve kuş pisliği) tespit etmek amacıyla yapay zekâ destekli bir yöntem sunmuştur. Çalışmalarında, özellikle küçük ve belirsiz özelliklere sahip kuş pisliklerini tespit etmenin zorluğuna odaklanmışlardır. Bu kapsamda, YOLOv5'i temel alan, CBAM dikkat modülü ve iki özel tespit başlığı (toz ve kuş pisliği için) içeren SDS-YOLO adında özel bir model geliştirmişlerdir. Geliştirilen bu model, özellikle kuş pisliği tespitinde mAP50 değerini %40,2 ve F1 skorunu %26,6 oranında artırırken, model parametre sayısını %24 oranında azaltmıştır (Naeem vd., 2025).

Yanılmaz vd., İHA'lara entegre kameralar ile yakalanan 100 adet FV panelin termal görüntülerini kullanarak YOLO algoritmalarının (YOLOv5, YOLOv6, YOLOv7 ve YOLOv8) sıcak nokta tespitindeki performanslarını kıyaslamıştır. Çalışma sonucunda YOLOv8, %83,8'lik ortalama hassasiyet (mean Average Precision - mAP) değeri ile diğer varyantlara kıyasla daha iyi bir performans göstermiştir (Yanılmaz vd., 2024).

Kim vd., İHA ile çekilen termal kızılötesi görüntülerden FV panel alanlarını otomatik olarak çıkarmak için bir algoritma önermiştir. Bu işlemin, arızalı panellerin otomatik tespiti için bir ön adım olarak gerekli olduğu, zira manuel analizin zaman alıcı olduğu belirtilmiştir. Geliştirilen yöntem; dikey ve yatay filtreleme ile doğrusal kenarların vurgulanması, hiyerarşik histogram kümeleme ile kenar adaylarının çıkarılması, morfolojik işlemlerle panel dizisi alanının belirlenmesi ve komşu panel geometrisi kullanılarak alanların iyileştirilmesi gibi adımları içermektedir. Önerilen algoritmanın, manuel olarak sayısallaştırılmış verilerle kıyaslandığında ortalama %95,0 bütünlük, %96,9 doğruluk ve %92,1 kalite elde ettiği ifade edilmiştir (Kim vd., 2016).

Kim vd., İHA ile elde edilen termal kızılötesi görüntüler kullanılarak FV panellerdeki arızaların otomatik olarak tespit edilmesini sağlayan bir algoritma sunmuştur. Önerilen yöntemde, her bir panelin ortalama yoğunluk ve standart sapma değerleri istatistiksel olarak analiz edilmiş ve arızalı paneller, her panel dizisi içinde yapılan yerel karşılaştırmalar yoluyla tanımlanmıştır. Kamera ile hedef arasındaki mesafeye bağlı sıcaklık değişimleri dikkate alınarak, küresel eşikleme yerine yerel bir eşikleme kuralı kullanılmıştır. Test edilen örnek görüntülerde algoritmanın tüm arızalı panelleri doğru bir şekilde tespit ettiği ve genel doğruluk oranının %97'nin üzerinde gerçekleştiği görülmüştür. Sonuçlar, bu yöntemin büyük ölçekli FV santrallerinde hassas ve verimli arıza tespiti için uygun olduğunu ve daha geniş veri setleri ile geliştirilebileceğini göstermiştir (Kim vd., 2017).

Winston vd., güneş enerjisi panellerindeki mikro çatlakları ve sıcak noktaları tespit etmek amacıyla, görüntü işleme ile Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) tabanlı hibrit bir yöntem önermiştir. Yöntem, kusurların görünürlüğünü artırmak için termal ve elektrolüminesans görüntülerinin ön işleme ile başlamış ve ardından istatistiksel ile dokuya dayalı teknikler kullanılarak özellik çıkarımı yapmıştır. İki aşamalı bir sınıflandırma yapısı kullanan bu yaklaşımda, ilk aşamada YSA modeli bir ön sınıflandırma gerçekleştirmiş, sonrasında ise DVM modeli nihai kararı vererek teşhis doğruluğunu artırmıştır. Deneysel sonuçlar, geliştirilen bu hibrit yöntemin yüksek doğruluk oranı ile kusurları başarıyla tespit ettiğini ve mikro çatlaklar ile sıcak noktalar arasında ayrım yapabildiğini göstermiştir. Bu çalışma, makine öğrenmesi ile görüntü analizi entegrasyonunun, FV panel denetimini otomatikleştirme ve uzun vadeli performans güvenilirliğini sağlama konusunda umut verici bir yaklaşım sunduğunu ortaya koymuştur (Winston vd., 2021).

Wu ve Hao, küçük sıcak noktaların tespitini iyileştirmek ve arka plan gürültüsünü azaltmak amacıyla, geliştirilmiş bir Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (Faster Region-Convolutional Neural Network - Faster R-CNN) varyantı olan SK-FRCNN'i sunmuşlardır. Bu modele, alıcı alan boyutunun uyarlanabilir bir şekilde ayarlanmasını sağlayan ve böylece özellik çıkarımını geliştiren bir Selective Kernel Attention mekanizması dahil etmişlerdir. Geliştirilen bu algoritmanın, orijinal Faster R-CNN ağına göre %1,82'lik bir performans artışıyla, ortalama %79,98'lik bir tespit doğruluğu elde ettiği belirtilmiştir (Wu ve Hao, 2023).

Duan ve Ma, multispektral kameralarla donatılmış İHA kullanarak güneş enerjisi santrallerindeki FV panellerde sıcak nokta arızalarının tespitine yönelik yeni bir yöntem önermiştir. Yöntem kapsamında, İHA'lar tarafından çekilen görünür ve kızılötesi görüntüler fotogrametrik olarak işlenerek coğrafi referanslı termal görüntüler oluşturulmuş ve arızalı panellerin tespiti için bu görüntülere Otsu eşikleme ile morfolojik işlemler uygulanmıştır. Çin'in Guangdong Eyaleti, Qingyuan'da gerçekleştirilen saha testleri, önerilen yöntemin sıcak nokta arızalarını yüksek doğrulukla tespit edebildiğini ortaya koymuştur. Geliştirilen sistem, geleneksel yöntemlere kıyasla fiziksel temas gerektirmemesi ve otomatik işlem akışı sayesinde hem maliyet etkinliği hem de yüksek verimlilik sunmaktadır. Bununla birlikte, yöntemin küçük parlak noktaların algılanmasında ortaya çıkan yanlış pozitifleri azaltmak için daha fazla optimizasyona ihtiyaç duyduğu belirtilmiştir (Duan ve Ma, 2024) .

Ali vd., FV panellerdeki sıcak noktaların termografik görüntüler aracılığıyla erken tespiti için yeni bir yöntem sunmuştur. Önerilen yaklaşım, termal görüntüleri kesişmeyen bölgelere ayırmaya ve bu bölgelerden çıkarılan renkli görüntü tanımlayıcılarını makine öğrenmesi algoritmaları için birer öznitelik olarak kullanmaya dayanmıştır. Bu yöntemle, FV panelleri; normal, sıcak noktalı ve kusurlu olmak üzere üç farklı sınıfa ayırmak amacıyla çeşitli makine öğrenmesi modelleri eğitilmiştir. Deneysel analizler, k-En Yakın Komşu (k-Nearest Neighbors – k-NN) sınıflandırıcısı ile kullanılan Kırmızı-Yeşil Ölçekten Bağımsız Özellik Dönüşümü (Red-Green Scale-Invariant Feature Transform - rgSIFT) tanımlayıcısının %98,7'lik bir doğruluk oranıyla en yüksek performansı gösterdiğini ortaya koymuştur. Çalışmada ayrıca, sınıflandırma doğruluğunun 71x71 piksellik optimal bölge boyutunda en üst düzeye çıktığı ve bu modelin mevcut çalışmalara kıyasla daha üstün sonuçlar verdiği tespit edilmiştir (Ali vd., 2021).

Sun vd., FV panellerdeki sıcak noktaları tespit etmek amacıyla, YOLOv5 ağına bağlantı noktalarını ve tahmin başlıklarını iyileştirerek yeni bir yöntem geliştirmiştir.

YOLOv5 ağını temel alan bu yöntemde, K-means kümeleme algoritması kullanılarak veri setine özel ve daha küçük çapa kutuları optimize edilmiştir. Ayrıca, küçük hedeflerin tespit hassasiyetini artırmak amacıyla ağı daha büyük bir (160×160) tahmin katmanı eklenmiştir. Önerilen model, %87,8 mAP, %89,0 ortalama duyarlılık ve %88,9 F1 skoru elde ederken, 98,6 saniye başına düşen kare sayısı (frames per second – FPS) ile yüksek hızını korumuştur (Sun vd., 2022).

Gurras vd., İHA yardımıyla çekilen termal görüntüler ve dijital görüntü işleme teknikleri kullanarak FV panellerdeki arızaların otomatik olarak tespitini ve sınıflandırılmasını amaçlayan bir yöntem önermiştir. Geliştirilen sayısal algoritma, termal görüntülerden anlamlı bölgeler çıkarmak için Gauss filtreleme, eşikleme, morfolojik dönüşümler, bağlı bileşen analizi ve K-means kümeleme gibi ön işlem adımlarını Evrişimli Sinir Ağları (Convolutional Neural Network - CNN) ile birleştirmiştir. Bu bölgeler, sıcaklık aralıklarına ve geometrik şekillerine göre sınıflandırılarak tozlanma, hücre çatlağı, potansiyel kaynaklı bozulma ve kırık bypass diyotu gibi arıza türleriyle ilişkilendirilmiştir. Algoritma, gerçek saha verileri ve farklı irtifalardaki İHA uçuşları ile test edilmiş ve yüksek doğrulukla arıza karakterizasyonu sağlamıştır. Sonuçlar, yöntemin büyük ölçekli güneş enerjisi santrallerinde hızlı, düşük maliyetli ve temassız arıza tespiti için etkili bir araç olduğunu göstermiştir (Gurras vd., 2021).

Zhang vd., FV panellerdeki hem yüzeysel hem de içsel arızaların tespiti için termal kızılötesi ve optik uzaktan algılama verilerini birleştiren çok kaynaklı bir izleme teknolojisi önermiştir. Yöntemde, Mask R-CNN ve derin öğrenme temelli hata sınıflandırma algoritmaları ile FV panellerin otomatik olarak konumlandırılması ve her panelin arıza durumunun sınıflandırılması gerçekleştirilmiştir. Optik görüntüler toz, kuş pisliği ve yaprak gibi yüzeysel engelleri tespit ederken, termal kızılötesi görüntüler içsel kusurları (sıcak noktalar ve kötü hatlar) ortaya koymuştur. Çin'in Jiangsu Eyaleti'nde yürütülen deneysel çalışmalarda, geliştirilen sistemin yüksek doğrulukla çoklu arıza tiplerini tespit edebildiği gösterilmiştir. Bu çalışma, PV santrallerinde uzaktan ve temassız şekilde geniş alanlı, hızlı ve akıllı arıza teşhisi yapılabilmesini sağlayan yeni nesil bir yaklaşım sunmuştur (Zhang vd., 2024a).

Pan vd., FV panellerdeki kusurların tespitinde karşılaşılan zorlukları ele almış ve bu amaçla YOLOv5 modelini temel alan YOLO-ACF adında yeni bir yaklaşım sunmuştur. Önerilen model, mekansal ve kanal bilgilerini akıllıca bütünleştirmek üzere tasarlanmış bir Adaptif Tamamlayıcı Füzyon (Adaptive Complementary Fusion - ACF)

modülü içermektedir. Bu modülün temel amaçları arasında modelin tespit performansını artırmak, daha hafif bir yapı için model boyutunu küçültmek ve tespit sürecini hızlandırmak yer almaktadır. Yapılan deneysel çalışmalarda, YOLO-ACF modelinin, en güncel modellerden biri olan YOLOv8'e kıyasla çeşitli performans metriklerinde daha iyi sonuçlar sergilediği gösterilmiştir. Ayrıca, YOLOv5 modeline göre daha az parametreye sahip olduğu ve daha hızlı çalıştığı kanıtlanmıştır. Elde edilen sonuçlar, YOLO-ACF'nin kusur tespiti performansı, model karmaşıklığı ve hızı arasında başarılı bir denge kurarak FV panel üretiminde pratik bir çözüm sunduğunu doğrulamaktadır (Pan vd., 2024).

Zhao vd., yenilenebilir enerji ve elektronik endüstrilerinde kusurların tespiti amacıyla kullanılan aktif kızılötesi termografi (Infrared Thermographic - IRT) teknolojisindeki ilerlemeleri kapsamlı bir şekilde ele almıştır. Çalışmada, kullanılan uyarma kaynaklarına göre; darbeli termografi, kilitli termografi, ultrasonik titreşimli termografi ve girdap akımlı termografi gibi temel aktif IRT yöntemleri ayrıntılı olarak incelenmiştir. Özellikle yenilenebilir enerji sektöründe, FV panellerin izlenmesi ve bakımında kritik bir rol oynayan kusurların tespiti için IRT görüntülemenin uygulanması derinlemesine araştırılmıştır. Benzer şekilde, elektronik endüstrisinde devre kartları, yarı iletken çipler ve lehim bağlantıları gibi bileşenlerin kalite kontrolü ve kusur analizi için bu teknolojinin uygulamalarına odaklanılmıştır. Son olarak makalede, IRT görüntülemenin yapay zeka ve derin öğrenme algoritmalarıyla entegrasyonunun, tespit süreçlerini otomatikleştirerek ve doğruluğu artırarak her iki sektör için de verimli ve hassas çözümler sunduğu vurgulanmıştır (Zhao vd., 2023).

Yin vd., İHA ile çekilen kızılötesi görüntülerdeki FV panel arızalarını tespit etmek amacıyla, YOLOvX'i temel alan PV-YOLO adında bir model önermiştir. Çalışmada, küçük nesnelerin tespit performansını artırmak hedefiyle YOLOvX'in omurga ağı PVTv2 ağı ile değiştirilmiş ve modele CBAM dikkat mekanizması eklenmiştir. Geliştirilen bu model, özel bir veri seti üzerinde yapılan testlerde %92,56'lık bir mAP değerine ulaşarak, temel aldığı YOLOvX modelinden %10,46 daha yüksek bir performans sergilemiştir (Yin vd., 2023).

1.2. Tezin İçeriği ve Amacı

Bu tez çalışması, FV enerji santrallerinde oluşan sıcak nokta anomalilerinin tespitine yönelik görüntü işleme temelli yapay zekâ yaklaşımlarını incelemeyi ve bu amaç doğrultusunda farklı YOLO algoritmalarının karşılaştırmalı analizini yapmayı

amaçlamaktadır. FV panellerde meydana gelen sıcak nokta arızaları, yalnızca enerji üretiminde verim kayıplarına neden olmakla kalmamakta, aynı zamanda yangın riski başta olmak üzere ciddi güvenlik tehditleri de oluşturmaktadır. Bu nedenle, bu tür arızaların erken ve doğru şekilde tespiti, FV enerji sistemlerinin operasyonel güvenilirliği ve sürdürülebilirliği açısından kritik öneme sahiptir.

Tez kapsamında, derin öğrenme tabanlı nesne tespiti algoritmalarından biri olan YOLO mimarisi temel alınarak geliştirilen YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 sürümleri değerlendirilmiştir. Her bir sürüm, sıcak nokta tespiti görevindeki performansı açısından; kesinlik, duyarlılık, F1 skoru, mAP50 ve mAP50-95 gibi istatistiksel performans metrikleriyle analiz edilmiştir. Bu bağlamda, çalışmanın temel amacı; farklı YOLO varyantlarının sıcak nokta anomalilerini ne ölçüde ve hangi başarı düzeyinde tespit edebildiğini nesnel olarak ortaya koymak, böylece bu algoritmaların FV sistem bakım ve izleme süreçlerine entegrasyon potansiyelini değerlendirmektir.

Tezin bir diğer özgün katkısı ise, tespit edilen sıcak nokta anomalilerinin coğrafi koordinat verileri kullanılarak haritalandırılmasıdır. Bu işlem, İHA aracılığıyla elde edilen kızılötesi görüntülerdeki arıza bölgelerinin konumlarının sahaya entegre edilmesini sağlamakta; böylece, saha sorumlularının arıza bölgelerine hızlı erişimini ve müdahale sürecini kolaylaştırmaktadır. Bu tür konumsal görselleştirme, yalnızca tespit işlevini değil, aynı zamanda karar destek sistemleri ile bakım optimizasyonu gibi uygulamalarda da önemli bir işlevsellik sunmaktadır.

1.3. Tezin Organizasyonu

Bu tez çalışması sırasıyla; Giriş, Genel Bilgiler, Materyal ve Yöntem, Araştırma Bulguları ve Tartışma ile Sonuç ve Öneriler bölümlerinden oluşmaktadır.

Giriş bölümünde, küresel ısınma ve iklim değişikliği sorunlarına giriş yapılarak yenilenebilir enerjinin bu bağlamdaki kritik rolü vurgulanmıştır. Güneş enerjisinin artan önemi, Türkiye'nin bu alandaki hedefleri ve FV sistemlerin yaygınlaşması ele alınmıştır. Ayrıca, FV panellerde zamanla ortaya çıkan performans kayıpları ve arıza türlerine dikkat çekilmiş, özellikle sıcak nokta anomalilerinin oluşturduğu riskler üzerinde durulmuştur. Çalışmanın amacı, kapsamı ve literatürdeki yeri özetlenmiş; araştırmanın gerekliliği ve katkı potansiyeli ortaya konmuştur.

Genel Bilgiler bölümünde, FV güneş panelleri, bu panellerde meydana gelen temel arıza türleri ve bu arızaların tespiti için kullanılan kızılötesi görüntüleme teknikleri hakkında genel bilgiler sunulmuştur. Bu kapsamda, sıcak nokta, dizi anomalileri, diyot

arızaları, gölgelenme ve tozlanma gibi sorunlar ayrıntılı olarak ele alınmıştır. Ayrıca, YOLO algoritmasının gelişim süreci ve sıcak nokta tespitindeki rolü incelenmiştir.

Materyal ve Yöntem bölümünde, çalışmanın materyal ve metodolojisi detaylandırılmıştır. Bu bölümde, araştırmanın yapıldığı çalışma alanı, veri toplama ve hazırlık süreçleri, veri setinin içeriği ve yapısı açıklanmıştır. Ayrıca, çalışmada kullanılan YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 algoritmalarının mimari özellikleri ve teknolojik farklılıkları üzerinde durulmuş ve performans değerlendirme metrikleri tanımlanmıştır.


Araştırma Bulguları ve Tartışma bölümünde, yapılan deneysel çalışmaların sonuçları sunulmuş ve bu sonuçlar tartışılmıştır. Farklı YOLO modellerinin sıcak nokta tespiti konusundaki performansları; kesinlik, duyarlılık, F1 skoru ve mAP gibi metrikler kullanılarak karşılaştırmalı olarak analiz edilmiştir. Modellerin eğitim süreci grafikleri ve tespit sonuçları görsel olarak sunulmuş bulgular detaylı bir şekilde değerlendirilmiştir.

Sonuç ve Öneriler bölümünde, tez çalışmasından elde edilen genel sonuçlar özetlenmiş ve gelecek çalışmalara yönelik önerilerde bulunulmuştur. Bu bölümde, incelenen YOLO modellerinin güçlü ve zayıf yönleri vurgulanarak, FV enerji santrallerinde anomali tespiti için en uygun çözümler üzerine değerlendirmeler yapılmıştır.

2. GENEL BİLGİLER


2.1. Fotovoltaik Güneş Panelleri

Fotovoltaik ifadesi, güneş ışınımını doğrudan elektrik enerjisine dönüştüren çevre dostu bir enerji üretim teknolojisini tanımlar (Dada ve Popoola, 2023). Bu teknoloji, yarı iletken özelliklere sahip malzemeler aracılığıyla herhangi bir mekanik hareket olmaksızın elektrik üretimini mümkün kılar (Al-Ezzi ve Ansari, 2022). FV güç sistemleri, bu dönüşümün gerçekleştirilmesi için gerekli olan çeşitli bileşenlerin bir araya getirilmesiyle oluşur. Bu sistemler yalnızca enerji üretimini değil, aynı zamanda üretilen enerjinin düzenlenmesi, depolanması ve şebekeye aktarılmasını da kapsayan bütüncül bir yapıdır. FV sistemlerde en temel ve işlevsel bileşen, güneş ışığını elektrik enerjisine çeviren FV panel ya da modüllerdir. Bu modüller, güneş ışığına maruz kaldıklarında fotonların etkisiyle yarı iletken malzeme içinde serbest elektronlar oluşturarak elektrik üretirler. Üretilen bu enerji, doğru akım (DC) formundadır ve sistem ihtiyaçlarına göre alternatif akıma (AC) dönüştürülebilir. Güneşin gün içerisindeki hareketi ve atmosferik değişkenler, panellere ulaşan ışıma miktarını ve dolayısıyla üretim verimliliğini doğrudan etkiler. FV modüller, sistemin genel performansını belirleyen ve enerji dönüşüm sürecinin merkezinde yer alan ana bileşenlerdir (Shaker vd., 2024). Şekil 2.1’de, FV sistemlerde yer alan temel bileşenler ve güneşten elektrik üretimi süreci görsel olarak sunulmaktadır.




Şekil 2.1. Bir güneş enerji sisteminin bileşenleri

Bir FV panel, Şekil 2.2’de gösterildiği gibi istenilen akım ve gerilim değerlerinde bağlanarak belirli sayıdaki güneş hücresinin bir araya getirilmesinden oluşur. Güneş hücreleri ise genellikle kristal silisyum (Si) malzemeden üretilir. Temelde güneş hücreleri Si bazlı, n tipi ve p tipi yarı iletken malzemelerin bir araya getirilmesinden meydana gelir (Aghaei vd., 2022).



Şekil 2.2. Bir FV panele ait güneş hücrelerinin modellenmesi

FV panellerin üzerinde güneş ışınımı olması sonucu fotonlar, Şekil 2.3’te yer alan hücrelerdeki yarı iletken yüzeye çarpar. Bu çarpma sonucunda yarı iletken malzemelerin içerisindeki elektronların enerjisi artarak serbest kalır ve bir FV etki oluşturur. Oluşan FV etki ise bir elektrik akımını meydana getirir. Başka bir deyişle, bir güneş hücresi, güneş ışığına maruz kaldığında içerisindeki n tipi ve p tipi yarı iletken malzemelerin arasında meydana gelen potansiyel fark sonucunda çalışmaktadır. Güneş ışınımı, n tipi levhalardaki elektronları serbest bırakarak, p tipi levhaların boşluklarını doldurmak üzere harekete geçirir. Bunun sonucunda meydana gelen potansiyel fark (voltaj) FV hücrelerinin elektrik akımı üretmesine olanak sağlar (Al-Ezzi ve Ansari, 2022).



Şekil 2.3. Güneş hücresi bileşenleri

2.2. Güneş Panellerinde Görülen Arıza Türleri ve Nedenleri

Güneş enerjisi, karbon emisyonunu azaltma ve sürdürülebilir enerji üretimi sağlama noktasında kritik bir rol üstlenmektedir. Panel üretimindeki maliyet düşüşleri ve teknolojik gelişmeler, güneş enerjisinden elektrik üretimi yapan FV sistemlerin yaygınlaşmasını hızlandırmıştır (Mustafa vd., 2020). Türkiye de bu alandaki büyüme potansiyeli yüksek ülkeler arasında yer almakta ve 2017-2027 yılları arasında da ek olarak 10 GW solar kapasitesi kurmayı hedeflemektedir (IEA, 2021). Ayrıca, FV panellerin üretim aşamasında karbon emisyonunun dikkatli bir şekilde yönetilmesi durumunda, diğer enerji kaynaklarına kıyasla çok daha düşük sera gazı salınımı gerçekleştiği bilinmektedir (Mehedi vd., 2022). Ancak FV paneller, ortalama 20 ila 25 yıllık performans garantisine sahip olsa da (Kaaya vd., 2019; Goudelis vd., 2022), bu süre içinde çeşitli arızaların oluşması kaçınılmazdır. Paneldeki arızaları tespit etmek ve gerekli bakımları yapmak, elektrik üretim kayıplarını asgari düzeyde tutmak açısından önem taşır (Santhakumari ve Sagar, 2019). Güneş paneli kaynaklı arızalar pek çok nedenle ortaya çıkabilmektedir: Üretim hataları, sahada karşılaşılan çevresel faktörler, yanlış montaj veya bakım eksikliği bunlardan birkaçıdır (Al Mahdi vd., 2024).


Öne çıkan arıza türleri arasında çatlaklar, delaminasyon, bağlantı kutusu arızaları, bypass diyotu problemleri ve özellikle sıcak nokta adıyla bilinen yüksek sıcaklık bölgeleri yer almaktadır (Jordan vd., 2017). Bağlantı kutusunun su alması veya yanlış malzeme kullanılması, panellerin ömrünü kısaltan önemli faktörler arasında sayılır (Miller vd., 2014; Chang vd., 2015) Diğer taraftan, hücre çatlakları hem üretim sürecindeki mekanik gerilmeler hem de kurulum sahasında meydana gelebilecek darbe veya titreşimler sonucunda oluşabilir. Bu çatlakların kapsadığı alan oranına göre panelin güç kaybı da önemli ölçüde artar (Wendt vd., 2009; Köntges vd., 2010). Delaminasyon, FV panel katmanlarında yapısal bütünlüğü sağlayan etilen vinil asetat (EVA) gibi kapsülleme malzemelerinin adezyon özelliklerini kaybetmesiyle ortaya çıkan bir bozulma türüdür ve bu durum, nem girişine ve korozyon oluşumuna zemin hazırlayarak panel performansını olumsuz yönde etkileyebilir (Berghold vd., 2012).

Güneş enerji sistemlerinin performansını etkileyen bir diğer husus da panel yüzeyinin temizliği ve periyodik bakım uygulamalarıdır. Kuş pisliği veya toz gibi dış etkenler, panel yüzeyinde gölgelenmeye yol açarak hücrelerin dengesiz ısınmasına ve sonuç olarak sıcak nokta oluşumlarına neden olabilmektedir (Mustafa vd., 2020). Bu tür

birikintiler, ışıının panel yüzeyine homojen dağılmasını engelleyerek enerji üretim verimliliğinde kayıplara yol açmaktadır.

2.3. Kızılötesi Görüntüleme Teknikleri ile Tespit Edilebilecek Arıza Türleri


FV güneş enerjisi santrallerinde performans kayıplarının en etkin şekilde giderilmesi; sistem güvenliğinin sağlanması, önleyici bakım uygulamalarının hayata geçirilmesi ve arızaların erken aşamada tespit edilmesine bağlıdır. Bu kapsamda, kızılötesi (termal) görüntüleme teknikleri, özellikle görünür spektrumla tespit edilemeyen ısı kaynaklı anomalilerin belirlenmesinde etkili bir yöntem olarak öne çıkmaktadır. Hücre, modül ve sistem düzeyinde ortaya çıkan ısı hatalarının tespitinde termal kameraların kullanımı hem enerji üretim verimliliğinin artırılmasına hem de bakım süreçlerinin daha hedef odaklı ve duyarlı biçimde yürütülmesine katkı sağlamaktadır. Bu yöntem sayesinde, sahadaki potansiyel arızaların erken dönemde belirlenmesi ve önlem alınması mümkün hâle gelmektedir. Analiz ve değerlendirmelere tabi tutulmak üzere termal görüntüleme metoduyla tespit edilmesi mümkün olan ve Şekil 2.4'te sunulan başlıca anomaliler; dizi anomalileri, diyot arızaları, gölgelenme, tozlanma ve sıcak nokta sorunlarıdır.



Şekil 2.4. Termal görüntüleme ile tespit edilen birkaç arıza örneği

2.3.1. Dizi Anomalileri

FV güneş enerjisi sistemlerinde modüller, genellikle seri bağlantı yöntemiyle birbirine bağlanarak dizi yapılarını oluşturur. Bu diziler, ürettikleri DC'yi, AC'ye dönüştürmek amacıyla evirici sistemlerine entegre edilir. Saha içerisinde yer alan dizileri birbirine bağlayan konnektörlerde meydana gelebilecek gevşeme, aşınma ya da kopma gibi fiziksel bozulmalar; ayrıca bağlantı kutusu, bypass diyotları, evirici ve hücre arızaları ya da panel yüzeyinde biriken kir, toz ve benzeri çevresel etkenler, elektrik üretiminde düşüşe ve sistem veriminde kayba yol açabilmektedir. Bu tür bozulma ve arıza durumlarında diziler üzerinde ısı anomalileri gelişebilir. Bu anomaliler Şekil 2.5'teki gibi kızılötesi kameralarda gözlemlenebilen karakteristik özellikleri ile tespit edilebilir (Köntges vd., 2014).




Şekil 2.5. Termal kamera ile tespit edilen dizi anomalileri

2.3.2. Diyot Arızaları


Şekil 2.6'da gösterildiği üzere, FV panel yüzeyinin bir bölümünün gölgede kalması durumunda, hücreler arasındaki elektriksel akışta dengesizlikler meydana gelir. Bu tür gölgelenme koşulları, hatalı kablo bağlantıları, yetersiz ya da kalitesiz lehimleme uygulamaları ve bypass diyotlarında oluşabilecek arızalarla birleştiğinde, panelin belirli bölgelerinde lokal ısınmalar yani sıcak nokta oluşumları gözlemlenebilir ve bu durum sistemin genel verimliliğini önemli ölçüde düşürmektedir (Yang vd., 2024). Bu nedenle, hem tasarım aşamasında gölgelenme riskinin en aza indirgenmesi hem de periyodik

bakım süreçleri ile elektriksel bağlantıların ve diyotların bütünlüğünün kontrol altında tutulması büyük önem arz etmektedir.



Şekil 2.6. Bypass diyotlarının paneldeki gölgeli alanı devreden çıkartışı


Kızılötesi kameralarla incelenen modülün üzerinde Şekil 2.7'deki gibi boylu boyunca şerit şeklinde oluşan ısı farklılıkları genellikle diyot arızalarının oluştuğunun habercisidir. Bu arıza türünde hasar alan veya tamamen bozulan diyot devreden çıkar bu durum sonucunda karşı bir direnç oluşacağından devreden çıkan bölgede bir ısınma meydana gelir. Arızalı panele kızılötesi ışıktaki bakıldığında oluşan görüntünün sebebi de bu ısınmadır. (Vieira vd., 2020; Yin vd., 2023)



Şekil 2.7. Termal kamera ile tespit edilen diyot arızaları

2.3.3. Kuş Pisliği

FV panellerin kurulu olduğu bölgelerdeki yerel biyoçeşitlilik dikkate alındığında, özellikle martı gibi kuş türlerinin güneş enerjisi santralleri üzerinde uçarken dışkı bırakmaları, panel yüzeyinde önemli arızalara yol açabilmektedir. Kuş dışkısı, doğrudan bir veya birden fazla FV panele temas ettiğinde, panelin yüzeyinde fiziksel kirlenmeye ve dolaylı olarak performans kaybına neden olur. Bu tür arızalar, genellikle panellerin düzenli olarak temizlenmemesi sonucu daha da belirgin hale gelir. Kuş dışkısında bulunan çeşitli asidik ve kimyasal bileşikler, panel yüzeyinde kimyasal aşınmalara yol açarak modülün fiziksel bütünlüğünü tehdit edebilir. Aynı zamanda, bu tür birikintiler güneş ışığının panel yüzeyine ulaşmasını engelleyerek lokal ısınmalara sebep olur; bu durum zamanla sıcak nokta oluşumuna yol açabilir ve sistemin genel verimliliğini ciddi şekilde azaltabilir. Özellikle santral çevresini sürekli mesken tutan kuş popülasyonları bu tür arıza riskini artıran çevresel faktörler arasında yer almaktadır. Bu bağlamda, biyogaz veya çöp gazı gibi atık kaynaklardan elektrik üreten tesislerde hibrit sistem olarak entegre edilen güneş enerjisi santrallerinde söz konusu riskin göz önünde bulundurulması gerekmektedir. Zira organik atıkların ve çöplerin bulunduğu alanlar, martı gibi türlerin yaşam alanı olarak tercih ettikleri bölgeler arasında yer alır (Ahmed vd., 2021). Şekil 2.8’de sunulan örneklerde görüldüğü üzere, kuş pislikleri, kızılötesi (termal) görüntüleme ile de görünür ışıktaki olduğu gibi açık bir şekilde tespit edilebilmektedir.



Şekil 2.8. Kuş pisliği görüntüsü (a) RGB kamerada, (b) Termal kamerada

2.3.4. Gölgeleme

Bir güneş enerjisi santralinde, FV modüllerin ve hatta dizilerin üzerine gölge düşmesine neden olabilecek baca, aydınlatma direği, ağaç, çalı ve benzeri yapısal ya da doğal engellerin varlığı, sistem performansını olumsuz etkileyen önemli çevresel sorunlar arasında yer almaktadır. Şekil 2.9’da örnekleri sunulan bu tür gölgelenmeler, güneş enerjisi santrallerinin aktif üretim saatlerinde panel yüzeyine gelen ışınmı engelleyerek, ilgili modüllerden enerji üretiminin tamamen veya kısmen durmasına yol açabilir. Gölgelemenin süreklilik göstermesi hâlinde, etkilenmiş panel gruplarının verimliliği ciddi şekilde azalır ve bu durum uzun vadede sistemin genel performansını düşürür. Bu tür problemlerin önüne geçilebilmesi için santral sahasının kurulacağı bölgenin çevresel analizinin detaylı biçimde yapılması ve gölge oluşturabilecek tüm sabit veya büyüme potansiyeline sahip unsurların dikkate alınması gerekmektedir. Özellikle arazi tipi güneş enerjisi santrallerinde, çevrede doğal olarak yetişen çalı, ot ve benzeri bitki örtüsünün düzenli olarak temizlenmesi; ayrıca yakın çevrede bulunan ağaçların uzayan dallarının periyodik olarak budanması, gölgeleme riskinin azaltılmasında etkili bir önlem olarak değerlendirilmelidir.




(a)

(b)


Şekil 2.9. FV panel üzerine düşen (a) direk gölgesi, (b) yabani otların gölgeleri

Gölgede kalan panel yüzeyleri zamanla termal dengesizliklere ve lokal ısınmalara bağlı hasarlara maruz kalabileceğinden, saha kontrollerinin düzenli ve sistematik biçimde yürütülmesi büyük önem taşımaktadır. Bu bağlamda, kızılötesi (termal) görüntüleme teknikleri ile gölgelenmeye maruz kalan bölgeler Şekil 2.10’da gösterildiği üzere görsel olarak tespit edilebilmekte ve performans izleme süreçlerinde önemli bir tanı aracı olarak kullanılmaktadır (Köntges vd., 2014).



Şekil 2.10. Yabani ot kaynaklı termal kamera ile tespit edilen gölgelenmeler

FV güneş enerji santrallerinin bulunduğu arazilerdeki bitki örtüsünün (yabani otlar, ağaçlar, çalılar vb.) düzenli olarak kontrol edilmesi sürecine vejetasyon bakımı denir. Sahalarda vejetasyon bakımının yapılması olası yabani otların veya ağaçların neden olabileceği yangın ihtimalinin önüne geçmek ve güneş enerji panellerinden maksimum verim alabilmek için gereklidir. Saha içerisinde aşırı derecede büyüyen otlar panelleri Şekil 2.10'daki gibi gölgede bırakabilir. Ayrıca bu otların ve diğer bitkilerin panel yüzeyine temas etmesi, yangın risklerine neden olabileceğinden çok tehlikelidir. FV güneş enerji sahalarında vejetasyon bakımı farklı yöntemler ile yapılabilir. Bunlar; hayvan otlatma, motorlu tırpan, kimyasal ilaçlama gibi uygulamalardır. Ek olarak, çakıl, talaş gibi malzemelerle malçlama veya hem toprak erozyonunu azaltan hem de toprağı örten, kısa boylu bitki türlerinin dikilmesiyle istenmeyen yabancı otların yetişmesi engellenebilir. Bu ve benzeri önleyici yöntemlerle enerji santralindeki bitki örtüsü kontrol altında tutulabilir. Vejetasyon bakımı, enerji üretiminin verimli olması için önemlidir. Aynı zamanda yangın riskini azaltarak saha güvenliğini sağlar ve ekipmanların korunmasına yardımcı olarak ömrünü uzatır. Şekil 2.11(a) vejetasyon bakımı için ekolojik bir yöntemi sunarken, Şekil 2.11(b) ise saha içerisindeki bileşenlerin (köşk, direk vb.) kurulumunda gölgelenme sorunu oluşturmayacak biçimde konumlandırılmasına örnek olarak sunulmuştur.




(a)

(b)

Şekil 2.11. (a) Hayvan otlatma metodu ile vejetasyon bakımı, (b) Gölge sorunu oluşturmayacak şekilde köşk yeri seçimi örneği

2.3.5. Tozlanma

Tozlanma sorunu, güneş enerjisi santrallerinde iklim koşulları, çevresel etkenler ve bölgesel faaliyetler sonucu FV panel yüzeylerinde zamanla oluşan partikül birikimidir. Bu partiküller, güneş ışınımının panel modüllerine doğrudan ulaşmasını kısmen engelleyerek enerji üretimini olumsuz etkiler. Örneğin, Şekil 2.12(b)'de yer alan demir-çelik fabrikasına kurulu çatı tipi güneş enerjisi santralinde, ortamda oluşan demir tozları; çimento tesislerine yakın bölgelerde çimento tozu veya çöl ikliminde rüzgârla taşınan kumlar, benzer şekilde tozlanma sorununa neden olabilmektedir. Kızılötesi görüntüleme yönteminde, sahadaki bazı dizi hatları boyunca belirgin olmayan ancak toplu hâlde cılız renk değişimlerinin varlığı, panel yüzeyinde toz birikimine işaret edebilir (Köntges vd., 2014; Köntges vd., 2017). Bu tür termal izler, kızılötesi kamera ile yapılan incelemelerde Şekil 2.12(a)'da olduğu gibi net bir şekilde gözlemlenebilmektedir.




(a)

(b)

Şekil 2.12. Tozlanma sorununun tespiti; (a) RGB kamerada, (b) kızılötesi kamerada

2.3.6. Sıcak Nokta (Hotspot)

Güneş panellerinde sıcak nokta olarak adlandırılan arızalar, genellikle gölge altında kalan ya da hücreler arasındaki hatalı bağlantı sonucu oluşan ters akım akışı sebebiyle ortaya çıkar (Vaas vd., 2023). Bu tür arızalar Şekil 2.13'te olduğu gibi, panelin ilgili bölgesinde anormal ısınmaya neden olup, verimde ciddi düşüslere ve kalıcı hasarlara yol açabilmektedir (Lamb vd., 2022). Aşırı ısınmanın oluşturduğu riskler arasında yangın tehlikesi ve hücrelerin tamamen yanarak kullanılamaz hale gelmesi de yer almaktadır (Shin vd., 2018; Vieira vd., 2020). Sıcak nokta arızası meydana gelen panelin onarılması için ilgili hücresinin değiştirilmesi gerekir. Arızalı hücreyi değiştirmenin ekonomik maliyeti yüksek olduğundan, ilgili paneli tamamen değiştirmek daha isabetli bir yöntem olacaktır.



Şekil 2.13. Termal kamera ile tespit edilen sıcak nokta arızaları

Sıcak nokta arızalarının erken teşhisi hem üretim kayıplarını minimuma indirmek hem de olası yangın risklerini azaltmak açısından büyük önem taşımaktadır. Geleneksel inceleme yöntemleri arasında görsel denetim, elektrolüminans ve kızılötesi görüntüleme yer alır (Al Mahdi vd., 2024). Özellikle termal kameralar yardımıyla yapılan kızılötesi inceleme, sıcaklık anomalilerini hızlıca tespit etmede oldukça etkilidir (Chaudhary ve Chaturvedi, 2018). Bunun yanı sıra, İHA'lar kullanılarak büyük ölçekli güneş enerji santrallerinin üzerinde termal tarama yapmak da sıkça tercih edilmektedir (Hwang vd., 2021). Bu yöntem, periyodik bakımları kolaylaştırdığı gibi, arızaların tespitinde zamandan ve maliyetten tasarruf sağlamaktadır. Lofstad-Lie vd., İHA kullanarak geliştirdikleri iki aşamalı uçuş stratejisi ile operasyon süresini yaklaşık %60 oranında

azaltmayı başarmış; bu yöntemle sıcaklık temelli anomalilerin hızlı, etkin ve maliyet açısından verimli bir biçimde tespit edilebileceğini ortaya koymuşlardır (Lofstad-Lie vd., 2022).

Öte yandan, giderek gelişen teknoloji ile birlikte çeşitli robotlar ve yapay zekâ yöntemleri, yenilenebilir enerji sistemlerinde kurulumdan bakım operasyonlarına kadar farklı alanlara entegre edilmektedir. Söz konusu entegrasyon, çevresel sürdürülebilirlik ve enerji kaynaklarının daha verimli kullanılmasını destekleyecektir (Iqbal vd., 2019).

İHA kullanılarak yapılan termal denetimlerde hava koşulları, panellerin güneşlenme durumları, rüzgâr hızı ve ortam sıcaklığı göz önünde bulundurulmalıdır. Termal denetimin yapılacağı esnada havanın açık ve güneşli, panellerin çalışma sıcaklığının 45 derece ve üzeri olduğu şartlar gözetilmelidir. Ölçümler yapılırken normal hücreler ve anormal sıcaklık gösteren hücreler bir ΔT sıcaklık farkıyla ayrı ayrı ölçülmeli ve farklı değerlendirmelerle ele alınmalıdır:

$0^{\circ}\text{C} < \Delta T < 10^{\circ}\text{C}$: Anormal hücreler gözlem altında tutulmalıdır.

$10^{\circ}\text{C} < \Delta T < 20^{\circ}\text{C}$: Anormal hücreler periyodik olarak takip edilmelidir.

$\Delta T \geq 20^{\circ}\text{C}$: Anormal hücreler için aksiyona geçilmeli ve gerekli işlemler yapılmalıdır (Bıyık vd., 2023).

2.4. YOLO Algoritması ve Sürümlerinin Gelişim Süreci


Derin öğrenme tabanlı nesne tespiti algoritmaları içerisinde, YOLO ailesi son yıllarda öne çıkan modellerden biridir. YOLO, görüntüyü tek bir seferde işleyerek nesne koordinatlarını ve sınıflandırma sonuçlarını eş zamanlı olarak üretebildiği için gerçek zamanlı uygulamalara oldukça uygundur (Redmon vd., 2016; Redmon ve Farhadi, 2017). İlk versiyonlarından itibaren hızlı ve etkin bir şekilde nesne tespiti yapan YOLO, COCO (Common Objects in Context) gibi geniş veri setleriyle eğitilerek özellikle günlük hayatta sık rastlanan objelerin tanınmasında yüksek başarı elde etmiştir (Lin vd., 2015; Redmon vd., 2016; Redmon, 2021).

Zamanla geliştirilen yeni sürümler, farklı mimari iyileştirmeler ve eğitim stratejileri sunarak performans ve hız konusunda önemli ilerlemeler kaydetmiştir. YOLOv4 ve YOLOv5 sürümleri; mAP değerlerinde artış sağlarken, aynı zamanda daha kullanıcı dostu bir eğitim altyapısı vadetmiştir (Gallagher ve Oughton, 2025; Hussain, 2024). YOLOv6, endüstriyel uygulamalara uyum ve düşük hesaplama gücü gerektiren sistemlerde çalışma hedefiyle tasarlanmış olup, hızlı yanıt verme başarısı kaydetmiştir (Hussain, 2024; C. Li vd., 2022b). Ardından gelen YOLOv7, özellikle gerçek zamanlı

nesne tespiti için optimize edilmiş, model mimarisinde yapılan değişikliklerle, kızılötesi ve görünür ışık görüntülerinde yapabildiği değerlendirmeler ile doğruluk değerlerinde iyi iş çıkararak, önceki sürümlerinin üzerinde bir performans sergilemiştir (Wang vd., 2023). 2023'te tanıtılan YOLOv8 ise, küçük nesnelerin tespitinde yaşanan kısıtlamaları azaltmayı ve segmentasyon gibi ek görevlerde de başarılı olmayı hedeflemiştir (Gallagher ve Oughton, 2025; Jegham vd., 2024; L. Zhang vd., 2024b).

En yeni sürümlerden olan YOLOv9, YOLOv10 ve YOLOv11, model mimarisinde ek düzenlemeler, öğrenme stratejisinde optimizasyon ve daha az parametreyle daha yüksek performans elde etme amacıyla tasarlanmıştır (Ultralytics, 2024a; Wang vd., 2024a; Wang vd., 2024b). Özellikle YOLOv9, önceki sürümlerde yaşanan hesaplama maliyeti sorunlarını gidermeye odaklanırken YOLOv10, otonom sürüş ve nesne takibi gibi yüksek veri çeşitliliği gerektiren uygulamalarda başarısını kanıtlamıştır. YOLOv11 ise Ultralytics tarafından 2024 yılında duyurulmuş, nesne algılama dışındaki makine öğrenimi görevlerini de destekleyen bir platform sunmayı hedeflemiştir (Gallagher ve Oughton, 2025; Jegham vd., 2024).

2025 yılının Şubat ayında piyasaya sürülen YOLOv12 modelinde ise, daha önceki modellerin mimarisinde rol alan CNN tabanlı uygulamalara olan ihtiyaç ortadan kaldırılmaya çalışılmış ve bunun yerine alan dikkat merkezli bir metot önerilmiştir (Tian vd., 2025). YOLO algoritmalarının yıllara göre sürüm gelişimi Şekil 2.14'te gösterilmiştir.




Şekil 2.14. YOLO algoritma ailesinin kronolojik gelişim zaman çizelgesi (2015-2025)

Literatürde, güneş paneli arızalarının otomatik tespiti konusunda YOLO ailesi üzerine yapılan çalışmalar hızla artmaktadır. Bu alandaki araştırmalar, sıcak nokta arızalarını kızılötesi görüntüler üzerinden tespit edilebileceğini göstermektedir (Lamb vd., 2022). Dolayısıyla, panel seviyesinde büyük hacimli veri toplama imkânı olan

iřletmeler, arıza tespiti ve bakım sũreçlerini kısaltarak enerji ũretim verimliliğini artıracabilecek bir potansiyele sahip olmaktadır.

2.5. YOLO Algoritması Sıcak Nokta Tespiti

řekil 2.15(a)'da olduđu gibi ok sayıda termal sıcak nokta gũrũntũsũ ũzerinde, řekil 2.15(b)'de gũsterildiđi gibi sıcak nokta bulunan bũlgelerde etiketleme iřlemi yapılarak, bir veri seti oluřturulur. Bu veri seti, YOLO'nun tespit edeceđi nesneyi ũđrenmesi iin gereklidir. YOLO'nun eđitimi sırasında algoritma veri setindeki gũrũntũleri, gũrũntũlerin piksellerini ve hali hazırda yapılmıř olan etiketleri sadece birer defa inceler. Eđitim boyunca, YOLO'nun evriřimli katmanları gũrsellerde bulunan sıcak noktalara ũzgũ gũrsel ũz nitelikleri ũđrenir. Bařka bir deyiřle model, sıcak nokta hatalarının olađan halin dıřında beyaz ve daha parlak noktaların olduđunu ũđrenir.




řekil 2.15. (a) Sıcak nokta verisi, (b) veri etiketlenmesi, (c) YOLO'nun tespiti

Tespit ařamasına geildiđinde ise model, sıcak noktaların bulunduđu bũlgeleri tahmin etmeye alıřır. Her tahmin iin bir gũven skoru atayarak gũven skoru dũřũk olan tahminleri eler. Ayrıca aynı sıcak nokta iin yapılan oklu tespitleri de tek bir tespitte birleřtirir. Geriye kalan tahminler, YOLO'nun incelediđi gũrseldeki sıcak noktalardır. Sonu olarak termal gũrũntũ ierisinde bulunan sıcak noktaları etraflarına izilmiř sınırlayıcı kutucuklar ile iřaretleyip řekil 2.15(c)'deki gibi bir ıktı olarak sunar.

3. MATERYAL VE YÖNTEM

3.1. Çalışma Alanı


Bu çalışmada kullanılan veri seti, Türkiye'nin Ege Bölgesi'nde yer alan Manisa ilinin Kula ilçesine bağlı İncesu mahallesinde konumlanmış bir güneş enerji santralinden temin edilmiştir. Çalışma sahasının güneş enerjisi potansiyelini göstermek amacıyla, Türkiye Cumhuriyeti Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'na bağlı Meteoroloji Genel Müdürlüğü (MGM) tarafından sağlanan veriler kullanılmıştır. Bu kapsamda, Heliostat yöntemiyle oluşturulan ve 2004-2021 yılları arasını kapsayan Manisa iline ait ortalama günlük küresel güneş radyasyonu ($\text{kWh/m}^2\text{-gün}$) dağılım haritası Şekil 3.1'de sunulmaktadır (MGM, 2025).



Şekil 3.1. 2004-2021 yılları ortalama küresel güneş radyasyonu dağılım haritası

Santralin konumlandığı bölgenin güneş enerjisi potansiyeli incelendiğinde, Yenilenebilir Enerji Genel Müdürlüğü (YEGM) tarafından 1985-2006 dönemi verileriyle hazırlanan ve Şekil 3.2'de sunulan Güneş Enerjisi Potansiyeli Atlası'na (GEPA) göre, Kula ilçesinin yıllık toplam güneş radyasyonu değerinin $1550\text{-}1650 \text{ kWh/m}^2\text{-yıl}$ aralığında olduğu görülmektedir. Bölgedeki ortalama günlük radyasyon, en yüksek değerine $6,46 \text{ kWh/m}^2\text{-gün}$ ile Temmuz ayında ulaşırken, en düşük değerini $1,62 \text{ kWh/m}^2\text{-gün}$ ile Aralık ayında almaktadır. Güneşlenme süreleri de bu mevsimsel

değişime paralellik göstermekte olup, en uzun süre 11,64 saat ile Temmuz’da, en kısa süre ise 3,96 saat ile Aralık’ta kaydedilmiştir (YEGM, 2025).



(a)

(b)

Şekil 3.2. GEPA’ya göre Manisa ilinin; (a) Global radyasyon değerleri (kWh/m²-gün), (b) Güneşlenme süreleri (saat)


3.2. Veri Toplama ve Hazırlık Süreci

Bu çalışmada kullanılan veri seti, güneşli ve açık hava koşullarında İHA ile elde edilen toplam 1443 adet görüntüden oluşmaktadır. Söz konusu görüntüler, Ankara merkezli bir enerji firmasının mühendisleri tarafından gerçekleştirilen saha çalışmaları esnasında elde edilmiş kızılötesi (termal) fotoğraflardır. Veri seti, özellikle sıcak nokta arızası sergileyen FV panellerin görsellerine odaklanmaktadır. Görüntüleme süreci, farklı zaman dilimlerinde İHA kullanılarak gerçekleştirilmiş olup, İHA’nın operasyonel uçuş rotası Şekil 3.3’te şematik olarak gösterilmektedir. Her görüntü, konum verilerini (enlem, boylam ve yükseklik) içeren Değiştirilebilir Görüntü Dosyası Biçimi (Exchangeable Image File Format - EXIF bilgileriyle birlikte kaydedilmiştir.



Şekil 3.3. İHA’nın santral sahasındaki uçuş güzergahı

YOLO tabanlı modellerin eğitimi için oluşturulan veri setindeki kızılötesi görüntüler üzerinde çeşitli veri artırma teknikleri uygulanmıştır. Bu işlemler, Roboflow platformu aracılığıyla gerçekleştirilmiştir. Bu çalışmada uygulanan başlıca veri artırma yöntemleri; $\pm 5\%$ bulanıklaştırma, 90° çevirme, 90° döndürme, 180° aynalama, kaydırma, $\pm 5\%$ parlaklık ve $\pm 10\%$ kontrast ayarlamalarıdır. Kontrast gibi parametrelerde yapılan değişiklikler düşük tutulmuş, böylece termal tonlamanın bozulmaması gözetilmiştir. Bu tekniklerin kullanımıyla veri setinin örnek sayısı ve çeşitliliği artırılarak modelin aşırı öğrenme eğilimi azaltılmıştır. Görsellerdeki sıcak nokta anomalileri, LabelImg yazılımı kullanılarak YOLO formatında etiketlenmiştir. Buna ek olarak, model performansını olumsuz yönde etkileyebilecek ve yanlış sınıflandırmalara neden olabilecek karmaşık arka plan etkilerinin minimize edilmesi amacıyla, negatif örnekler de veri setine dâhil edilmiştir (Du et al., 2021). Bu negatif örnekler, herhangi bir arıza bulunmayan FV panellere ait görüntülerden oluşmaktadır. Negatif örneklerin kullanımındaki temel amaç, modelin yalnızca sıcak nokta tespitine odaklanmasını engellemek, arka plan verisini de öğrenmesini sağlayarak yanlış pozitif tahminlerin önüne geçmektir. Bu yaklaşımla modelin genel doğruluk ve güvenilirliğinin artırılması hedeflenmiştir. Çalışmada izlenen genel adımlar Şekil 3.4'te görselleştirilmiştir.



Şekil 3.4. Çalışmanın temel adımları

FV sistemlerde kızılötesi görüntüleme tekniklerinin uygulanmasında dikkat edilmesi gereken temel unsurlardan biri de kullanılacak ekipmanların seçimidir (Lamaka

et al., 2023). Bu çalışmada, veri setinin oluşturulması amacıyla DJI marka İHA ile birlikte, İHA üzerine entegre edilmiş Zenmuse H20T marka kızılötesi kamera tercih edilmiştir. Zenmuse H20T kamerası, 8-14 μm spektral aralığı, 13,50 mm odak uzaklığı (f), 9,80 μm piksel boyutu (Δ), 36,30 mm L_0^{50} ve 145,18 mm L_0^{200} değerlerine sahip teknik özellikleriyle yüksek çözünürlüklü termal görüntüleme sağlamaktadır.

Sıcak nokta içeren görüntülerin azlığı, modelin genelleme yeteneğini sınırlamıştır. Bu durumu aşmak için kapsamlı veri artırma yöntemleri uygulanmış ve negatif örnek (yani arıza içermeyen panel görüntülerinin) sayısı dengelenmiştir. İHA'nın farklı yükseklik ve açılardan uçurulması veri çeşitliliğini artırırken, aynı arızaların tekrarını önlemek amacıyla kümeleme algoritmaları ve ısı haritası analizleri kullanılmıştır. Böylece veri temsili tutarlılığı ve görselleştirme doğruluğu geliştirilmiştir.

3.3. Veri Setinin İçeriği

Veri seti, 543 orijinal görüntü, 400 artırılmış görüntü ve 400 negatif örnekten oluşmakta olup, toplam 1443 görüntü dengeli bir biçimde eğitim, doğrulama ve test alt kümelerine ayrılmıştır. Bu kapsamda; 1009 görüntü (%70) eğitim, 218 görüntü (%15) doğrulama ve 216 görüntü (%15) test amacıyla kullanılmıştır. Veri dağılımı görsel olarak Şekil 3.5'te sunulmuştur.



Şekil 3.5. Çalışmada kullanılan veri setinin dağılımı


3.4. Çalışmada Kullanılan YOLO Algoritmaları

3.4.1. YOLOv9

YOLOv9, derin sinir ağlarındaki katmanlar arası bilgi kaybı problemini ve hafif ağlarda derinlemesine denetim uygulamasının yarattığı optimizasyon zorluklarını ele almak üzere geliştirilmiştir. Model, bu sorunlara çözüm olarak Programlanabilir Gradyan Bilgisi (Programmable Gradient Information - PGI) adı verilen yeni bir metodoloji önermektedir. Önceki çalışmaların aksine YOLOv9, veri akışındaki bilgi bütünlüğüne odaklanır. PGI'nın temel işlevi, bir yardımcı tersinir kol kullanarak güvenilir gradyan bilgisi üretmek ve bu sayede amaç fonksiyonunun doğru bir şekilde optimize edilmesini sağlamaktır. Bu yaklaşım, bilgi kaybını engelleyerek ve yanıltıcı gradyanları ortadan kaldırarak modelin nesne tespiti performansını artırmayı hedefler.

PGI'nın mimarisi üç temel bileşen üzerine kuruludur. Birincisi, modelin çıkarım için kullandığı standart ana daldır. İkinci ve en kritik bileşen olan yardımcı tersinir kol ise, ana dalın geri yayılım süreci için güvenilir gradyanlar üreterek ağ parametrelerinin etkin bir şekilde güncellenmesini sağlar. Bu yapı, girdi verileri ile hedefler arasındaki doğru eşlemeyi koruyarak kayıp fonksiyonunun modeli doğru yönlendirmesine yardımcı olur ve ileri besleme adımlarında daha az ilişkili özelliklerden kaynaklanabilecek yanıltıcı korelasyonların öğrenilmesini engeller. Tersinir mimarisi sayesinde tam bilgi akışını güvence altına alan bu kol, çıkarım maliyetini artırmamak adına test aşamasında devre dışı bırakılabilme esnekliğine sahiptir. Son olarak, özellikle hafif modeller ve çoklu tahmin dallarına sahip mimariler için geliştirilen çok seviyeli yardımcı bilgi mekanizması, farklı tahmin katmanlarından dönen gradyanları bir entegrasyon ağı aracılığıyla birleştirir. Bu sayede, ana dalın tüm hedef nesneler hakkında bütüncül ve kapsamlı bilgi edinmesi sağlanarak öğrenme süreci güçlendirilir.

Şekil 3.6'da gösterildiği üzere, YOLOv9'un omurga mimarisi, Genelleştirilmiş Etkin Katman Toplama Ağı (Generalized Efficient Layer Aggregation Network - GELAN) olarak adlandırılan yeni ve hafif bir yapıya dayanmaktadır. GELAN, mevcut CSPNet ve ELAN mimarilerinin temel prensiplerini birleştirerek geliştirilmiştir. Gradyan yolu planlaması konsepti üzerine tasarlanan bu mimari, esnek yapısı, ağ derinliğindeki değişimlere karşı gösterdiği dayanıklılık ve yüksek parametre verimliliği gibi önemli avantajlar sunar. Bu özellikler sayesinde GELAN, farklı hesaplama kapasitelerine sahip cihazlar ve çeşitli uygulama senaryoları için optimize edilmiş modellerin geliştirilmesini mümkün kılmaktadır.




Şekil 3.6. YOLOv9 algoritmasının mimarisi (Wang vd., 2024b kaynağından düzenlenerek oluşturulmuştur.)

YOLOv9, önceki varyantlara kıyasla sunduğu mimari iyileştirmeler sayesinde çeşitli avantajlar sağlamaktadır. Özellikle PGI ve GELAN mimarileriyle birleştirildiğinde, modelin eğitim sürecinde daha yüksek performans elde edildiği görülmektedir. Bu yapı, özellikle hafif model konfigürasyonlarında üstün sonuçlar üretirken, farklı boyutlardaki model varyantlarında da doğruluk açısından istikrarlı ve kararlı bir yapı sunmaktadır. Ayrıca, YOLOv9'un MS COCO gibi standart nesne tespiti veri setleri üzerinde, daha az parametre ve düşük hesaplama maliyetiyle yüksek doğruluk oranlarına ulaşması, gerçek zamanlı uygulamalarda tercih edilme potansiyelini artırmaktadır. Tüm bu özellikler, modelin hem parametre sayısı hem de hesaplama karmaşıklığı açısından optimal verimlilik sunduğunu göstermektedir (Wang vd., 2024b).

3.4.2. YOLOv10

YOLOv10 varyantının mimarisi, kendisinden önceki modeller gibi omurga, boyun ve kafa bileşenlerini temel almakla birlikte hem mimari tasarımda hem de eğitim sonrası işlemlerde getirdiği köklü yeniliklerle ayrılmaktadır. Bu yeniliklerin en önemlilerinden biri, geleneksel nesne tespiti ardışık düzenlerinde çıkarım hızını önemli ölçüde yavaşlatan Maksimum Olmayan Bastırma (Non-Maximum Suppression - NMS) adımına yönelik geliştirmelerdir. YOLOv10, NMS'nin yarattığı bu hesaplama yükünü ortadan kaldırmak amacıyla, tutarlı çift atamalar adında NMS-içermeyen yeni bir eğitim stratejisi önermektedir. Şekil 3.7'de detaylandırılan bu strateji, iki tamamlayıcı mekanizmadan oluşur: Eğitim sürecinde zengin denetim sinyalleri sağlayarak model performansını optimize eden bire-çok atama yapan başlık ve her bir gerçek nesneye yalnızca tek bir

tahmin atayarak çıkarım aşamasında NMS ihtiyacını tamamen ortadan kaldıran bire-bir atama yapan başlık. Bu ikili yaklaşım, modelin hem yüksek doğrulukla eğitilmesini hem de çıkarım sırasında maksimum verimliliğe ulaşmasını sağlar.



Şekil 3.7. YOLOv10 algoritmasının mimarisi (Wang vd., 2024a kaynağından düzenlenerek oluşturulmuştur.)


Eğitim sürecinde her iki başlık türü de (bire-bir ve bire-çok) optimize edilerek omurga ve boyun katmanları arasında çoklu başlık atamalarının avantajlarından en yüksek düzeyde yararlanır. Modelin çıkarım aşamasında ise yalnızca bire-bir başlık ataması tercih edilerek işlem gerçekleştirilir. Bu yaklaşım, geleneksel olarak kullanılan NMS gibi ön işleme adımlarına gereksinim duymadan uçtan uca nesne tespiti imkânı sunar. Çift başlık atamalarının kararlı biçimde çalışabilmesi için tutarlı eşleştirme metriği kullanılır. Bu metrik; sınıflandırma skoru, gerçek kutu ile tahmin kutusu arasındaki örtüşme oranını (IoU) ve uzamsal ön bilgiyi bütünleştirerek başlık atamalarında yüksek doğruluk sağlar. Böylece hem bire bir hem de bire çok başlıklar ile yapılan tahminler ile gerçek nesneler arasındaki uyum korunur. Tutarlı eşleştirme metriği, modelin daha etkin şekilde optimize edilmesini sağlayarak genel tespit performansını artırır (Wang et al., 2024a).

3.4.3. YOLOv11

YOLOv11, önceki mimari ve eğitim yaklaşımlarını temel alarak geliştirilmiş, gerçek zamanlı nesne tespiti görevlerinde daha az parametre kullanımıyla daha hızlı ve verimli bir performans sunmayı hedefleyen bir modeldir. Bu sürüm, önceki YOLO varyantlarında yer alan Uzamsal Piramit Havuzlama-Hızlı (Spatial Pyramid Pooling-Fast - SPPF) bloğunu korurken, buna ek olarak Paralel Uzamsal Dikkatli Evrişimli Blok (Convolutional Block with Parallel Spatial Attention - C2PSA) isimli yeni bir blok entegre etmektedir. C2PSA, modelin görüntüdeki önemli bölgelere odaklanmasını

sağlayarak uzamsal dikkat mekanizmasını güçlendirir. YOLOv11'in mimarisi, klasik YOLO yapısında yer alan omurga, boyun ve kafa bileşenlerinde yapılan yapısal yeniliklerle desteklenmiştir: Omurga bölümünde, önceki varyantlarda kullanılan C2f blokları yerine C3k2 (Cross Stage Partial with kernel size 2) blokları tercih edilmiştir. C3k2 blokları, daha küçük çekirdek boyutları kullanarak işlem hızını artırırken, tespit performansında herhangi bir kayba yol açmaz. Ayrıca, C2PSA bloğunun eklenmesi sayesinde modelin farklı boyut ve konumlara sahip nesneleri daha doğru şekilde algılaması amaçlanmaktadır. Boyun katmanında da C3k2 blokları kullanılmış ve C2PSA modülü ile bir dikkat mekanizması oluşturulmuştur. Bu yapı, önceki modellerle karşılaştırıldığında modelin dikkat yönlendirme kapasitesini önemli ölçüde artırmaktadır. Kafa bölümünde, C3k2 bloğunun ardından CBS (Convolution-BatchNorm-SiLU) katmanları eklenmiştir. Bu katmanlar, veri akışını dengelemek amacıyla toplu normalizasyon ve sigmoid doğrusal birim (Sigmoid Linear Unit - SiLU) aktivasyon fonksiyonunu kullanır. Devamında Conv2D katmanı ile her tespit dalında sınırlayıcı kutu koordinatları ve sınıf tahminlerine ait özellikler çıkarılır. Son olarak, tespit katmanında sınırlayıcı kutular ve skor değerleri birleştirilerek nihai çıktı elde edilir.

YOLOv11, entegre edilen gelişmiş dikkat mekanizması ve optimize edilmiş mimarisi sayesinde daha az parametre ile daha hızlı ve yüksek doğruluklu tahminler sunmaktadır. Şekil 3.8'de gösterildiği üzere; nesne algılama, sınıflandırma, segmentasyon, poz tahmini ve yönlendirilmiş nesne algılama gibi çeşitli görevleri destekleyerek bilgisayarla görü uygulamaları için geniş bir kullanım alanı sunmaktadır. Ayrıca, bulut tabanlı sistemler başta olmak üzere farklı donanım ve yazılım ortamlarında kolaylıkla uygulanabilir olması sayesinde kullanıcıya esnek çözümler sağlamaktadır (Khanam ve Hussain, 2024; Ultralytics, 2024a; Ultralytics, 2024b).




Şekil 3.8. YOLOv11 algoritmasının mimarisi (Khanam ve Hussain, 2024 kaynağından düzenlenerek oluşturulmuştur.)

3.4.4. YOLOv12

Şubat 2025'te yayımlanan YOLOv12, YOLO serisinin en güncel ve yenilikçi sürümüdür. Önceki YOLO modellerinin ağırlıklı olarak CNN tabanlı mimarilere dayanmasına karşın, YOLOv12 dikkat merkezli yeni bir mimari sunarak gerçek zamanlı nesne tespitinde alternatif bir yaklaşım önermektedir. Bu model, CNN tabanlı yöntemlere duyulan gereksinimi azaltmayı ve hatta tamamen ortadan kaldırmayı hedeflemektedir. Klasik YOLO mimari yapısını büyük ölçüde korumakla birlikte, dikkat tabanlı mekanizmalar, omurga ağında yapılan değişiklikler ve çeşitli mimari iyileştirmelerle hem yüksek doğruluk hem de hızlı çıkarım sağlamayı amaçlamaktadır.

YOLOv12'nin temel yeniliklerinden biri olan dikkat merkezli mekanizma, geleneksel CNN mimarileri yerine Alan Dikkat Modülü (Area Attention - A2) kullanımıdır. A2 modülü, girdi özellik haritasını yatay ve dikey olarak eşit parçalara bölerek hesaplama yükünü azaltmakta ve işlem hızını artırmaktadır. Çapraz dikkat, eksenel dikkat veya kaydırılmış pencere yöntemlerinden farklı olarak, Şekil 3.9'da gösterildiği gibi, A2 varsayılan olarak haritayı dört parçaya ayırarak sade ve hızlı bir hesaplama gerçekleştirir. Bununla birlikte, bu yaklaşım bazı durumlarda doğrulukta düşüşe ve hesaplama yükünde artışa neden olabilmektedir.



Şekil 3.9. YOLOv12 algoritmasının; (a) alan dikkat modülü, (b) mimarisi (Tian et al., 2025 kaynağından düzenlenerek oluşturulmuştur.)

Bu ek yük ve optimizasyon sorunlarına çözüm olarak modelde Artık Verimli Katman Toplama Ağı (Residual Efficient Layer Aggregation Network – R-ELAN) kullanılmıştır. R-ELAN, klasik ELAN mimarisinden farklı olarak, tek bir özellik haritası

üzerinde blok düzeyinde artık bağlantılar ve ölçekleme teknikleri ile daha kararlı bir öğrenme süreci sağlar. Özellikle YOLOv12'nin l ve x gibi daha büyük varyantlarında stabil eğitimi desteklemek adına R-ELAN önemli bir katkı sunmaktadır.

Bunun yanı sıra, dikkat mekanizmasının neden olduğu bellek erişim verimsizliklerini gidermek amacıyla FlashAttention yöntemi entegre edilmiştir. Dikkat hesaplamaları sırasında GPU ile SRAM arasındaki bellek erişimi gecikmeleri, dikkat tabanlı sistemlerin CNN tabanlı modellere kıyasla daha yavaş çalışmasına neden olabilmektedir. FlashAttention, bu sorunu ortadan kaldırmak üzere bellek erişim süreçlerini optimize ederek dikkat hesaplamalarının verimliliğini artırır.

YOLOv12 modelini önceki sürümlerden ayıran bir diğer önemli unsur, donanımsal gereksinimlere duyduğu bağımlılıktır. Dikkat merkezli mimarisi nedeniyle ortaya çıkan bellek yönetimi sorunlarını aşabilmek için model, FlashAttention teknolojisinin kullanımını gerektirmektedir. Ancak FlashAttention yalnızca belirli GPU mimarilerini desteklemektedir; bu kapsamda NVIDIA'nın Ampere, Ada Lovelace, Hopper ve Turing mimarilerine sahip GPU'ları (örneğin T4, A100, RTX serisi) önerilmektedir. Bu nedenle, YOLOv12 algoritmasının verimli ve kararlı bir şekilde çalıştırılabilmesi için uyumlu NVIDIA GPU donanımı kullanımı tavsiye edilmektedir (Tian et al., 2025).

İncelenen YOLO modelleri, mimari yapıları ve optimizasyon alanları bakımından çeşitli farklılıklar göstermekte olup bu durum Çizelge 3.1'de detaylandırılmıştır.

Çizelge 3.1. YOLO modellerine ait özellikler ve farklar

Model	Mimari ve Teknolojik Farklılıklar
YOLOv9	- Bilgi kaybını önlemek için PGI mekanizmasını sunar. - Hafif ağ mimarisi olarak GELAN'ı kullanır. - Özellikle hafif modellerde performansı artırmaya odaklanır.
YOLOv10	- Çıkarım hızını artırmak amacıyla NMS sonrası işleme ihtiyacını ortadan kaldıran tutarlı çift atamalar eğitim stratejisini kullanır. - Eğitimde bire çok ve bire bir başlıklar kullanırken, çıkarımda yalnızca bire bir başlık kullanır.
YOLOv11	- Daha az parametre ile daha hızlı gerçek zamanlı nesne tespiti için tasarlanmıştır. - Omurgada C2f bloğu yerine C3k2 bloğunu kullanır. - Modelin önemli alanlara odaklanmasını sağlayan C2PSA bloğunu ekler. - Nesne algılama dışındaki görevleri de (segmentasyon, poz tahmini vb.) destekler.
YOLOv12	- CNN tabanlı mimarilere alternatif olarak dikkat merkezli bir yaklaşım sunar ve A2 modülünü kullanır. - Dikkat mekanizmasının getirdiği Ek yükü ve optimizasyon sorunlarını çözmek için R-ELAN'ı kullanır. - Dikkat mekanizmasının bellek verimsizliğini aşmak için FlashAttention teknolojisine ihtiyaç duyar ve bu nedenle güçlü NVIDIA ekran kartlarını (Turing veya daha yenisi) gerektirir.

3.5. Performans Değerlendirme Metrikleri

Bu çalışmada geliştirilen derin öğrenme temelli modellerin etkinliğini nesnel biçimde değerlendirebilmek amacıyla, nesne tespiti ve sınıflandırma problemlerinde yaygın olarak kabul gören beş farklı performans metriği kullanılmıştır. Bunlar; Kesinlik, Duyarlılık, F1 Skoru, mAP50 ve mAP50-95 şeklinde sıralanmaktadır. Söz konusu metrikler, modelin yalnızca doğru pozitif tahmin yeteneğini değil, aynı zamanda genel başarı düzeyini de nicel olarak ifade etmeye olanak tanımaktadır.

Kesinlik, modelin pozitif olarak tahmin ettiği örnekler arasında gerçekten doğru olanların oranını ifade eder. Yanlış pozitiflerin sayısının düşük olması, bu metriğin yüksek çıkmasını sağlar. Matematiksel olarak Denklem (3.1)'deki formül ile hesaplanır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.1)$$

Burada TP doğru pozitifleri, FP ise yanlış pozitifleri temsil eder.

Duyarlılık, modelin gerçekten pozitif olan örneklerin ne kadarını doğru şekilde tespit edebildiğini ölçer. Bu metrik, kaçırılan pozitif örneklerin (yanlış negatiflerin) minimize edilmesini amaçlayan durumlarda önem kazanmaktadır. Denklem (3.2) kullanılarak hesaplanır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.2)$$

Burada TP doğru pozitif, FN ise yanlış negatif örnek sayısını ifade eder.

F1 skoru, kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır. Bu metrik, her iki ölçütün dengesini gözeterek, dengesiz veri setlerinde daha sağlıklı bir başarı değerlendirmesi yapılmasına imkân tanır. Özellikle bir metrik yüksekken diğerrinin düşük olduğu durumlarda, F1 skoru bu farkı dengeleyici bir gösterge olarak öne çıkar. Modelin genel performansı değerlendirilirken F1 skoru göz önünde bulundurulmalıdır (Du vd., 2021; Jegham vd., 2024). F1 skoru ise Denklem (3.3)'te verilen matematiksel ifadeyle hesaplanır.

$$F1 \text{ skoru} = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.3)$$

mAP, nesne tespiti görevlerinde modelin genel başarımını ölçmek için yaygın olarak kullanılan kapsamlı bir performans metriğidir. Bu metrik, her sınıf için hesaplanan Ortalama Hassasiyet (AP – Average Precision) değerlerinin ortalamasını alarak modelin sınıflar genelindeki tespit yeteneğini değerlendirir. Nesne tespiti için mAP genellikle belirli IoU eşiklerinde hesaplanır. IoU, tahmin edilen sınırlayıcı kutu ile gerçek sınırlayıcı kutu arasındaki örtüşmeyi ölçer ve Denklem (3.4)'teki şekilde tanımlanır:

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} \quad (3.4)$$

mAP50, nesne tespiti modellerinde tahmin edilen nesne konumlarının, gerçek nesne konumlarıyla %50 eşleşme ($IoU \geq 0.5$) sağladığı durumlarda ortalama doğruluk oranını ifade eder. Bu metrik, modelin belirli bir eşik değerinde genel doğruluk düzeyini yansıtarak, özellikle sınırlı hata toleransı olan sistemlerde değerlendirme için kullanılmaktadır.

$$mAP50 = \frac{1}{N} \sum_{i=1}^N AP_i \quad (IoU = 0,50 \text{ için}) \quad (3.5)$$

Burada N, sınıf sayısını ifade eder.

mAP50–95, IoU eşik değerinin 0,50’den 0,95’e kadar 0,05’lik artışlarla değiştirildiği 10 farklı değer üzerinden hesaplanan ortalama doğruluk değeridir. Bu metrik, modelin farklı eşik seviyelerinde gösterdiği performansı bütüncül bir şekilde değerlendirerek, genel tespit başarısı hakkında daha kapsamlı bir fikir sunar.

$$mAP50 - 95 = \frac{1}{10} \sum_{t=0,50}^{0,95} mAP_t \quad (3.6)$$

Burada mAP_t , IoU eşiği t olduğunda hesaplanan ortalama doğruluğu ifade eder.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 algoritmalarının FV panellerdeki sıcak nokta anomalilerini tespit etme performansları, çeşitli metrikler kullanılarak karşılaştırmalı olarak analiz edilmiştir. İlk olarak, modellerin eğitim süreci ve kullanılan performans metrikleri tanımlanmış, ardından elde edilen nicel sonuçlar tablolar ve grafikler eşliğinde sunulmuştur. Son olarak, modellerin mimari farklılıklarıyla ilişkisi tartışılarak pratik sonuçları değerlendirilmiştir.

Her bir model, son yıllarda geliştirilen YOLO sürümlerine yapılan katkıları (Ultralytics, 2024a; Wang vd., 2024a) temel alarak, gerçek zamanlı nesne tespiti kabiliyetini farklı seviyelerde sunmaktadır. Modellerin eğitiminde Çizelge 4.1'deki uygun hiperparametreler ve optimizasyon teknikleri uygulanmıştır.

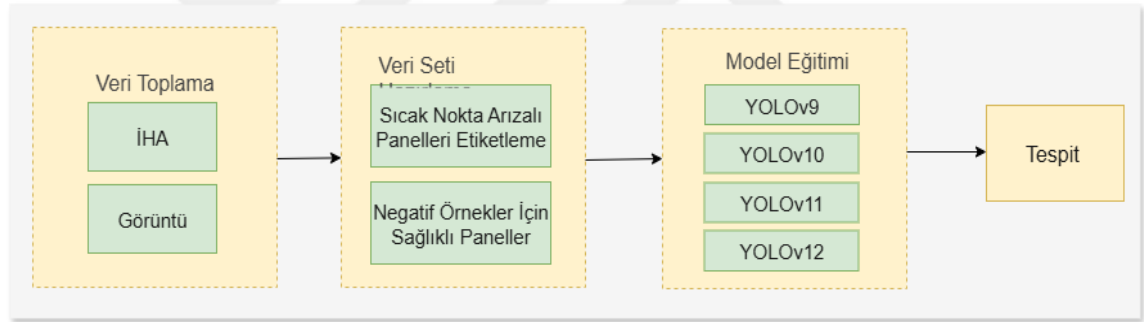
Çizelge 4.1. Modellerin eğitim parametreleri

Parametre	YOLOv9	YOLOv10	YOLOv11	YOLOv12
Epoch Sayısı	100	100	100	100
Optimizasyon Algoritması	AdamW	AdamW	AdamW	AdamW
IoU Eşiği (Threshold)	0,7	0,7	0,7	0,7
Momentum	0,9	0,9	0,9	0,9
Veri Çoğaltma	Var	Var	Var	Var
Patience	Yok	Yok	Yok	30
GPU	T4 GPU	T4 GPU	T4 GPU	A100 GPU

Modellerin eğitim süreci birkaç temel aşamadan oluşmaktadır. İlk olarak, etiketli görüntüler (sıcak nokta var/yok) eğitim için uygun formata getirilerek veri yükleme ve ön işleme işlemleri gerçekleştirilmiştir. Bu aşamada, görüntülerin doğru etiketlendiğinden ve modelin anlayabileceği yapıya dönüştürüldüğünden emin olunmuştur. Ardından, eğitimde kullanılacak YOLO sürümüne (YOLOv9, YOLOv10, YOLOv11 ve YOLOv12) göre model konfigürasyonları dikkatlice belirlenmiş ve her bir model için adaletli bir kıyaslama yapılabilmesi adına standart ayarlar kullanılmıştır. Eğitim sürecinde, 100 epoch boyunca AdamW optimizasyon algoritması uygulanmış ve bu sayede ağırlıklar sürekli güncellenerek modelin öğrenmesi sağlanmıştır. Her epoch sonunda doğrulama seti kullanılarak modelin ara performansı değerlendirilmiş ve olası aşırı öğrenme durumu kontrol edilmiştir. Eğitim tamamlandıktan sonra, test seti

üzerinde modelin kesinlik, duyarlılık, F1 skoru ve ortalama hassasiyet değerleri hesaplanarak nihai performans analizleri yapılmıştır. Bu süreç sayesinde her modelin güçlü ve zayıf yönleri sistematik olarak değerlendirilmiştir.

Bu çalışmada izlenen genel yöntem akışı, Şekil 4.1’de şematik olarak sunulmuştur. İlk aşamada, FV enerji santraline ait alanın termal görüntüleri, İHA kullanılarak sistematik biçimde elde edilmiştir. Toplanan bu görüntüler, çalışma kapsamında kullanılacak veri setini oluşturmak amacıyla sınıflandırılarak etiketlenmiştir. Veri seti oluşturulurken, sıcak nokta anomalisi tespit edilen FV paneller pozitif örnekler olarak, sağlıklı paneller ise negatif örnekler olarak etiketlenmiştir. Bu ön hazırlık sürecini takiben, oluşturulan veri seti kullanılarak dört farklı YOLO algoritması (YOLOv9, YOLOv10, YOLOv11 ve YOLOv12) üzerinde eğitim gerçekleştirilmiştir. Eğitim süreci sonunda, her bir modelin sıcak nokta arızalarını tespit etme başarımı belirlenen performans metrikleri üzerinden karşılaştırmalı olarak değerlendirilmiş ve ardından tespit aşamasına geçilmiştir.



Şekil 4.1. YOLO modellerinin eğitimi için takip edilen adımlar


Model eğitiminin tamamlanmasının ardından, sıcak nokta tespitlerine ilişkin çıktılar, modelin oluşturduğu sınırlayıcı kutu koordinatları ile birlikte kaydedilmiştir. Bu aşamada, her bir görüntüye ait EXIF meta verileri kullanılarak (enlem, boylam ve yükseklik bilgileri), tespit edilen sıcak nokta anomalileri coğrafi olarak haritalandırılmıştır. Böylece, güneş enerji santralinde yer alan panellerin hangilerinde ve hangi konumlarda sıcaklık anomalileri olduğu, Şekil 4.2’de gösterildiği gibi konumsal düzlemde görsel olarak sunulabilir hâle getirilmiştir. Sıcak nokta içeren panellerin tespit edilmesinin ardından, bu panellere ait sınırlayıcı kutular, ilgili görüntülerin meta verileri ile eşleştirilerek bir veri listesi oluşturulmuştur. İHA’nın uçuş güzergâhı boyunca elde edilen EXIF verileri ile bu listeler ilişkilendirilmiş ve her bir arızalı panelin coğrafi konumu (enlem ve boylam bilgileri) hesaplanmıştır. Ardından, konumu belirlenen arızalı

paneller, riskli bölgelerin daha net biçimde analiz edilebilmesi amacıyla ısı haritası yöntemiyle görselleştirilmiştir. Bu şekilde elde edilen harita, bakım ve onarım faaliyetlerinde görevli saha ekipleri tarafından etkili bir şekilde kullanılabilecek, yönlendirici bir karar destek aracı olarak işlev görmektedir.



Şekil 4.2. EXIF verileri ile konumları belirlenen sıcak nokta arızalarının ısı haritası

YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 modellerinin sınıflandırma performanslarının daha ayrıntılı biçimde değerlendirilebilmesi amacıyla, her bir modelin TP, FP ve FN değerleri görsel olarak karşılaştırılmıştır. Bu değerler, modellerin sıcak nokta içeren panelleri doğru tespit edebilme kabiliyetini ve sağlıklı panelleri yanlış şekilde etiketleme eğilimini analiz etmeye olanak tanımaktadır. Şekil 4.3'te, her bir modelin sınıflama doğruluğu açısından güçlü ve zayıf yönlerini ortaya koyan bu temel sınıflandırma çıktıları karşılaştırmalı olarak sunulmuştur.



Şekil 4.3. Modellerin karışıklık matrisi değerleri

Şekil 4.3'te sunulan değerler, her bir modelin gerçek arızaları ne ölçüde doğru tespit edebildiğini (TP), hangi oranda yanlış alarm ürettiğini (FP) ve kaç adet arızayı atladığını

(FN) nicel biçimde ortaya koymaktadır. Grafik incelendiğinde, YOLOv9 ve YOLOv11 ailesine ait bazı sürümlerin yüksek TP değerleriyle öne çıktığı görülmektedir. Özellikle YOLOv9 m sürümü, 172 TP, 38 FP ve 24 FN değeri ile hem yüksek doğru tespit oranı hem de düşük yanlış alarm üretimi açısından dikkat çekmektedir. Bu sonuçlar, modelin kesinlik ve duyarlılık dengesini başarılı biçimde sağladığını göstermektedir. Benzer şekilde, YOLOv9 c sürümü de yine 172 TP değeri üretmiş olmakla birlikte, 44 FP değeriyle biraz daha yüksek oranda yanlış alarm üretmiştir. Bu durum, modelin arıza tespitinde yüksek başarı gösterirken, sınıflandırma sürecinde daha agresif davrandığını ve bu nedenle nispeten daha fazla yanlış pozitif sonuç ürettiğini göstermektedir.

YOLOv11 ailesinde, YOLOv11 s (TP=168, FP=37, FN=28) ve YOLOv11 x (TP=171, FP=48, FN=25) sürümleri öne çıkmaktadır. Her iki modelin doğru tespit sayıları YOLOv9 m'ye oldukça yakın düzeydedir. Ancak, YOLOv11 x sürümünde daha yüksek bir FP değeri gözlemlenmiştir, bu da modelin zaman zaman gereksiz uyarılara yol açabileceğini göstermektedir. Buna karşılık, YOLOv11 s sürümünün FP değerinin düşük kalması, modelin daha seçici ve istikrarlı bir performans sergilediğini ortaya koymaktadır. Ayrıca, YOLOv11 algoritmalarının YOLOv9'a kıyasla daha düşük parametre sayısı ve daha hızlı çalışma süresi sunduğu göz önünde bulundurulduğunda, bu performans avantajı daha da önem kazanmaktadır.

Önceden COCO veri seti ile eğitilmemiş olan YOLOv11 untrained sürümü (TP=170, FP=68, FN=26) de yüksek TP değerine ulaşmıştır. Ancak yüksek FP değeri, modelin aşırı duyarlı çalıştığını ve çok sayıda yanlış alarm ürettiğini göstermektedir. Bu durum, modelin genel olarak arıza tespitine eğilimli olduğunu ancak sınıflandırma doğruluğunun iyileştirilmesi gerektiğini ortaya koymaktadır. Bu bağlamda, daha geniş ve dengeli bir veri seti ile eğitildiğinde, YOLOv11 algoritmasının daha başarılı sonuçlar verebileceği öngörülmektedir.

YOLOv10 ailesine ait modeller, genellikle 158 ile 168 arasında değişen TP değerleri üretmiş ve genel performans açısından diğer iki algoritma ailesinin gerisinde kalmıştır. Her ne kadar bazı sürümleri kabul edilebilir düzeyde sonuçlar üretse de genel eğilim bu algoritmanın sınırlı başarıya sahip olduğunu göstermektedir.


YOLOv12 ailesinde ise en yüksek TP değerine YOLOv12 s sürümünün (TP=169) ulaştığı görülmektedir. Ancak bu model, aynı zamanda 73 FP ile en yüksek yanlış alarm oranına da sahiptir. Bu durum, modelin agresif bir sınıflandırma eğilimi gösterdiğini göstermektedir. Öte yandan, YOLOv12 l sürümünün (TP=168, FP=52, FN=28) daha

dengeli bir performans sergileyerek YOLOv12 ailesi içinde en kararlı varyant olduğu değerlendirilmektedir.

Çizelge 4.2, FV panellerdeki sıcak nokta anomalilerinin tespiti amacıyla geliştirilen farklı YOLO algoritma versiyonlarının karşılaştırmalı performans metriklerini sunmaktadır. Bu kapsamda; kesinlik, duyarlılık, F1 skoru, mAP50 ve mAP50-95 değerleri dikkate alınmıştır.

Çizelge 4.2. YOLO modellerinin karşılaştırmalı performans metrikleri

Versiyon	Kesinlik	Duyarlılık	F1 Skoru	mAP50	mAP50-95
YOLOv9 t	0.78581	0.73980	0.7621	0.81186	0.29135
YOLOv9 s	0.77675	0.79592	0.7862	0.85087	0.29346
YOLOv9 m	0.84301	0.76712	0.8033	0.85463	0.32593
YOLOv9 c	0.83194	0.79592	0.8135	0.85835	0.31394
YOLOv9 e	0.78053	0.74490	0.7623	0.81163	0.28935
YOLOv10 n	0.77447	0.80612	0.7900	0.82453	0.30200
YOLOv10 s	0.77940	0.75510	0.7671	0.81945	0.29021
YOLOv10 m	0.82376	0.75510	0.7879	0.83298	0.29746
YOLOv10 b	0.7918	0.75675	0.7739	0.81975	0.29038
YOLOv10 l	0.81535	0.76599	0.7899	0.83690	0.30262
YOLOv10 x	0.76735	0.78061	0.7739	0.82514	0.30298
YOLOv11 n	0.77971	0.77654	0.7781	0.83918	0.29699
YOLOv11 s	0.83005	0.82234	0.8262	0.86381	0.28583
YOLOv11 m	0.81763	0.78061	0.7987	0.83792	0.30282
YOLOv11 l	0.83272	0.76020	0.7948	0.84501	0.30730
YOLOv11 x	0.83961	0.72113	0.7759	0.83318	0.31112
YOLOv11 untrained	0.68638	0.82143	0.7479	0.81257	0.26637
YOLOv12 n	0.73635	0.78571	0.7602	0.81784	0.29628
YOLOv12 s	0.81280	0.75321	0.7819	0.82720	0.29495
YOLOv12 m	0.84290	0.76020	0.7994	0.85000	0.29591
YOLOv12 l	0.84498	0.77871	0.8105	0.84739	0.29927
YOLOv12 x	0.82678	0.71429	0.7664	0.83396	0.29837
YOLOv12 untrained	0.66139	0.76020	0.7074	0.72305	0.23697




Şekil 4.4. Modellerin karşılaştırmalı performans grafiği

Çizelge 4.2 ve Şekil 4.4'teki metrikler detaylı bir şekilde incelendiğinde, her modelin kendine özgü güçlü ve zayıf yönleri olduğu görülmektedir. Kesinlik, yani yanlış alarm üretmeme konusunda en başarılı model, %84,5'lik bir oranla YOLOv12 l versiyonudur; bu, yaptığı tespitlerin yüksek derecede güvenilir olduğunu gösterir. Buna karşılık, mevcut sıcak noktaları tespit etme ve atlamama başarısını ölçen duyarlılık metriğinde ise YOLOv11 s versiyonu %82,2 ile lider konumdadır. Bu model, aynı zamanda %82,6'lık F1 skoru ve %86,4'lük mAP50 değeri ile de zirvede yer alarak, kesinlik ve duyarlılık arasında en iyi dengeyi kuran ve genel performansı en yüksek olan model olduğunu kanıtlamaktadır. Ancak, tespit edilen anomalilerin konum hassasiyetini daha katı bir şekilde ölçen mAP50-95 metriği devreye girdiğinde, YOLOv9 m versiyonu %32,6 ile en iyi sonucu elde ederek zorlu koşullar altında en hassas konumlandırmayı yaptığını göstermiştir.

Model karşılaştırmalarında, YOLOv9 (özellikle “m” sürümü) mAP50-95 metriğinde en yüksek başarıyı elde ederek yüksek hassasiyetli konumlandırma yeteneğini kanıtlamıştır. YOLOv11 (“s” sürümü) duyarlılık, F1 skoru ve mAP50 değerlerinde öne çıkarak sıcak nokta tespitinde en etkili sonuçları sunmuştur. YOLOv12 (“l” sürümü) yüksek kesinlik değerine ulaşsa da diğer metriklerde nispeten düşük performans

göstermiştir. YOLOv10 ise doğruluk ve tespit başarısında diğer ailelerin gerisinde kalmıştır. Genel olarak, en başarılı ve dengeli sonuçlar YOLOv9 ve YOLOv11 ailelerinden elde edilmiştir.

Şekil 4.5, tez kapsamında incelenen YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 modellerinin sıcak nokta anomalilerini tespit etme performanslarının nitel bir karşılaştırmasını sunmaktadır.



Şekil 4.5. Modellerin sıcak nokta tespitleri; (a) görselin aslı, (b) YOLOv9, (c) YOLOv10, (d) YOLOv11, (e) YOLOv12


Şekil 4.5(a) herhangi bir işlem uygulanmamış orijinal termal görüntüleri içererek görsel bir referans teşkil etmektedir. Takip eden Şekil 4.5(b), (c), (d) ve (e) alt bölümleri ise sırasıyla YOLOv9, YOLOv10, YOLOv11 ve YOLOv12 modellerinin aynı görüntüler üzerindeki tespit sonuçlarını sergilemektedir. Modellerin çıktısı, tespit edilen anomali bölgelerini çevreleyen sınırlayıcı kutular ve her bir tespit için modelin güven seviyesini belirten olasılık skorları ile birlikte sunulmuştur. Şekil 4.5 incelendiğinde, YOLOv9 ve YOLOv11 modellerinin mevcut sıcak noktaları daha başarılı bir şekilde tespit ettiği, YOLOv11'in ise daha yüksek güven skorları ürettiği anlaşılmaktadır. Buna karşılık, YOLOv10 ve YOLOv12 modellerinin bazı sıcak nokta anomalilerini tespit edemediği (yanlış negatif), özellikle YOLOv12 modelinin hatalı bir tespitte bulunduğu (yanlış pozitif) gözlemlenmektedir.

Şekil 4.6 ile Şekil 4.26 arasında sunulan grafikler, her bir YOLO modelinin eğitim süreci boyunca gösterdiği öğrenme davranışını ve son tespit yetkinliğini çok yönlü olarak değerlendirmek adına önemli bir temel oluşturmaktadır. Bu grafikler; kesinlik-duyarlılık eğrileri, karışıklık matrisleri ve eğitim sürecini özetleyen hata grafikleri gibi farklı görsel çıktıları kapsamaktadır.

Kesinlik-duyarlılık eğrileri, modelin karar verme eşiği farklılaştıkça sınıflandırma performansındaki değişimi ortaya koymaktadır. Bu eğriler, bir modelin ne ölçüde doğru pozitifler tespit ederken yanlış alarmlardan kaçınabildiğini gösteren önemli bir araçtır. Başarılı bir modelin eğrisi, grafik üzerinde sağ üst köşeye yakın seyreder; yani hem yüksek kesinlik hem de yüksek duyarlılık değerlerine ulaşır. Bu eğrinin altında kalan alan ne kadar büyükse, modelin çeşitli eşik değerleri boyunca genel başarımının da o denli güçlü olduğu söylenebilir. Karışıklık matrisleri ise modellerin sınıflandırma doğruluğunu daha ayrıntılı bir düzeyde değerlendirmeye yardımcı olur. Bu matrisler; TP, FP, TN ve FN sayılarının grafiksel bir dağılımını sunarak, modelin hangi tür sınıflandırma hatalarına daha yatkın olduğunu ortaya koyar. Etkili bir sınıflayıcıdan, matrisin köşegenindeki değerlerin yüksek; köşegen dışı hata değerlerinin ise düşük olması beklenir. Bu sayede, modelin örneğin sağlıklı panelleri yanlışlıkla arızalı olarak işaretleyip işaretlemediği ya da gerçek sıcak noktaları gözden kaçırıp kaçırmadığı net şekilde görülebilir.


Eğitim süreci boyunca kaydedilen hata değerleri de modelin öğrenme etkinliği hakkında önemli ipuçları sunar. Epoch'lar boyunca kayıp değerlerinde gözlemlenen düzenli azalma, modelin eğitildikçe daha doğru tahminler yaptığını ve hedeflenen çıktılarına yaklaştığını göstermektedir. Bu grafikler, optimizasyon sürecinin ne kadar başarılı yönetildiğini anlamak açısından önemli bir referanstır. Ayrıca, performansın

genel bir özetini sunan metrikler, kesinlik, duyarlılık, mAP50 ve mAP50–95, model başarısını değerlendirmede kritik rol oynamaktadır. Yüksek kesinlik, modelin yaptığı pozitif sınıflandırmaların büyük ölçüde doğru olduğunu ve yanlış alarm olasılığının düşük kaldığını ifade ederken; yüksek duyarlılık, mevcut tüm arızaların büyük kısmının başarıyla tespit edildiğini ve gözden kaçırılma oranının düşük olduğunu gösterir. mAP50 ve mAP50–95 değerleri ise sadece doğru sınıflandırmayı değil, aynı zamanda tespit edilen nesnelerin konumlandırma doğruluğunu da değerlendiren bütüncül başarı ölçütleridir. Bu metriklerde elde edilen yüksek değerler, modelin genel nesne tespiti performansının tatmin edici olduğunu açıkça ortaya koyar.



(a)



(b)



(c)


Şekil 4.6. YOLOv9 t modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.6(a) kesinlik-duyarlılık eğrisi, YOLOv9 t modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.6(b), modelin 164 sıcak noktayı doğru tespit ederken 68 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 32 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.6(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.7. YOLOv9 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.7(a) kesinlik-duyarlılık eğrisi, YOLOv9 s modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.7(b), modelin 168 sıcak noktayı doğru tespit ederken 36 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 28 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.7(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.8. YOLOv9 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.8(a) kesinlik-duyarlılık eğrisi, YOLOv9 m modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.8(b), modelin 172 sıcak noktayı doğru tespit ederken 24 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 38 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.8(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)


(b)



(c)


Şekil 4.9. YOLOv9 c modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.9(a) kesinlik-duyarlılık eğrisi, YOLOv9 c modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.9(b), modelin 172 sıcak noktayı doğru tespit ederken 24 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 44 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.9(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.10. YOLOv9 c modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.10(a) kesinlik-duyarlılık eğrisi, YOLOv9 e modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.10(b), modelin 170 sıcak noktayı doğru tespit ederken 26 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 55 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.10(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)


(b)



(c)


Şekil 4.11. YOLOv10 n modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.11(a) kesinlik-duyarlılık eğrisi, YOLOv10 n modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.11(b), modelin 158 sıcak noktayı doğru tespit ederken 38 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 32 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.11(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)



(b)



(c)


Şekil 4.12. YOLOv10 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.12(a) kesinlik-duyarlılık eğrisi, YOLOv10 s modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.12(b), modelin 160 sıcak noktayı doğru tespit ederken 36 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 41 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.12(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.13. YOLOv10 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.13(a) kesinlik-duyarlılık eğrisi, YOLOv10 m modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.13(b), modelin 168 sıcak noktayı doğru tespit ederken 28 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 43 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.13(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.14. YOLOv10 b modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.14(a) kesinlik-duyarlılık eğrisi, YOLOv10 b modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.14(b), modelin 166 sıcak noktayı doğru tespit ederken 30 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 56 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.14(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.15. YOLOv10 l modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.15(a) kesinlik-duyarlılık eğrisi, YOLOv10 1 modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.15(b), modelin 159 sıcak noktayı doğru tespit ederken 37 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 38 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.15(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.16. YOLOv10 x modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.16(a) kesinlik-duyarlılık eğrisi, YOLOv10 x modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.16(b), modelin 158 sıcak noktayı doğru tespit ederken 38 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 45 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.16(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)

(b)




(c)

Şekil 4.17. YOLOv11 n modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi,


(c) eğitim sonuç grafikleri

Şekil 4.17(a) kesinlik-duyarlılık eğrisi, YOLOv11 n modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.17(b), modelin 168 sıcak noktayı doğru tespit ederken 28 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 55 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.17(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.18. YOLOv11 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.18(a) kesinlik-duyarlılık eğrisi, YOLOv11 s modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.18(b), modelin 168 sıcak noktayı doğru tespit ederken 28 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 37 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.18(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.19. YOLOv11 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.19(a) kesinlik-duyarlılık eğrisi, YOLOv11 m modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.19(b), modelin 170 sıcak noktayı doğru tespit ederken 26 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 46 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.19(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)



(b)



(c)



Şekil 4.20. YOLOv11 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.20(a) kesinlik-duyarlılık eğrisi, YOLOv11 l modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.20(b), modelin 167 sıcak noktayı doğru tespit ederken 29 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 44 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.20(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.21. YOLOv11 x modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.21(a) kesinlik-duyarlılık eğrisi, YOLOv11 x modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.21(b), modelin 162 sıcak noktayı doğru tespit ederken 34 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 48 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.21(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.




Şekil 4.22. YOLOv12 n modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.22(a) kesinlik-duyarlılık eğrisi, YOLOv12 n modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.22(b), modelin 168 sıcak noktayı doğru tespit ederken 28 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 65 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.22(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)


(b)



(c)


Şekil 4.23. YOLOv12 s modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.23(a) kesinlik-duyarlılık eğrisi, YOLOv12 s modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.23(b), modelin 169 sıcak noktayı doğru tespit ederken 27 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 73 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.23(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)


(b)



(c)


Şekil 4.24. YOLOv12 m modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.24(a) kesinlik-duyarlılık eğrisi, YOLOv12 m modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.24(b), modelin 167 sıcak noktayı doğru tespit ederken 29 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 54 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.24(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)


(b)



(c)


Şekil 4.25. YOLOv12 l modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.25(a) kesinlik-duyarlılık eğrisi, YOLOv12 1 modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.25(b), modelin 168 sıcak noktayı doğru tespit ederken 28 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 52 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.25(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.



(a)

(b)



(c)

Şekil 4.26. YOLOv12 x modelinin; (a) kesinlik-duyarlılık eğrisi, (b) karışıklık matrisi, (c) eğitim sonuç grafikleri

Şekil 4.26(a) kesinlik-duyarlılık eğrisi, YOLOv12 x modelinin farklı güven eşiklerinde hem kesinlik hem de duyarlılık arasındaki performans dengesini göstermektedir. Şekil 4.26(b), modelin 162 sıcak noktayı doğru tespit ederken 34 tanesini kaçırdığını ve sağlıklı panellerle ilgili olarak 52 yanlış alarm ürettiğini sayısal olarak özetleyerek sınıflandırma doğruluğunu ortaya koymaktadır. Şekil 4.26(c), epochlar boyunca hata değerlerinin düzenli olarak azalması ve mAP gibi metriklerin yükselmesiyle modelin eğitim sürecinde başarılı bir şekilde öğrendiğini ve genelleme yeteneği kazandığını doğrulamaktadır.

YOLOv9 modelinin eğitim sürecinde doğruluk oranı istikrarlı şekilde artarken, kayıp fonksiyonu belirgin biçimde azalma göstermiştir. Ancak eğitim süresi bakımından daha yavaş yakınsama eğilimi gösterdiği, özellikle büyük modellerde daha geç stabilizasyon sağladığı gözlemlenmiştir. YOLOv9 ailesinin beş farklı sürümü (t, s, m, c ve e) performans metrikleri açısından artan bir doğruluk ve düşen bir hız dizisi sergilemektedir. “t” ve “s” sürümleri, düşük parametre sayısı ve hızlı çıkarım süresi avantajı sunarken, ortalama bir mAP50-95 değeri ile sınırlı kalmıştır. “m” sürümünde, parametre sayısındaki artışa paralel olarak kesinlik ve duyarlılık değerlerinde kayda değer yükselişler gözlemlenmiştir ve mAP50-95 değerindeki yüksek skor dikkat çekmektedir. “c” ve “e” sürümleri ise, daha büyük katman yapısına sahip olmasına rağmen çıkarım hızı pratik sınırlar içinde kalarak nispeten “m” sürümünün gerisinde kalmıştır.

YOLOv10 modeli, klasik NMS yönteminde karşılaşılan işlem gecikmelerini ortadan kaldırmak amacıyla geliştirilmiş tutarlı çift atamalar stratejisini kullanarak çıkarım sürecinde önemli ölçüde hız artışı sağlamaktadır. YOLOv10 modelinin “b” ve “l” sürümlerinde eğitim tutarlılığı artan başlık eşleştirme mantığı sayesinde kesinlik ve duyarlılık dengesi iyileşir. Özellikle “x” sürümü, diğer modellere kıyasla en yüksek mAP50-95 değerini elde ederken çıkarım süresini makul seviyede tutar. Buna karşılık, iki aşamalı atama yapısı eğitim süreçlerini karmaşıktırmakta ve orta ölçekli “m” ile “b” versiyonlarının mutlak doğruluk performansı, YOLOv9 m ve YOLOv11 s’nin gerisinde kalabilmektedir. Bu yüzden YOLOv10, yüksek hız gerektiren otonom sistemler için ideal olsa da en yüksek hassasiyet talep eden saha tespiti uygulamalarında tercih edilen bir seçenek olmayabilir.

YOLOv11 ailesindeki n, s, m, l ve x versiyonlarının performans grafikleri (Şekil 4.16–4.20) incelendiğinde, önceki sürümlerin üzerine eklenen optimizasyon katmanlarının, özellikle orta ve büyük ölçekli modellerde tutarlı kazanımlar sunduğu görülmektedir. “n” sürümünde temel görsel tespit yeteneği korunurken, eğitim

esnasındaki hız avantajı, temel uygulamalar için yeterli doğruluk seviyesini karşılamaktadır. “s” sürümü, “n” sürümüne kıyasla %5,898’lik duyarlılık artışı ile arka plan karmaşıklığına karşı daha dayanıklı hale gelmiştir. “s” sürümü, tüm aileler arasında en yüksek mAP50 (~0.8638) ve F1 skoru (~0.8262) değerlerine ulaşmış, yanlış pozitif oranını (FP=37) en aza indirmiştir. Bu, YOLOv11 s’nin düşük bakım maliyetiyle güvenilir tespit yapmasını sağlar. Orta ölçekli “m” versiyonu, kesinlik-duyarlılık eğrisinde en iyi dengeyi yakalamış; mAP50-95 skorundaki artış, modelin çeşitli koşullarda genellenabilirliğini güçlendirmiştir. “l” ve “x” versiyonlarındaki ek dikkat katmanları, özellikle düşük kontrastlı ve küçük hedeflerde belirgin performans kazanımları ortaya koyar. Ancak dikkat modüllerinin ek bellek yükü, sınır cihazlarında ek donanım gereksinimleri doğurabilir. YOLOv11, duyarlılık açısından en tutarlı sonuçları sunmuş ve en yüksek F1 skorlarından birine ulaşarak hem doğru sınıflandırma oranı hem de pozitif örnekleri kaçırmama açısından öne çıkmıştır.

En yeni mimari seti olan YOLOv12’nin n, s, m, l ve x sürümleri (Şekil 4.22–4.26), önceki nesillere kıyasla hem mimari hem de eğitim stratejisi bakımından önemli revizyonlar içermektedir. YOLOv12, A2 modülü ve R-ELAN bloklarıyla klasik CNN yaklaşımını tamamen dikkat merkezli bir mimariye dönüştürür. Önceki nesillerin, performans metriklerinin gerisinde kalmayan sonuçlar veren YOLOv12, CNN ihtiyacını ortadan kaldırmaktadır. Bununla beraber FlashAttention optimizasyonları sayesinde çıkarım süresine yalnızca minimal bir yük getirir. “s” ve “m” modellerindeki kademeli performans iyileştirmeleri, dikkat tabanlı işlemlerin gerçek dünya görüntülerindeki karmaşıklığı daha etkin ele alabileceğini gösterir. “l” varyantı, en yüksek kesinlik değerini (0.84498) sergilerken, işlem verimliliğini korumak için gerektirdiği GPU desteği, saha cihazlarında erişilebilirlik açısından bir sınırlama yaratır. Hafif varyantlar gömülü uygulamalarda tercih edilebilirken, dikkat merkezli büyük modeller, yüksek donanım kapasitesine sahip platformlarda maksimum doğruluk sağlar.

Bu çalışmanın bazı sınırlılıkları da göz önünde bulundurulmalıdır. Öncelikle, analiz yalnızca tek bir FV enerji santralinden elde edilen verilerle yürütülmüş olup, bu durum geliştirilen modellerin farklı iklim koşullarına veya coğrafi bölgelere genellenebilirliğini sınırlandırmaktadır. Çalışmada yalnızca sıcak nokta arızaları üzerinde durulmuş; FV panellerde sıklıkla karşılaşılan diyot arızası, mikro çatlaklar veya delaminasyon gibi diğer önemli kusur türleri kapsam dışında bırakılmıştır. Öte yandan, termal görüntüleme ile yapılan tespitlerin doğruluğu; çekim sırasında mevcut olan hava koşulları (örneğin; bulutluluk, ortam sıcaklığı ve rüzgâr hızı) tarafından etkilenebilir niteliktedir. Bu çevresel

değişkenlerin model performansı üzerindeki etkileri ise bu çalışma kapsamında ayrıntılı biçimde ele alınmamıştır. Ayrıca, YOLOv12 gibi daha yeni nesil modellerin yüksek performanslı donanım (özellikle GPU) gereksinimleri, bu çözümlerin donanım kapasitesi sınırlı olan taşınabilir saha sistemlerinde yaygın kullanımını kısıtlayabilir. Gelecekte gerçekleştirilecek araştırmalarda; farklı çevresel koşulları temsil eden daha çeşitli veri setlerinin kullanılması, çeşitli panel arızalarının birlikte değerlendirilmesi ve çevresel faktörlerin modellemeye entegrasyonu, geliştirilen sistemlerin pratik uygulanabilirliğini ve sektörel güvenilirliğini önemli ölçüde artıracaktır.



5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, FV enerji santrallerinde karşılaşılan ve hem enerji kaybına hem de güvenlik açıklarına neden olabilen sıcak nokta anomalilerinin tespiti amacıyla, derin öğrenme tabanlı bir nesne tespiti yöntemi olan YOLO algoritmasının dört farklı versiyonu (YOLOv9, YOLOv10, YOLOv11 ve YOLOv12) karşılaştırmalı olarak değerlendirilmiştir. Yapılan analizler sonucunda, özellikle YOLOv9 m ve YOLOv11 s modellerinin sıcak nokta tespiti görevinde diğer modellere kıyasla daha istikrarlı ve yüksek doğruluklu sonuçlar verdiği gözlemlenmiştir. Bu bulgular, söz konusu iki modelin, FV santrallerde bakım ve denetim süreçlerinde pratik olarak kullanılabileceğine dair güçlü bir gösterge sunmaktadır.

Model başarımı, kesinlik, duyarlılık, F1 skoru, mAP50 ve mAP50–95 gibi çeşitli performans metrikleri üzerinden çok yönlü olarak ele alınmıştır. YOLOv11 s modeli, özellikle yüksek duyarlılık oranı ve hızlı tahmin kabiliyeti sayesinde gerçek zamanlı uygulamalara uygun bir yapı sergilemiştir. Donanımsal açıdan daha az kaynak gerektirmesi ise modelin saha koşullarında uygulanabilirliğini artıran önemli bir avantaj olarak öne çıkmaktadır. Öte yandan YOLOv9 m modeli, GELAN mimarisinin sağladığı dengeli öğrenme yeteneği sayesinde, arka plan çeşitliliğinin fazla olduğu senaryolarda dahi tutarlı ve güvenilir sonuçlar üretmeyi başarmıştır. Bu durum, kullanılan mimarinin görev özelinde doğru belirlenmesinin ne kadar kritik olduğunu da ortaya koymaktadır.

Tez kapsamında geliştirilen yöntem, geleneksel termal ölçüm ya da görsel inceleme gibi manuel yaklaşımlara kıyasla daha hızlı, otomatik ve hata payı düşük bir çözüm önerisi sunmaktadır. Bu yaklaşım sayesinde, bakım operasyonları zaman ve maliyet açısından optimize edilmekte; aynı zamanda insan hatasından kaynaklı riskler azaltılarak sistematik, veri odaklı bir denetim süreci sağlanmaktadır. Eğitim sırasında uygulanan veri artırma teknikleri ve negatif örnekleme stratejileri, modelin farklı koşullara karşı genelleme kabiliyetini pekiştirmiştir. Bu yönleriyle sunulan yöntem, benzer projelerde referans alınabilecek nitelikte bir örnek teşkil etmektedir.

Geliştirilen metodoloji; veri toplama, etiketleme, model eğitimi, test aşaması ve elde edilen sonuçların coğrafi olarak haritalandırılması gibi adımları içeren modüler ve esnek bir yapı sunmaktadır. Bu yapı yalnızca sıcak nokta tespitine değil, aynı zamanda panellerde karşılaşılan diğer yaygın arıza türlerinin (tozlanma, diyot arızası, gölgelenme vb.) belirlenmesine yönelik uygulamalara da kolayca uyarlanabilir durumdadır. Böylece,

yöntemin hem bilimsel hem de endüstriyel düzeyde geniş bir uygulama potansiyeline sahip olduğu anlaşılmaktadır.

Bu tez çalışması hem kuramsal katkılar hem de pratik uygulamalar açısından anlamlı çıktılar üretmiştir. Geniş ölçekli FV enerji santrallerinde görüntü işleme destekli yapay zekâ uygulamalarının yaygınlaştırılması, tesislerin dijitalleşme düzeyini artıracak ve daha otonom bir izleme altyapısının önünü açacaktır. Gelecek çalışmalarda, farklı coğrafyalardan elde edilmiş daha büyük veri kümeleri ile model genelleme yeteneklerinin artırılması hedeflenmeli; aynı zamanda çoklu arıza türlerini eş zamanlı olarak tespit edebilen modellerin geliştirilmesiyle, FV sistemlerin verimlilik ve güvenilirlik düzeylerinin daha da üst seviyelere taşınması mümkün olacaktır.



KAYNAKLAR

- Açıkgöz, H., Korkmaz, D., Dandıl, Ç. (2022). Classification of hotspots in photovoltaic modules with deep learning methods. *Turkish Journal of Science and Technology*, 17(2), 211-221. <https://dx.doi.org/10.55525/tjst.1158854>.
- Aghaei, M., Fairbrother, A., Gok, A., Ahmad, S., Kazim, S., Lobato, K., Kettle, J. (2022). Review of degradation and failure phenomena in photovoltaic modules. *Renewable and Sustainable Energy Reviews*, 159, 112160. <https://dx.doi.org/10.1016/j.rser.2022.112160>.
- Ahmed, W., Sheikh, J. A., Farjana, S. H., Mahmud, M. A. P. (2021). Defects impact on PV system GHG mitigation potential and climate change. *Sustainability*, 13(14), 7793. <https://dx.doi.org/10.3390/su13147793>.
- Al-Ezzi, A. S., Ansari, M. N. M. (2022). Photovoltaic solar cells: a review. *Applied System Innovation*, 5(4), 67. <https://dx.doi.org/10.3390/asi5040067>.
- Al Mahdi, H., Leahy, P. G., Alghoul, M., Morrison, A. P. (2024). A review of photovoltaic module failure and degradation mechanisms: Causes and detection techniques. *Solar*, 4(1), 43-82. <https://dx.doi.org/10.3390/solar4010003>.
- Ali, M. U., Saleem, S., Masood, H., Kallu, K. D., Masud, M., Alvi, M. J., Zafar, A. (2022). Early hotspot detection in photovoltaic modules using color image descriptors: An infrared thermography study. *International Journal of Energy Research*, 46(2), 774-785. <https://dx.doi.org/10.1002/er.7201>.
- Balachandran, G. B., Devisridhivyadharshini, M., Ramachandran, M. E., Santhiya, R. (2024). Comparative investigation of imaging techniques, pre-processing and visual fault diagnosis using artificial intelligence models for solar photovoltaic system—A comprehensive review. *Measurement*, 232, 114683. <https://dx.doi.org/10.1016/j.measurement.2024.114683>.
- Banu, N., ve Fazal, S. (2025). Climate change, livelihood crisis and resilience: an introduction. N. Banu, S. Fazal (Ed.), *Livelihoods and Well-Being in the era of Climate Change: Risk to Resilience across India içinde* (3-18 s). Cham: Springer Nature Switzerland. https://dx.doi.org/10.1007/978-3-031-81132-6_1.
- Belhachat, F., Larbes, C., Bennia, R. (2024). Recent advances in fault detection techniques for photovoltaic systems: An overview, classification and performance evaluation. *Optik*, 171797. <https://dx.doi.org/10.1016/j.ijleo.2024.171797>.
- Berghold, J., Roericht, M., Böttcher, A., Wendlandt, S., Hanusch, M., Koch, S., Grunow, P., Stegemann, B. (2012). Electrochemical corrosion within solar panels. *Proceedings of the 27th European Photovoltaic Congress and Exhibition* (24-28 s). Frankfurt.

- Bıyık, E., Bilir, L., Bulunuz, O., Sarı, E., Yıldırım, N. (2023). *Fotovoltaik Güç Sistemleri Nitelikli Teknik İş Gücü (Seviye 5+) İçin Mesleki Temel Konular El Kitabı*. T.C. Çalışma ve Sosyal Güvenlik Bakanlığı.
- Bochkovskiy, A., Wang, C.-Y., Liao, H.-Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934. <https://dx.doi.org/10.48550/arXiv.2004.10934>.
- Chang, M., Chen, C., Hsueh, C. H., Hsieh, W. J., Yen, E., Ho, K. L., Chuang, H. P., Lee, C. Y., Chen, H. (2015). The reliability investigation of PV junction box based on 1GW worldwide field database. *IEEE 42nd Photovoltaic Specialist Conference (PVSC) (pp. 1-4)*. <https://dx.doi.org/10.1109/PVSC.2015.7356130>
- Chaudhary, A., Chaturvedi, D. (2018). Analyzing defects of solar panels under natural atmospheric conditions with thermal image processing. *International Journal of Image, Graphics and Signal Processing*, 10, 10-21. <https://dx.doi.org/10.5815/ijigsp.2018.06.02>.
- Dada, M., ve Popoola, P. (2023). Recent advances in solar photovoltaic materials and systems for energy storage applications: a review. *Beni-Suef University Journal of Basic and Applied Sciences*, 12(1), 1-15. <https://dx.doi.org/10.1186/s43088-023-00405-5>.
- Du, S., Zhang, B., Zhang, P., Xiang, P., Xue, H. (2021). FA-YOLO: An improved YOLO model for infrared occlusion object detection under confusing background. *Wireless Communications and Mobile Computing*, 2021(1), 1896029. <https://dx.doi.org/10.1155/2021/1896029>.
- Duan, R., Ma, Z. (2024). A method for detecting photovoltaic panel faults using a drone equipped with a multispectral camera. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, X-1-2024, 59-65. <https://dx.doi.org/10.5194/isprs-annals-X-1-2024-59-2024>.
- Duranay, Z. B. (2023). Fault detection in solar energy systems: A deep learning approach. *Electronics*, 12(21), 4397. <https://dx.doi.org/10.3390/electronics12214397>.
- Gallagher, J. E., Oughton, E. J. (2025). Surveying You Only Look Once (YOLO) multispectral object detection advancements, applications, and challenges. *IEEE Access*, 13, 7366-7395. <https://dx.doi.org/10.1109/ACCESS.2025.3526458>.
- Ghanbari, T. (2017). Hot spot detection and prevention using a simple method in photovoltaic panels. *IET Generation, Transmission & Distribution*, 11(4), 883-890. <https://dx.doi.org/10.1049/iet-gtd.2016.0794>.
- Goudelis, G., Lazaridis, P. I., Dhimish, M. (2022). A review of models for photovoltaic crack and hotspot prediction. *Energies*, 15(12), 4303. <https://dx.doi.org/10.3390/en15124303>.
- Gurras, A., Gergidis, L., Mytafides, C., Tzounis, L., Paipetis, A. S. (2021). Automated detection-classification of defects on photo-voltaic modules assisted by thermal

- drone inspection. *MATEC Web of Conferences*, 349, 03015. <https://dx.doi.org/10.1051/mateconf/202134903015>.
- Güneş Enerjisi Potansiyeli Atlası (GEPA). (2022). Erişim adresi: <https://gepa.enerji.gov.tr/pages/45.aspx> (Son Erişim Tarihi: 10/05/2025).
- Han, T., Bao, M., He, T., Zhang, R., Feng, X., Huang, Y. (2025). LW-PV DETR: Lightweight model for photovoltaic panel surface defect detection. *Engineering Research Express*, 7(1), 015357. <https://dx.doi.org/10.1088/2631-8695/adb4be>.
- Hussain, M. (2024). YOLOv1 to v8: Unveiling each variant—a comprehensive review of YOLO. *IEEE Access*, 12, 42816-42833. <https://dx.doi.org/10.1109/ACCESS.2024.3378568>.
- Hwang, H. P.-C., Ku, C. C.-Y., Chan, J. C.-C. (2021). Detection of malfunctioning photovoltaic modules based on machine learning algorithms. *IEEE Access*, 9, 37210-37219. <https://dx.doi.org/10.1109/ACCESS.2021.3063461>.
- IEA, International Energy Agency. (2021). Turkey 2021 Energy Policy Review. Erişim adresi <https://www.iea.org/reports/turkey-2021> (Son Erişim Tarihi: 12/12/2024).
- IEA, International Energy Agency. (2023). CO₂ Emissions in 2022. Erişim adresi <https://www.iea.org/reports/co2-emissions-in-2022> (Son Erişim Tarihi: 12/12/2024).
- IEA. (2024a). *CO₂ Emissions in 2023 IEA Paris* Erişim adresi: <https://www.iea.org/reports/co2-emissions-in-2023> (Son Erişim Tarihi: 12/12/2024).
- IEA, International Energy Agency. (2024b). *Renewables 2024*. Erişim adresi <https://www.iea.org/reports/renewables-2024> (Son Erişim Tarihi: 12/12/2024).
- IEA, International Energy Agency. (2024c). Share of renewable electricity generation by technology, 2000-2030. Erişim adresi <https://www.iea.org/data-and-statistics/charts/share-of-renewable-electricity-generation-by-technology-2000-2030> (Son Erişim Tarihi: 12/12/2024).
- Iqbal, J., Al-Zahrani, A., Alharbi, S. A., Hashmi, A. (2019). Robotics inspired renewable energy developments: Prospective opportunities and challenges. *IEEE Access*, 7, 174898-174923. <https://dx.doi.org/10.1109/ACCESS.2019.2957013>.
- Islam, M. A., Hasanuzzaman, M., Rahim, N. A., Nahar, A., Hosenuzzaman, M. (2014). Global renewable energy-based electricity generation and smart grid system for energy security. *The Scientific World Journal*, 2014(1), 197136. <https://dx.doi.org/10.1155/2014/197136>.
- Jalal, M., Khalil, I. U., ul Haq, A. (2024). Deep Learning approaches for visual faults diagnosis of photovoltaic systems: State-of-the-art review. *Results in Engineering*, 102622. <https://dx.doi.org/10.1016/j.rineng.2024.102622>.

- Jegham, N., Koh, C. Y., Abdelatti, M., Hendawi, A. (2024). Evaluating the evolution of YOLO (You Only Look Once) models: A comprehensive benchmark study of YOLO11 and its predecessors. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2411.00201>.
- Jordan, D. C., Silverman, T. J., Wohlgemuth, J. H., Kurtz, S. R., VanSant, K. T. (2017). Photovoltaic failure and degradation modes. *Progress in Photovoltaics: Research and Applications*, 25(4), 318-326. <https://dx.doi.org/10.1002/pip.2866>.
- Kaaya, I., Koehl, M., Mehilli, A. P., de Cardona Mariano, S., Weiss, K. A. (2019). Modeling outdoor service lifetime prediction of PV modules: Effects of combined climatic stressors on PV module power degradation. *IEEE Journal of Photovoltaics*, 9(4), 1105-1112. <https://dx.doi.org/10.1109/JPHOTOV.2019.2916197>.
- Khanam, R., Hussain, M. (2024). YOLOv11: An overview of the key architectural enhancements. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2410.17725>
- Kim, D., Youn, J., Kim, C. (2016). Automatic photovoltaic panel area extraction from UAV thermal infrared images. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 34(6), 559-568. <https://dx.doi.org/10.7848/ksgpc.2016.34.6.559>.
- Kim, D., Youn, J., Kim, C. (2017). Automatic fault recognition of photovoltaic modules based on statistical analysis of UAV thermography. International Conference on Unmanned Aerial Vehicles in Geomatics, Bonn.
- Köntges, M., Kunze, I., Kajari-Schröder, S., Breitenmoser, X., Bjorneklett, B. (2010). Quantifying the risk of power loss in PV modules due to micro cracks. *25th European Photovoltaic Solar Energy Conference*, Valencia, Spain (pp. 3745-3752).
- Köntges, M., Kurtz, S., Packard, C., Jahn, U., Berger, K., Kato, K., Friesen, T., Liu, H., Van Iseghem, M., Friesen, G. (2014). Review of failures of photovoltaic modules. *International Energy Agency Photovoltaic Power Systems Programme*. 3.2 (pp. 1-132)
- Köntges, M., Oreski, G., Jahn, U., Herz, M., Hacke, P., Weiß, K.A. (2017). Assessment of photovoltaic module failures in the field. *International Energy Agency Photovoltaic Power Systems Programme*. <https://dx.doi.org/10.1016/j.rser.2022.112160>.
- Lamaka, A. A., Gutarau, A. V., Shcherbakou, N. G., Ivuts, P. V. (2023). Photospectral data obtaining with the unmanned aerial spectrometry vehicle. *Devices and Methods of Measurements*, 14(1), 7-17. <https://dx.doi.org/10.21122/2220-9506-2023-14-1-7-17>.
- Lamb, W. P., Asnes, D. E., Kupfer, J., Lickey, E., Bakken, J., Haskell, R. C., Saeta P. N., ve Yang, Q. (2022). Real-time anticipation and prevention of hot spots by monitoring the dynamic conductance of photovoltaic panels. *IEEE Journal of*

Photovoltaics, 12(4), 1051-1057. <https://dx.doi.org/10.1109/JPHOTOV.2022.3161420>.

- Li, G., Wang, F., Feng, F., ve Wei, B. (2022a). Hot spot detection of photovoltaic module based on distributed fiber Bragg grating sensor. *Sensors*, 22(13), 4951. <https://dx.doi.org/10.3390/s22134951>.
- Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L., Wei, X. (2022b). YOLOv6: A single-stage object detection framework for industrial applications. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2209.02976>.
- Lin, T.-Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Ramadan, D., Perona, P., Zitnick, C. L., Dollár, P. (2015). Microsoft COCO: Common Objects in Context. *arXiv*. <https://dx.doi.org/10.48550/arXiv.1405.0312>.
- Lofstad-Lie, V., Marstein, E. S., Simonsen, A., Skauli, T. (2022). Cost-effective flight strategy for aerial thermography inspection of photovoltaic power plants. *IEEE Journal of Photovoltaics*, 12(6), 1543-1549. <https://dx.doi.org/10.1109/PVSC43889.2021.9518710>.
- Mehedi, T. H., Gemechu, E., Kumar, A. (2022). Life cycle greenhouse gas emissions and energy footprints of utility-scale solar energy systems. *Applied Energy*, 314, 118918. <https://dx.doi.org/10.1016/j.apenergy.2022.118918>.
- MGM, T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü. (2025). Türkiye Global Güneş Radyasyonu Uzun Yıllar Ortalaması (2004-2021) Heliosat Model Ürünleri. Erişim adresi https://www.mgm.gov.tr/kurumici/radyasyon_iller.aspx?il=manisa (Son Erişim Tarihi: 20/04/2025).
- Miller, D. C., Deibert, S. L., Wohlgemuth, John. H. (2014). Trial-run of a junction-box attachment test for use in photovoltaic module qualification. *IEEE 40th Photovoltaic Specialist Conference (PVSC)* (ss. 2182-2187). <https://dx.doi.org/10.1109/PVSC.2014.6925357>.
- Mustafa, R. J., Gomaa, M. R., Al-Dhaifallah, M., Rezk, H. (2020). Environmental impacts on the performance of solar photovoltaic systems. *Sustainability*, 12(2), 608. <https://dx.doi.org/10.3390/su12020608>.
- Naeem, U., Chadda, K., Vahaji, S., Ahmad, J., Li, X., Asadi, E. (2025). Aerial imaging-based soiling detection system for solar photovoltaic panel cleanliness inspection. *Sensors*, 25(3), 738. <https://dx.doi.org/10.3390/s25030738>.
- Obaideen, K., Olabi, A. G., Al Swailmeen, Y., Shehata, N., Abdelkareem, M. A., Alami, A. H., Rodriguez, C., Sayed, E. T. (2023). Solar energy: Applications, trends analysis, bibliometric analysis and research contribution to sustainable development goals (SDGs). *Sustainability*, 15(2), 1418. <https://dx.doi.org/10.3390/su15021418>.

- Pan, W., Sun, X., Wang, Y., Cao, Y., Lang, Y., Qian, Y. (2024). Enhanced photovoltaic panel defect detection via adaptive complementary fusion in YOLO-ACF. *Scientific Reports*, 14(1), 26425. <https://dx.doi.org/10.1038/s41598-024-75772-9>.
- Pruthviraj, U., Kashyap, Y., Baxeavanaki, E., ve Kosmopoulos, P. (2023). Solar photovoltaic hotspot inspection using unmanned aerial vehicle thermal images at a solar field in South India. *Remote Sensing*, 15(7), 1914. <https://dx.doi.org/10.3390/rs15071914>.
- Redmon, J. (2021). Practical Computer Vision. *University of Washington*. <https://search.proquest.com/openview/18ec45fab2b28b0052cd8aef4c8414a8/1?pq-origsite=gscholar&cbl=18750&diss=y> (Son Erişim Tarihi: 23/05/2025).
- Redmon, J., Divvala, S.K., Girshick, R.B., ve Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788.
- Redmon, J., ve Farhadi, A. (2016). YOLO9000: Better, Faster, Stronger. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 6517-6525. <https://dx.doi.org/10.1109/CVPR.2017.690>.
- Redmon, J., ve Farhadi, A. (2018). YOLOv3: An incremental improvement. *ArXiv*, abs/1804.02767. <https://dx.doi.org/10.48550/arXiv.1804.02767>
- Santhakumari, M., ve Sagar, N. (2019). A review of the environmental factors degrading the performance of silicon wafer-based photovoltaic modules: Failure detection methods and essential mitigation techniques. *Renewable and Sustainable Energy Reviews*, 110, 83-100. <https://dx.doi.org/10.1016/j.rser.2019.04.024>.
- Shaker, L. M., Al-Amiery, A. A., Hanoon, M. M., Al-Azzawi, W. K., Kadhum, A. A. H. (2024). Examining the influence of thermal effects on solar cells: a comprehensive review. *Sustainable Energy Research*, 11(1), 6. <https://dx.doi.org/10.1186/s40807-024-00100-8>.
- Shin, W. G., Ko, S. W., Song, H. J., Ju, Y. C., Hwang, H. M., Kang, G. H. (2018). Origin of bypass diode fault in c-Si photovoltaic modules: Leakage current under high surrounding temperature. *Energies*, 11(9), 2416. <https://dx.doi.org/10.3390/en11092416>.
- Soukharev, B. (2025). Global warming and mass migration: Climate change and its impact on migration to the north. *Springer Nature Switzerland*. https://dx.doi.org/10.1007/978-3-031-74454-9_1.
- Sun, T., Xing, H., Cao, S., Zhang, Y., Fan, S., Liu, P. (2022). A novel detection method for hot spots of photovoltaic (PV) panels using improved anchors and prediction heads of YOLOv5 network. *Energy Reports*, 8, 1219-1229. <https://dx.doi.org/10.1016/j.egy.2022.08.130>.
- Tian, Y., Ye, Q., Doermann, D. (2025). YOLOv12: Attention-centric real-time object detectors. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2502.12524>.

- Ultralytics. 2024a. (2024). *Ultralytics YOLO11*. Erişim adresi: <https://docs.ultralytics.com/modes> (Son Erişim Tarihi: 23/05/2025).
- Ultralytics. (2024b). *YOLO11 vs YOLOv10: Detailed Technical Comparison*. Erişim adresi: <https://docs.ultralytics.com/compare/yolo11-vs-yolov10> (Son Erişim Tarihi: 23/05/2025).
- Vaas, T. S., Pieters, B. E., Gerber, A., Rau, U. (2023). Thermal stimulation of reverse breakdown in CIGS solar cells. *IEEE Journal of Photovoltaics*, 13(3), 398-403. <https://dx.doi.org/10.1109/JPHOTOV.2023.3240680>.
- Vieira, R. G., de Araújo, F. M. U., Dhimish, M., Guerra, M. I. S. (2020). A comprehensive review on bypass diode application on photovoltaic modules. *Energies*, 13(10), 2472. <https://dx.doi.org/10.3390/en13102472>.
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., Ding, G. (2024a). YOLOv10: Real-time end-to-end object detection. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2405.14458>.
- Wang, C.-Y., Bochkovskiy, A., Liao, H.-Y. M. (2023). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2207.02696>.
- Wang, C.-Y., Yeh, I.-H., Liao, H.-Y. M. (2024b). YOLOv9: Learning what you want to learn using programmable gradient information. *arXiv*. <https://dx.doi.org/10.48550/arXiv.2402.13616>.
- Wendt, J., Träger, M., Mette, M., Pfennig, A., Jaeckel, B. (2009). The link between mechanical stress induced by soldering and micro damages in silicon solar cells. *24th European Photovoltaic Solar Energy Conference*, 3420-3423.
- Winston, D. P., Murugan, M. S., Elavarasan, R. M., Pugazhendhi, R., Singh, O. J., Murugesan, P., Gurudhachanamoorthy, M., Hossain, E. (2021). Solar PV's micro crack and hotspots detection technique using NN and SVM. *IEEE Access*, 9, 127259-127269. <https://dx.doi.org/10.1109/ACCESS.2021.3111904>.
- Wu, X., Hao, X. (2023). SK-FRCNN: A fault detection method for hot spots on photovoltaic panels. *IEEE Access*, 11, 121379-121386. <https://dx.doi.org/10.1109/ACCESS.2023.3328332>.
- Wu, Z., Hu, Y., Wen, J. X., Zhou, F., Ye, X. (2020). A review for solar panel fire accident prevention in large-scale PV applications. *IEEE Access*, 8, 132466-132480. <https://dx.doi.org/10.1109/ACCESS.2020.3010212>.
- Xie, H., Yuan, B., Hu, C., Gao, Y., Wang, F., Wang, C., Wang, Y., Chu, P. (2024). ST-YOLO: A defect detection method for photovoltaic modules based on infrared thermal imaging and machine vision technology. *PloS one*, 19(12), e0310742. <https://dx.doi.org/10.1371/journal.pone.0310742>.

- Yang, B., Zheng, R., Han, Y., Huang, J., Li, M., Shu, H., Su, S., Guo, Z. (2024). recent advances in fault diagnosis techniques for photovoltaic systems: A critical review. *Protection and Control of Modern Power Systems*, 9(3), 36-59. <https://dx.doi.org/10.23919/PCMP.2023.000583>.
- Yanılmaz, S., Türkoğlu, M., Aslan, M. (2024). Güneş enerjisi santrallerinde YOLO algoritmaları ile hotspot kusurlarının tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36(1), 121-132. <https://dx.doi.org/10.35234/fumbd.1318060>.
- YEGM, Yenilenebilir Enerji Genel Müdürlüğü. (2025). Türkiye Güneş Enerjisi Potansiyeli Atlası (GEPA). Erişim adresi: <https://gepa.enerji.gov.tr/pages/45.aspx> (Son Erişim Tarihi: 20/04/2025).
- Yin, W., Lingxin, S., Maohuan, L., Qianlai, S., Xiaosong, L. (2023). PV-YOLO: Lightweight YOLO for photovoltaic panel fault detection. *IEEE Access*, 11, 10966-10976. <http://dx.doi.org/10.1109/ACCESS.2023.3240894>.
- Zhang, W., Wang, G., Yao, G., Lu, C., Liu, Y. (2024a). Study on fault monitoring technology of photovoltaic panel based on thermal infrared and optical remote sensing. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 855-860. <https://dx.doi.org/10.5194/isprs-archives-XLVIII-1-2024-855-2024>.
- Zhang, L., Wu, X., Liu, Z., Yu, P., Yang, M. (2024b) ESD-YOLOv8: An efficient solar cell fault detection model based on YOLOv8. *IEEE Access*, 12, 138801-138815. <http://dx.doi.org/10.1109/ACCESS.2024.3466209>.
- Zhao, X., Zhao, Y., Hu, S., Wang, H., Zhang, Y., Wuyi, M. (2023). Progress in active infrared imaging for defect detection in the renewable and electronic industries. *Sensors*, 23, 8780. <https://dx.doi.org/10.3390/s23218780>.