

T.C.
BİNGÖL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TABANLI SEGMENTASYON YAKLAŞIMLARI
İLE GÜNEŞ PANELLERİNİN OTOMATİK VERİMLİLİK
TESPİTİ

YÜKSEK LİSANS TEZİ

SÜMEYYE YANILMAZ

YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI

TEZ DANIŞMANI
Doç. Dr. Muzaffer ASLAN

BİNGÖL-2024

**DERİN ÖĞRENME TABANLI SEGMENTASYON YAKLAŞIMLARI İLE
GÜNEŞ PANELLERİNİN OTOMATİK VERİMLİLİK TESPİTİ**

Doç. Dr. Muzaffer Aslan danışmanlığında, Sümeyye Yanılmaz tarafından hazırlanan bu çalışma 05/08/2024 tarihinde aşağıdaki jüri tarafından Yenilenebilir Enerji Sistemleri Anabilim Dalı'nda Yüksek Lisans Tezi olarak **oybirliği** ile kabul edilmiştir.

Başkan : Doç. Dr. Nuh ALPARSLAN *İmza* :
Üye : Doç. Dr. Muzaffer ASLAN *İmza* :
Üye : Doç. Dr. Muammer TÜRKOĞLU *İmza* :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulunun// tarih ve/
nolu kararı ile onaylanmıştır.

Prof. Dr. Zafer ŞİAR
Enstitü Müdürü

ÖNSÖZ

Tez çalışmaları süresince yardımlarını ve engin bilgi birikimini esirgemeyen, çalışmaların tamamlanabilmesi için gerekli desteği veren değerli hocalarım Doç. Dr. Muzaffer ASLAN ve Doç. Dr. Muammer TÜRKOĞLU'na teşekkür ederim.

Son olarak bende büyük emekleri olan dualarını esirgemeyen, hayatımın her döneminde olduğu gibi yüksek lisans eğitim sürecinde göstermiş oldukları sabır, destek ve fedakarlıktan kaçınmayan sevgili anne ve babama en içten teşekkürlerimi sunarım.

Sümeyye YANILMAZ

Bingöl 2024

İÇİNDEKİLER

ÖNSÖZ.....	i
İÇİNDEKİLER.....	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	iv
ŞEKİLLER LİSTESİ.....	vi
TABLolar LİSTESİ.....	viii
ÖZET.....	ix
ABSTRACT.....	x
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ.....	8
3. FOTOVOLTAİK SİSTEMLER.....	13
3.1. Fotovoltaik Sistemler Arıza Çeşitleri	13
3.2. Fotovoltaik Sistemlerin Hücre Yapısı ve Çalışma Prensibi	14
3.2.1. Fotovoltaik Sistemlerin Hücre Yapısı.....	14
3.2.2. Fotovoltaik Sistemlerin Çalışma Prensibi.....	16
3.3. Fotovoltaik Panel Yapısı.....	18
3.4. Fotovoltaik Sistemlerin Verimini Etkileyen Arıza Çeşitleri.....	19
3.4.1. Hotspot Arızası.....	19
3.4.2. Bypass Diyot Arızası.....	20
3.5. Termografi Yöntemi.....	23
4. DERİN ÖĞRENME TABANLI SEGMENTASYON YÖNTEMLERİ.....	25
4.1. Bölgesel Tabanlı Segmentasyon Modelleri.....	29
4.1.1. YOLO Algoritması.....	29
4.1.2. YOLOv5 Algoritması.....	31
4.1.3. YOLOv6 Algoritması.....	33
4.1.4. YOLOv7 Algoritması.....	34
4.1.5. YOLOv8 Algoritması.....	35
4.2. Piksel Tabanlı Segmentasyon Modeli.....	37
4.2.1. U-Net.....	37

5. VERİ SETİ.....	39
5.1. Veri Setlerinin Analiz Edilmesi.....	39
5.2. Veri Setlerinin Etiketlenmesi.....	42
6. BULGULAR VE TARTIŞMA.....	44
6.1. Hotspot Hata Tespiti.....	44
6.2. Bypass Diyot Hata Tespiti.....	50
7. SONUÇLAR VE ÖNERİLER.....	55
KAYNAKLAR.....	57

SİMGELER VE KISALTMALAR LİSTESİ

IEA	: Uluslararası Enerji Ajansı
GEPA	: Güneş Enerjisi Potansiyeli Atlası
REN21	: Renewable Energy Policy Network For The 21st Century
YOLO	: You Only Look Once
PV	: Fotovoltaik
Hotspot	: Sıcak Nokta
İHA	: İnsansız Hava Aracı
BBox	: Bounding Box
SSD	: Single Shot Detection
FPS	: Frames Per Second
nBayes	: Naive Bayes
k-NN	: k-en Yakın Komşu Sınıflandırması
OPC	: Gerçek Dünya Çalışma Koşulları
STC	: Standart Test Koşulları
CNN	: Evrişimli Sinir Ağları
RNN	: Tekrarlayan Sinir Ağları
LSTM	: Uzun-Kısa Süreli Hafıza Ağları
RBM	: Sınırlı Boltzmann Makineleri
DBN	: Derin İnanç Ağları
AE	: Derin Oto-Kodlayıcı
RELU	: Düzeltilmiş Doğrusal Birim
IoU	: Intersection Over Union
CSPDarknet	: Cross Stage Partial Darknet
ESA	: Efficient Spatial Attention
PANet	: Path Aggregation Network
OAK	: OpenCV AI Kit
ELAN	: European Language Resources Association
MPCnv	: Max Pooling Convolution

PAN	: Path Aggregation Network
FPN	: Feature Pyramid Network
CSP	: Cross Stage Partial
SGD	: Stochastic Gradient Descent
AUC	: Area Under the Curve
AR-GE	: Arařtırma- Geliřtirme
IR	: Kızılötesi
mAP	: Mean Average Precision
Gt	: Gigaton
GW	: Gigawatt
kWp	: Kilowatt- peak
Vmpp	: Maksimum Güç Voltajı
Ipp	: Maksimum Güç Akımı
°F	: Fahrenheit
W	: Watt
mm	: milimetre
K	: Kelvin
°C	: Celsius
Hz	: Hertz
µm	: Mikrometre
CO ₂	: Karbondioksit
Si	: Silisyum
CdTe	: Kadmiyum tellür
GaAs	: Galyum arsenit
CIGS	: Bakır indiyum galyum selenit
EVA	: Etilen vinil asetat
PVF	: Polyvinyl Fluoride Film

ŞEKİLLER LİSTESİ

Şekil 1.1.	Türkiye Güneş Enerji Potansiyeli Atlası (GEPA).....	2
Şekil 1.2.	Türkiye global radyasyon değerleri ve güneşlenme süreleri.....	3
Şekil 3.1.	Yarı iletken malzemelerde difüzyon ve n-tipi ile p-tipi yarı iletkenlerin birleşim bölgesinde oluşan geçiş bölgesini gösteren diyagramlar. (a) Diyagramı, n-tipi ve p-tipi yarı iletkenler birleşmeden önceki durumu gösterirken, (b) diyagramı, birleşim sonrası oluşan yapısal elektrik alanı ve geçiş bölgesini göstermektedir.....	15
Şekil 3.2.	Fotovoltaik sistemlerin çalışma prensibi.....	16
Şekil 3.3.	Fotovoltaik hücreden, modül, panel ve dizi oluşumu.....	17
Şekil 3.4.	Fotovoltaik modül yapısı.....	18
Şekil 3.5.	Hotspot arızası termal kamera görüntüsü.....	20
Şekil 3.6.	Tek gölgeli hücreli PV modül.....	21
Şekil 3.7.	Bypass diyot arızası termal kamera görüntüsü.....	22
Şekil 3.8.	Termal kamera ile temassız sıcaklık ölçümü.....	24
Şekil 4.1.	CNN mimarisini genel gösterimi.....	26
Şekil 4.2.	Evrişim işlemi ile ilgili örnek bir uygulama.....	27
Şekil 4.3.	Havuzlama işlemi ile ilgili örnek bir gösterimi.....	28
Şekil 4.4.	YOLO nesne tespit sistemi.....	30
Şekil 4.5.	YOLOv5 mimari model.....	32
Şekil 4.6.	YOLOv6 mimari model.....	34
Şekil 4.7.	YOLOv7 mimari model.....	35
Şekil 4.8.	YOLOv8 mimari model.....	36
Şekil 4.9.	U-Net mimarisi.....	37
Şekil 5.1.	DJI Mavic 2 Enterprise Dual termal kameralı drone.....	40
Şekil 5.2.	Veri setindeki örnek görüntüler.....	41
Şekil 5.3.	Hotspot arızası MakeSense Etiketlenmesi.....	43
Şekil 5.4.	Bypass diyot arızası MakeSense Etiketlenmesi.....	43
Şekil 6.1.	Yapılan çalışmanın genel akış diyagramı.....	44

Şekil 6.2.	Önerilen modelin özgüllük-duyarlılık eğrisi.....	46
Şekil 6.3.	YOLO modellerinin görsel tahmin sonuları.....	48
Şekil 6.4.	YOLOv8 modelinin eğitim/kayıp grafikleri.....	49
Şekil 6.5.	U-Net-V2 modelinin karışıklık matrisi ve eğitim/doğrulama grafikleri.....	53
Şekil 6.6.	Önerilen U-Net tabanlı modellerin görsel sonuçları.....	54

TABLULAR LİSTESİ

Tablo 6.1.	YOLO modellerinin performansları (%)	46
Tablo 6.2.	U-Net modelleri	51
Tablo 6.3.	Geliştirilen U-Net modellerinin performans sonuçları	52

DERİN ÖĞRENME TABANLI SEGMENTASYON YAKLAŞIMLARI İLE GÜNEŞ PANELLERİNİN OTOMATİK VERİMLİLİK TESPİTİ

ÖZET

Dünyada enerji üretimi ve tüketimi, hızla artan nüfusla ve gelişen teknolojiyle birlikte önemli bir konu haline gelmiştir. Fosil enerji kaynaklarının hızla tükenmesi ve bu kaynakların kullanımının insan sağlığına olumsuz etkileri, karbondioksit (CO₂) emisyon miktarının artmasına yol açmaktadır. Bu nedenle, günümüzde ülkeler verimli ve sürdürülebilir enerji kaynaklarına yönelmektedir. Yenilenebilir enerji kaynaklarına olan ilgi ve yatırımlar da bu doğrultuda önemli ölçüde artmıştır. Bu kaynaklardan, enerji üretim teknolojisi hızla gelişen ve gelecek vaat eden uygulamalarından birisi olan güneş enerji sistemleridir. Bu sistemler, güneş ışığını doğrudan elektrik enerjisine dönüştüren fotovoltaik panellerden oluşur.

Ülkemiz coğrafi konumu nedeniyle yüksek güneş enerjisi potansiyeline sahip olup, 9.979 santral ve 10.048,512 MW kurulu güce sahiptir. Ancak, bu santrallerde bulunan fotovoltaik sistemlerin verimli çalışmasını olumsuz yönde etkileyen hücre hatası, modül hatası ve panel hatası gibi hatalar bulunmaktadır. Bu hatalar panelinin elektrik enerjisi üretme performansını düşürmekte ve verimini azaltmaktadır. Fotovoltaik sistemlerde oluşan arızaların tespiti ve teşhisi için insan gücüne ihtiyaç vardır. Fakat panellerdeki bu hataların tespiti için gereken insan gücü eksikliği ve güneş panellerinin ulaşım zorluğundan dolayı fotovoltaik sistemlerin bakım, onarım, kontrol süreleri gecikmektedir. Bu durum neticesinde hem maddi kayıplar fazlası ile artmakta hem de panellerin enerji verimliliği oldukça düşmektedir.

Bu çalışmada, fotovoltaik sistemlerin verimli çalışmasını olumsuz yönde etkileyen hücre hatası (hotspot arızası) ve modül hatası (bypass diyot arızası) tespiti için derin öğrenme tabanlı segmentasyon yaklaşımı termal kamera yardımıyla tespit ve teşhisi önerilmiştir. Önerilen bu sistemde hotspot arızasını YOLO algoritmaları ve bypass diyot arızalarını U-Net algoritmasıyla verimlilik tespiti yapılmıştır. Yapılan çalışmalar doğrultusunda hotspot arıza tespiti için 4 farklı YOLO algoritmaları performansları karşılaştırılmış ve en iyi sonuç veren model belirlenmiştir. Yapılan deneyler sonucuna göre, YOLOv8x algoritmasının %88,7 özgüllük, %80,5 duyarlılık ve %83,8 mAP değerleri ile diğer modellere göre en iyi performans sonucunu vermiştir. Bypass diyot arızası segmentasyonu için farklı katman derinlikleri ve filtre sayılarına sahip dört farklı U-Net modeli uygulanmıştır. Yapılan deneysel sonuçlara göre, %87,79 AUC, %82,97 F1-Score ve %70,89 IOU değerleri ile en yüksek performans U-Net-V2 mimarisi ile elde edilmiştir.

Anahtar Kelimeler: Fotovoltaik sistemler, hotspot arıza tespiti, bypass diyot arıza tespiti, YOLO algoritması, U-Net algoritması, görüntü işleme.

AUTOMATIC EFFICIENCY DETECTION OF SOLAR PANELS USING DEEP LEARNING BASED SEGMENTATION APPROACHES

ABSTRACT

Energy production and consumption in the world has become an important issue with the rapidly increasing population and developing technology. The rapid depletion of fossil energy resources and the negative effects of the use of these resources on human health lead to an increase in the amount of carbon dioxide (CO₂) emissions. For this reason, today countries are turning to efficient and sustainable energy sources. Interest and investments in renewable energy sources have increased significantly in this direction. Among these sources, solar energy systems are one of the rapidly developing and promising applications of energy production technology. These systems consist of photovoltaic panels that convert sunlight directly into electrical energy.

Our country has high solar potential due to its geographical location, with 9,979 plants and 10,048.512 MW installed capacity. However, there are errors such as cell error, module error, and panel error that negatively affect the efficiency of the photovoltaic systems in these plants. These errors decrease the power generation performance of the panel and reduce its efficiency. Human resources are needed to detect and diagnose failures in photovoltaic systems. However, due to the lack of manpower needed to detect these defects in the panels and the difficulty of transporting solar panels, maintenance, repair and inspection times of the photovoltaic systems are delayed. As a result, both the material losses are increasing and the energy efficiency of the panels is significantly reduced.

In this study, it is proposed to detect and diagnose cell faults (hotspot failures) and module faults (bypass diode failures) that negatively affect the efficient operation of photovoltaic systems using a deep learning-based segmentation approach with the aid of a thermal camera. The recommended system has been tested for the efficiency of hotspot failure using YOLO algorithms and bypass diode failures using the U-Net algorithm. The performance of four different YOLO algorithms has been compared and the model with the best results has been identified. As a result of experiments, the YOLOv8x algorithm produced the best performance compared to other models with 88.7% specificity, 80.5% sensitivity and 83.8% mAP values. Four different U-Net models with different layer depths and filter numbers have been implemented for bypass diode failure segmentation. Based on experimental results, 87.79% AUC, 82.97% F1-Score and 70.89% IOU values were obtained with the highest performance U-Net-V2 architecture.

Keywords: Photovoltaic systems, hotspot fault detection, bypass diode fault detection, YOLO algorithm, U-Net algorithm, image processing.

1. GİRİŞ

Küreselleşen dünyada, hızla artan nüfusla ve gelişen teknolojiyle birlikte hayatın her alanında kullanılan enerjinin üretimi ve tüketimi önemli bir hale gelmiştir. Enerjinin üretimi sırasında kısıtlı olan fosil enerji kaynaklarının hızlı tüketimi, karbondioksit (CO₂) emisyon miktarının artışına yol açarak insan sağlığı üzerinde olumsuz etkiler yaratmaktadır. Ayrıca, fosil yakıtların yanması sonucu ortaya çıkan emisyonlar atmosferdeki sera etkisini arttırmakta ve iklim değişikliğine neden olmaktadır. Uluslararası enerji ajansı (IEA) tarafından yayınlanan rapor verilerine göre, 2022 yılında CO₂ emisyon miktarı %0,9 artarak tüm zamanların en yüksek seviyesi olan 36,8 Gt'ye ulaşmıştır [1].

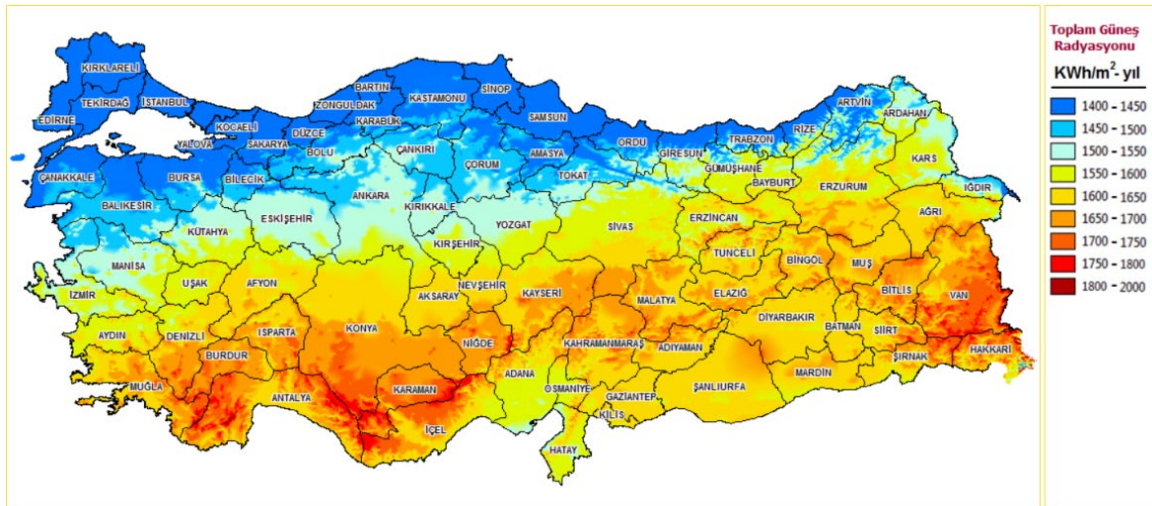
CO₂ emisyon miktarının artması ve buna bağlı olarak ortaya çıkan olumsuz etkiler, günümüzde somut önlemlerin alınması gerekliliği, ülkeleri verimli ve sürdürülebilir enerji kaynaklarını kullanmaya yönlendirmektedir. Bu doğrultuda, yenilenebilir enerji kaynaklarına olan ilgi ve yatırımlar önemli ölçüde artmaktadır. IEA tarafından yayınlanan rapor verilerine göre, 2022 ile 2027 yılları arasında yenilenebilir enerji kaynaklarının kapasitesinin neredeyse 2.400 GW artması (%75 oranında artarak) ve bu artış Çin'in toplam kurulu güç kapasitesine eşit hale gelmesi beklenmektedir [2].

Yenilenebilir enerji kaynakları; rüzgâr enerjisi, güneş enerjisi, jeotermal enerji, hidroelektrik enerji ve biyokütle enerjisi olarak sınıflandırılmaktadır. Yenilenebilir enerji kaynaklarından enerji üretim teknolojisi hızla gelişen ve gelecek vaat eden uygulamalarından birisi olan güneş enerji sistemleridir [3]. Güneş enerji sistemleri, kolay kurulum ve kullanım kolaylığına sahip olmanın yanı sıra temiz, sürdürülebilir, çevre dostu ve zararlı atık oluşturmayan bir yapıya sahip olduğu için, yenilenebilir enerji kaynakları arasında en fazla talep edilen enerji kaynağıdır.


Güneş enerjisi, dünya genelinde en yaygın ve sürdürülebilir enerji kaynağı olarak kabul edilirken, enerji elde etmek için farklı yöntemler de kullanılmaktadır. Özellikle doğrudan güneş radyasyonundan elde edilmesinin yanı sıra, rüzgâr, biyokütle, okyanus gibi dolaylı

formlardan da güneş enerjisinden faydalanmak mümkündür [4]. Güneş enerjisinin üretimi termal ve fotovoltaik (PV) sistemler aracılığıyla gerçekleştirilmektedir [5]. Termal sistemler, güneş enerjisini ısı enerjisine dönüştürerek su ısıtma, pişirme, kurutma, elektrik üretimi ve diğer uygulamalarda kullanılırken, fotovoltaik sistemler güneş enerjisini doğrudan elektriğe dönüştürerek aydınlatma, iletişim ve elektriksiz bölgelerde güç kaynağı olarak kullanılabilir [4]. PV sistemlerin güvenilirliği, dayanıklılığı ve sürdürülebilir enerji üretmesi dolayısıyla en önemli güç üretim sistemlerinden biri olarak kabul edilmektedir [5,6].


Türkiye, 36°- 42° Kuzey Paralelleri ile 26°- 45° Doğu Meridyenleri arasında bulunan coğrafi konumu sayesinde güneş enerji potansiyeli bakımından oldukça zengin bir ülkedir. Enerji Bakanlığı tarafından hazırlanan Türkiye Güneş Enerjisi Potansiyeli Atlasına (GEPA) göre, günde yaklaşık 7,5 saat güneşlenme süresi ve ortalama yıllık toplam güneşlenme süresi 2,741 saat olarak belirlenmiştir. Ayrıca, günlük ortalama güneş ışınım değeri 4,18 kWh/m² ve ortalama yıllık toplam güneş ışınım değeri 1.527,46 kWh/m² olarak hesaplanmıştır. GEPA’da yer alan genel potansiyel görünümü, Türkiye global radyasyon değerleri ve güneşlenme süreleri aşağıda Şekil 1.1 ve Şekil 1.2’de yer almaktadır. Bu geniş coğrafi alanda güneş ışınları yıl boyunca yoğun bir şekilde etkili olarak dağılır ve ülkenin güneş enerjisi üretimine büyük avantaj sağlamaktadır [7,8].



Şekil 1. 1. Türkiye Güneş Enerji Potansiyeli Atlası (GEPA) [8]

TÜRKİYE Global Radyasyon Değerleri (KWh/m²-gün)

TÜRKİYE Güneşlenme Süreleri (Saat)



Şekil 1. 2. Türkiye global radyasyon değerleri ve güneşlenme süreleri [8]

Jeopolitik konumdan dolayı avantajlı olan ülkemizin güneş enerjisi haritası incelendiğinde toplamda 9.979 güneş paneli santralinin bulunduğu görülmektedir. Bu santrallerin toplam kurulu gücü ise 10.048,512 MW'dir [7]. Ayrıca, REN21'in rapor verilerine göre Türkiye, 2019'da güneş enerjisi kullanımında Çin ve ABD'den sonra gelmektedir [9,10]. Ülkemizde güneş panellerinin kurulum kapasitesinde küresel düzeyde artış gözlenmektedir. PV sistemleri genellikle alüminyum çerçeve ve cam laminasyon gibi yöntemlerle çevresel faktörlere karşı korunurlar. Ancak, bu tedbirler sert iklim koşulları nedeniyle yetersiz kalabilmektedirler.

PV sistemlerinin üretim ve kullanım süreçlerinde güvenilirlik, güç düşüşü, dış çevre koşulları ve arızalar gibi çeşitli etmenlerde etkili olabilir. PV sistemlerinin verimini olumsuz etkileyen bu etmenleri hücre hatası, modül hatası ve panel hatası gibi kategorilere ayırabiliriz. Bu etmenler, panellerin akım akışını engelleyerek üretim gücünü ve verimliliğini azaltmaktadır [11]. Ayrıca, PV sistemlerinin çıkış gücünü potansiyel olarak %50'ye kadar düşürebilmektedir [12]. Bu nedenle, güneş enerjisi üretim santrallerinde, maksimum verimi sağlamak amacıyla panellerin bakımlarının düzenli aralıklarla yapılması ve arızalı ünitelerin değiştirilmesi veya onarılması gerekmektedir [13,14].

Arızalı PV panellerin görsel olarak tespiti, eğitimli uzmanlar için dahi zor bir süreçtir. Üretim ve lehimleme aşamaları sırasında PV hücreleri termomekanik streslere maruz

kalmaktadır [15]. Bu stresler sonucunda PV panellerin camında açıkça görünen çatlaklar, kırıklar ve çizik kusurlarının dışında, PV panellerin verimini etkileyen birçok kusur gözle görülemeyebilir [11]. PV sistemlerdeki verim kayıplarını azaltmak için bakımlarının düzenli aralıklarla yapılması gerekmektedir. Güneş enerji panellerin sayıca fazla PV sistemlerin arızalarının tek tek tespiti için yetersiz insan gücü eksikliği bulunmaktadır. Bununla birlikte, güneş panellerini coğrafi konumlarından kaynaklanan ulaşım zorlukları, PV sistemlerin bakım, onarım, kontrol sürelerinde geciktirmektedir [16–18]. Bu sebeple PV panellerin testlerinin daha hızlı ve kolay bir şekilde yapılabilmesi için termografi yöntemi kullanılmaktadır.

Termografi, PV sistemlerde çıplak gözle görülmeyen arızalı ve hasarlı panellerin hata analizinde kullanılan tahribatsız ve temassız bir yöntemdir [19]. Bu yöntem, termal kameralar ve ilgili uygulamalar aracılığıyla gerçekleştirilir. Termal kameralar, nesnelere yayılan ve gözle görülmeyen IR (kızılötesi) radyasyonu ölçmeye yarayan optik lensler ve kızılötesi sensörlerden oluşmaktadır [20,21]. Sensörler, sıcaklığı mutlak sıfırın üzerindeki nesnelere tarafından yayılan kızılötesi radyasyonu ölçer [22]. Kızılötesi radyasyonu, nesnelere atom ve molekül düzeyindeki titreşimlerinden kaynaklanan bir tür elektromanyetik radyasyondur. Bu radyasyon, nesnenin sıcaklığına bağlı olarak farklı dalga boylarında yayılır ve bu dalga boyları sensörler tarafından algılanarak sıcaklık ölçümlerine dönüştürülür [23]. Termal kameralarda görüntüleme yöntemi olarak kullanılan termografi, nesnelere tarafından yayılan gözle görülmeyen kızılötesi enerjisini (ısıyı) esas alarak bu enerjiye göre nesnenin görüntüsünü oluşturan renkler ve şekillere göre nesnenin genel yapısını görüntüleyen bir sistemdir [24]. PV sistemlerdeki hata analizini termal kamera yardımıyla tespit edilebilmektedir. Termal kameralarla elde edilen görüntülerin uzmanlar tarafından analiz edilmesi gerekmektedir, ancak bu analizlerin maliyeti oldukça yüksektir. Maliyeti düşürmek ve analiz sürecini hızlandırmak için yapay zekâ tabanlı otonom uzman sistemlerin geliştirilmesi gerekmektedir.

Bu tez çalışmasında, güneş panellerinin verimlilik durumunu otomatik olarak izlemek ve olası hataların türünü ve konumunu tespit etmek için derin öğrenme tabanlı segmentasyon yaklaşımını sistem tasarlanmıştır. Bu uzman sistem, güneş panellerinin işletim verilerini analiz ederek verimliliği daha iyi anlamak ve optimize etmek için derin öğrenme ve veri analitiği tekniklerini kullanarak hata tespiti yapar ve operatörlere hızlı geri bildirim

sağlar. Bu çalışma, bölgesel (YOLO) ve piksel tabanlı (U-Net) yaklaşımların bir araya getirilmesini içermektedir. Bu iki yaklaşımın kombinasyonu, farklı hata türlerini aynı anda tespit edebilme yeteneği sunmaktadır. İlk olarak, "YOLO" (You Only Look Once) adı verilen bölgesel tabanlı derin öğrenme modelini kullanarak, güneş panellerindeki hotspot (sıcak nokta) hatalarını tespit etmek için bir yöntem uygulanmıştır. Bu model, güneş panellerinin yüzeyindeki belli başlı hata türlerini belirlemek ve bu hataların konumlarını saptamak için kullanılmıştır. Hotspot hataları, aşırı ısınma veya diğer sorunlar nedeniyle panellerde oluşabilen kritik sorunlardan biridir. Diğer yandan, "U-Net" (Üç Boyutlu Nöral Ağlar) adı verilen piksel tabanlı bir derin öğrenme modeli kullanılmıştır. Bu model, güneş panellerinin her bir pikselini inceleyerek bypass diyot hatalarını tespit etmek için kullanılmıştır. Bypass diyotları, panellerin verimliliğini olumsuz etkileyebilecek ve enerji kayıplarına neden olabilecek önemli bir hata türüdür. Bu iki farklı yaklaşım, güneş paneli sistemlerinin hata tespiti ve bakım süreçlerini geliştirmeye yönelik önemli bir katkı sağlamıştır. Bu çalışma, güneş enerjisi endüstrisinde daha güvenilir ve etkili güneş paneli sistemlerinin geliştirilmesine yardımcı olacak bilimsel bir temel sunmaktadır. Ayrıca, enerji üretimindeki verimliliği artırmak ve bakım maliyetlerini azaltmak gibi pratik uygulamalara da katkıda bulunabilir. Bu tez çalışmasının yenilikçi ve özgün yönleri şu şekilde sıralanabilir.

- Bölgesel ve Piksel Tabanlı Yaklaşım Kombinasyonu: Güneş panellerindeki hataları tespit etmek için hem bölgesel (YOLO) hem de piksel tabanlı (U-Net) yaklaşımların bir araya getirilmesini içermektedir. Bu yaklaşım, farklı hata türlerini aynı anda tespit edebilme kapasitesi sunar ve güneş paneli sisteminin daha ayrıntılı bir analizine olanak tanımaktadır.
- YOLO ve U-Net Model Uygulamaları: YOLO ve U-Net gibi önde gelen derin öğrenme modellerinin güneş paneli hata tespitine uyarlanması, bu çalışmanın özgünlüğünü artırmaktadır. Bu modeller, genellikle nesne tanıma ve görüntü işleme alanlarında kullanılan teknolojilerdir, ancak bu tez çalışması, güneş paneli sistemlerindeki spesifik sorunları ele almak için bu modellerin kullanılmasını içermektedir.

- Güneş Enerjisi Endüstrisine Katkı: Bu çalışma, güneş enerjisi endüstrisinde verimlilik artırma ve bakım süreçlerini geliştirme potansiyeli taşımaktadır. Güneş panellerinin otomatik olarak taranması ve hataların tespit edilmesi, işletme maliyetlerini azaltabilir ve enerji üretiminde daha fazla verimlilik sağlayabilir.
- Derin Öğrenme Tabanlı Segmentasyon Yaklaşımını Uzman Sistem: Tez çalışması, bir uzman sistem olarak tasarlanan bir derin öğrenme modelini içerir. Bu uzman sistem, güneş paneli hatalarını otomatik olarak tespit edebilir ve operatörlere veya bakım ekiplerine hızlı geri bildirim sağlayabilir.
- Veri Analitiği ve Büyük Veri Kullanımı: Bu çalışma, büyük veri analitiği tekniklerini kullanarak güneş paneli sistemlerinin verimliliğini izler. Bu, güneş paneli üretim verilerinin daha iyi anlaşılmasına ve optimize edilmesine katkıda bulunabilir.
- Sürdürülebilirlik ve Temiz Enerjiye Katkı: Güneş enerjisi, temiz ve sürdürülebilir bir enerji kaynağıdır. Bu tez çalışması, güneş panellerinin daha uzun ömürlü olmasına ve daha az atığın oluşmasına yardımcı olarak sürdürülebilirlik ve temiz enerji hedeflerine katkıda bulunur.

Bu özgün ve yenilikçi yönler, tez çalışmasının güneş enerjisi endüstrisine potansiyel katkılarını vurgular ve bu alanda gelecekteki araştırmalara ilham kaynağı olabilir.

Bu tez çalışması, yedi bölümden oluşmaktadır. Bunlar:

- Giriş bölümünde; son dönemlerde ekonomik ve sosyal gelişmelere paralel olarak artan enerji talebi ve bu talebin karşılanması için yenilenebilir enerji kaynakları ile güneş enerjisi potansiyeli hakkında bilgi verilmiştir. Ayrıca bu bölümde tezin amacı, özgün ve yenilikçi yönleri ile katkılarına yer verilmiştir.
- Kaynak özetleri bölümünde, literatürde güneş panellerinin termal kamera ile arıza tespiti hakkında yapılmış akademik çalışmalar incelenmiştir ve bu çalışmalarının bulguları özetlenmiştir.

- Fotovoltaik sistemler, fotovoltaik sistemler ve fotovoltaik sistemlerde oluşabilecek arıza çeşitleri ve bu arızaların tespiti için kullanılan termal kamera yöntemi hakkında bilgilere yer verilmiştir
- Derin öğrenme tabanlı segmentasyon yöntemleri, bölgesel tabanlı segmentasyon modelleri ve piksel tabanlı segmentasyon modeli hakkında bilgi verilmiştir.
- Veri seti, yapılan çalışmada kullanılan veri setinin analiz süreci ve veri etiketleme bilgileri sunulmuştur.
- Bulgular ve tartışma bölümünde, önerilen yöntemlerle gerçekleştirilen deneysel çalışmaların sonuçları ve bu sonuçların analizi yer almaktadır. Ayrıca, elde edilen bulguların güneş panellerinin verimliliği ve arıza tespiti üzerindeki etkileri tartışılmıştır.
- Sonuçlar ve öneriler, yapılan tüm işlemler ve elde edilen sonuçlar değerlendirilmiş ve gelecekte yapılabilecek çalışmalar hakkında öneriler sunulmuştur.
- Tez çalışmasında önerilen yöntemlerle gerçekleştirilen çalışmalardan elde edilen sonuçlar ve bu sonuçların yorumlarına yer verilmiştir. Ayrıca, bu alanda gelecekte yapılacak çalışmalar için öneriler sunulmuştur. Bu öneriler, güneş paneli sistemlerinin daha etkin bir şekilde izlenmesi ve bakımının yapılması için yol gösterici olabilir.

2. KAYNAK ÖZETLERİ

PV panellerde meydana gelen arızaların tespit edilmesi, sistem verimliliğini artırmak ve güvenilirliği sağlamak açısından kritik bir öneme sahiptir. Ancak bu süreçte, bazı zorluklarla karşı karşıya kalınabilir. Özellikle, PV panellerin çoğu zaman uzak ve erişilmesi zor bölgelerde kurulması nedeniyle, bu panellerin bakım, onarım ve kontrol süreleri gecikebilir. Ayrıca, gereken insan gücü eksikliği de bu süreci daha da zorlaştırabilir. Bu bağlamda, PV sistemlerin bakımını kolaylaştırmak ve verimli bir şekilde çalışmasını sağlamak için otomasyon teknolojileri ve uzaktan izleme sistemleri gibi yenilikçi yaklaşımların kullanılması önemlidir. Bu, hatalı panellerin daha hızlı tespit edilmesini ve enerji üretiminin kesintisiz devam etmesini sağlamak için literatürde birçok çalışma yapılmıştır.

Kaycı [25], 4 rotorlu insansız hava aracına yerleştirilmiş termal kamera ile güneş panellerinin hücre hatası, modül hatası ve panel hatasını tespit etmek için derin öğrenme tabanlı hata tespit işlevine sahip bir sistem geliştirilmiştir. Derin öğrenme tabanlı YOLOv3 evrimsel sinir ağı kullanılmıştır. Termal kamera ile hücre, modül ve panel hatalarının olduğu bir termal veri seti oluşturulmuştur. Bu termal veri seti ile Yolov3 ağı eğitilmiştir. Eğitim gömülü yapay zekâ özellikli bir bilgi işlem cihazı olan Nvidia Jetson TX2 ile gerçekleştirilmiştir. YOLOv3 ağının eğitimi 162 adet görüntü ile 3000 adımda tamamlanmıştır. Eğitimin tamamlanmasının ardından yapılan deneylerde hücre hatasının tespit ve teşhisinde %97, modül hatasının tespit ve teşhisinde %95 ve panel hatasının tespit ve teşhisinde %93 doğruluk sonucuna ulaşılmıştır [7].

Henry vd. [26], PV modüllerde oluşan arızaların otomatik tespiti ve lokalizasyonu için otonom drone tabanlı kızılötesi termografi sistemini önermişlerdir. Önerilen drone sistemi, Pixhawk 2.1 uçuş kontrol cihazı kullanılarak geliştirilen gimbal donanımlı bir sistemden oluşmaktadır. Drone sistemiyle PV modüllerdeki arızaları yakalamak için Logitech C270 RGB kamera ve FLIR Vue Pro R termal kameradan oluşan çift kamera monte edilmiştir. Manuel drone kontrolü ihtiyacını ortadan kaldırmak için otomatik bir drone uçuş yolu planlama algoritmasını ve görüntüleri analiz etmek için görüntü işleme

algoritmasını kullanmışlardır. Drone sistemi, Güney Kore'nin Suncheon kentinde bulunan 1MW'lık güneş enerji santralinde 10 m yükseklikte 3m/s hızla hareket ederek güneş enerji santralini görüntülemiştir. RGB ve termal kamera görüntülerinin sırasıyla 1024x768 ve 640x480 çözünürlükte 1 sn aralıklarla 400 görüntü elde edilmiştir. Yapılan deneyler sonucunda, önerilen sisteminin kusurlu PV modüllerinin tespiti için etkili olduğu gözlemlenmiştir.

Han vd. [27], derin öğrenme yöntemi kullanılarak güneş panellerindeki arıza tespitini gerçekleştirmişlerdir. Önerilen sistemde, termal görüntü elde etmek ve güneş panellerindeki arızaların yerini belirlemek için termal kamera ve GPS ile donatılmış insansız hava aracı (İHA) kullanılmıştır. İHA ile termal görüntüler elde edilerek güneş panellerindeki arızaların yerlerini belirlemek amacıyla geliştirilmiş bir YOLOv3-tiny modeli kullanılmıştır. Veri seti, Güney Kore'deki Kumoh Ulusal Teknoloji Enstitüsü tarafından bebop dronu kullanılarak oluşturulmuştur. Bu veri setinde 1920x1080 çözünürlüğe sahip 1.470 termal görüntü bulunuyor ve bu görüntüler, BBox etiketleme aracı kullanılarak etiketlenmiştir. Etiketlerde 0 ve 1 sınıfı atandı. Sınıf 0, güneş panellerinde hata tespit edilmediğini, sınıf 1 ise hata tespit edildiğini temsil etmektedir. Veri setinin %70'i eğitim aşamasında kullanılmış, geri kalan %30'u ise test aşamasında kullanılmıştır. Geliştirilen model, eğitim aşaması sırasında 0,4126 ortalama kare hatasıyla %96,5'lik yüksek bir mAP değeri elde edilmiştir. Performans değerlendirme sonuçlarına göre, geliştirilmiş YOLOv3-tiny modelinin yüksek bir doğruluk, geri çağırma, F-skor değeri ve düşük hassasiyet değerleri, istikrarlı bir modelin performansını göstermiştir.

Ren vd. [28], PV sistemlerde hotspot tespiti için derin öğrenme temelli bir sistem geliştirmişlerdir. Geliştirilen sistemde Sigle Shot Detection (SSD) algoritmasını kullanmışlardır. Bu algoritma, VGG-16 evrişimli sinir ağı yapısının yerine MobileNet ağıyla değiştirilerek MobileNet-SSD ağı olarak adlandırılmıştır. Yapılan deneysel çalışmalarda, 2.000 görüntü toplanmıştır ve bunların 1.500'ünde hotspot hataları bulunuyordu. Orijinal veriler üzerinde ters çevirme, kırpma, ölçeklendirme, gürültü giderme gibi veri geliştirme ve genişletme işlemleri yapmışlardır. Bu işlemler sonucunda yaklaşık olarak 6.000 veri elde edilmiş ve bunlardan 200 tanesi test verisi olarak kullanılmıştır. Bu görüntüler labeling adlı bir yazılım programı kullanılarak etiketlenmiştir. MobileNet-SSD algoritması, PV sistemlerde hotspot tespitinde büyük

hedefler için %100 güven sağlarken, orta hedefler için %85 ve küçük hedefler için %54 güven düzeyine sahiptir. Ayrıca, geliştirilmiş MobileNet-SSD algoritmasını YOLO ve SSD algoritması ile karşılaştırmışlardır. Karşılaştırılma sonuçları, FPS hızının 46FPS'ten 27FPS'e göre büyük ölçüde iyileştirildiğini göstermektedir. Ayrıca büyük hedefler için %100 güvenceye sahip olan MobileNet-SSD algoritmasının YOLO algoritması ile karşılaştırıldığında güvenilirliğin %5,0 artış olduğunu, SSD algoritmasıyla yaklaşık olarak aynı olduğu tespit edilmiştir. Sonuç olarak, PV dizilerde hotspot algılama sisteminin, YOLO ve SSD algoritmalarına kıyasla iyi derecede güvene, yüksek algılama hızına, düşük kaçırılan tespit oranına ve iyi sağlamlığa sahip olduğunu gözlemlenmiştir.

Niazi vd. [29], güneş enerji sistemlerinde kullanılan PV modüllerde meydana gelen hotspot hatalarını tespit etmek, değerlendirmek ve sınıflandırmak amacıyla termal görüntülerden yararlanan bir makine öğrenme tekniği geliştirmişlerdir. Makine öğrenme tekniği, termal görüntülerin doku ve gradyan histogramı (HOG) özelliklerini kullanarak hotspot hatalarını tespit eder ve sınıflandırır. Termal görüntüleri FLIR VUE-Pro 640 termal kamera kullanılarak 42,24 kWp'lik bir PV sistemde 375 adet 640x512 çözünürlüğe ve renk kanalı piksel başına 8 bitlik derinliğine sahip görüntüler elde edilmiştir. Termal görüntüleri arızalı, hotspot hataları olan ancak hücrede bir hata olmayan (NDH) ve hotspot olmadan hücrede bir hata olmayan (NDNH) olmak üzere üç farklı kategoriye göre sınıflandırılmıştır. Kategorilere ayrılan hotspot hataları makine öğrenme tekniği olan nBayes (Naive Bayes) sınıflandırıcısı eğitilerek tespit edilir. Naive Bayes sınıflandırıcısı doğruluğu k-en yakın komşu sınıflandırıcısı (k-NN), rastgele sinir ağı sınıflandırıcısı (RNNC) ve Parzen yoğunluk tahminine dayalı eğitilebilir bir sınıflandırıcı (PARZENDC) dahil olmak üzere çeşitli makine öğrenme teknikleri ile karşılaştırılmıştır. K-en yakın komşu sınıflandırıcısı ile %81,30'luk, rastgele sinir ağı sınıflandırıcısıyla %84,80'lik, Parzen yoğunluk tahminine dayalı eğitilebilir bir sınıflandırıcıyla %84,26'lık doğruluk elde edilirken Naive Bayes sınıflandırıcısı ile 375 adet termal görüntünün 22 tanesi hatalı sınıflandırılarak %94,10 doğruluk elde etmiştir. Sonuç olarak, tüm sınıflandırıcılardan daha iyi bir performans gösteren nBayes sınıflandırıcısı olduğu gözlemlenmiştir.

Constantin vd. [30], Ulusal Elektrik Mühendisliği Araştırma ve Geliştirme Enstitüsü ICPE-CA çatısına monte edilen 8 yıllık 12 kW tepe gücüne sahip şebeke bağlantılı PV

panellerdeki bypass aktive edilmiş diyot hatalarının performansını değerlendirmişlerdir. Yapılan çalışmalarda, Seek Thermal Reveal PRO ve FLIR ThermoCAM P620 termal kameralar kullanılarak gerçekleştirilen termografik inceleme ile bypass aktive edilmiş diyot hatalarının tespitini yapmışlardır. PV panel performansının değerlendirilmesi, HT I-V 400 ekipmanı ile ölçülen Akım-Gerilim (I-V) ve Güç-Gerilim (P-V) özellikleri kullanılarak sağlıklı ve arızalı PV paneller karşılaştırılmıştır. Elde edilen termal görüntüler, Gerçek Dünya Çalışma Koşulları (OPC) karşılık gelen I-V ve P-V eğrilerinin ölçümü için invaziv yöntem izlenmiştir ve bu eğriler, Standart Test Koşulları (STC) için yaklaşık olarak hesaplanmıştır. Yaklaşık olarak hesaplanan eğriler PV panellerin nominal özellikleriyle karşılaştırılmıştır. Sağlıklı PV panellerle yapılan deneyler sonucunda, bir adet bypass aktif diyota sahip olan 4 numaralı PV panelin, nominal özelliklerine göre %44,24 daha düşük güce, %30,54 daha düşük V_{mpp} 'ye (maksimum güç voltajı) ve %19,81 daha düşük I_{mpp} 'ye (maksimum güç akımı) sahip olduğu gözlemlenmiştir. Öte yandan, iki adet bypass aktif diyota sahip olan 6 numaralı PV panel, nominal özelliklerine göre %72,54 daha düşük güç, %66,64 daha düşük V_{mpp} ve %17,67 daha düşük I_{mpp} ile oldukça düşük bir performansa sahip olduğu görülmüştür. Sonuç olarak, PV modülünde bir bypass diyotu arızalı olduğunda panelin çıkış gücünün yaklaşık %30, iki bypass diyotu arızalı olduğunda ise %65 oranında azaldığı görülmektedir. Ayrıca arızalı panellerin bypass diyotların değiştirilerek sistemin verimliliğinin geri kazanılabileceği sonucuna varılmıştır.

Dhimish vd. [31], PV modüllerinin çıkış gücü performansını etkileyen hotspot etkisini azaltmaya yönelik yöntemler değerlendirilmiştir. Bu çalışmada, 3 sıra halinde seri bağlı 9 adet 220 Wp nominal güce sahip polikristal silikon PV modüllünden oluşmaktadır. Her PV dizesi için, en az %98.5 verimlilik sağlayabilen bir Maksimum Güç Noktası Takipçisi (MPPT) kullanılmıştır. FLIR i5 termal görüntüleme kamerası kullanılarak tespit edilen hotspot için iki anahtarlı bir koruma sistemi önerilmiştir. Bu koruma sistemi, "16F877A" mikro denetleyicisi tarafından kontrol edilen MOSFET 'ler PV panele bağlanmıştır. Sıcak nokta azaltma tekniği etkinleştirilmeden önce hotspot ve referans güneş pili sıcaklıkları arasında 5.2°F 'lik bir fark gözlemlenmiştir. Ancak, hotspot azaltma tekniği etkinleştirildiğinde 110 sn'lik çalışmadan sonra sıcaklık farkı $0,2^{\circ}\text{F}$ 'ye eşit olduğu görülmüştür. Hotspot etkisini azaltma tekniği, 3 saatte bir 2 dk süreyle etkinleştirilmektedir. Hotspot etkisini azaltma tekniğinin temel nedeni, PV modülü çıkış

gücünü arttırmaktır. Bu nedenle önerilen teknikle ve teknik olmadan güç değeri iki farklı ışınım düzeyinde izlenmiş ve P-V eğrisi kullanılarak değerlendirilmiştir. G: 835 W/m² altında, önerilen teknik 3.6 W'lık bir artışı sağlarken, G: 612 W/m² altında 3.63 W'lık bir çıkış gücü iyileştirmesi sağlamıştır. Ayrıca, hotspot içeren PV modülünün iki başka PV paneliyle seri bağlantılı olduğu ikinci bir test gerçekleştirilmiş ve bu konfigürasyonda da çıkış gücünde yaklaşık olarak 3.57 W'lık bir artış olduğu bulunmuştur. Hotspot azaltma tekniği olarak geleneksel bypass diyotları ve aktif bypass anahtarlama tekniği de uygulanmıştır. Geleneksel bypass diyotları, PV modülündeki hücrelerin uzunluğuna bağlı olarak ters taraflı bir hücre aracılığıyla dağıtılabilecek maksimum çıkış gücünü sınırlamaktadır. Ancak bireysel hücre seviyesinde ayırık veya entegre bypass diyotlarının eklenmesi maliyetli olduğu için düşük maliyetli ve pratik bir hotspot koruma yöntemi gereklidir. Aktif bypass anahtarları, PV dizisini kısaltarak hotspot etkisinin azaltılmasına ve güç kaybının en aza indirilmesini sağlar. Ayrıca, aktif bypass anahtarlama yöntemi 2.8 W'lık bir kayıpla sonuçlanırken, bu çalışmada önerilen hotspot azaltma tekniği çıkış gücündeki kaybı 0.7 W'a kadar indirir. Sonuç olarak, düşük maliyetli ve etkili bir hotspot koruma yönteminin gerekliliği vurgulanmaktadır. Gelecekte PV dizisi konfigürasyon sistemleriyle çalışmak üzere hotspot azaltma tekniğinin geliştirilmesi ve mikro çatlaklı PV modüllerinin çıkış gücünü artırmak için daha fazla teknik geliştirilmesi hedeflenmektedir.

3. FOTOVOLTAİK SİSTEMLER

3.1. Fotovoltaik Sistemler ve Arıza Çeşitleri

Fotovoltaik sistemler, güneşten gelen fotonları doğrudan elektrik enerjisine dönüştüren yenilenebilir enerji sistemleridir. ‘Fotovoltaik’ kelimesi, Yunanca ‘ışık’ anlamına gelen ‘photo’ ve elektrik akımını geliştiren makinayı icat eden Alessandro Volta’nın isminden esinlenerek, voltaj anlamına gelen “voltaic” kelimelerinin birleşmesinden türetilmiştir [32]. 1839 yılında Fransız fizikçi Alexandre Edmond Becquerel tarafından yapılan deneyde, elektrolit içerisine daldırılmış iki metal elektrot arasındaki gerilimin, elektrolit üzerine düşen ışığın şiddetine bağlı olarak değiştiğini gözlemlemiştir. Bu deney, ışığın madde ile etkileşimi sonucu elektrik akımının üretilebileceğini göstererek, fotovoltaik etkinin keşfine öncülük etmektedir. 1873 yılında İngiliz mühendis Willoughby Smith, selenyum elementinin yüzeyine ışık düştüğünde elektriksel iletkenliğinin arttığını gözlemleyerek, selenyumun fotoiletken özelliğini keşfetmiştir [33]. İlk selenyum hücresi 1877 yılında William G. Adams ve Richard E. Day tarafından yapılan çalışmalarla, katı maddelerin de fotovoltaik etki gösterebileceğini kanıtladılar. 1883’te Charles Fritts, verimliliği %1’den az olan ilk fotovoltaik hücreyi geliştirmiştir. 1941 yılında Russel Ohl selenyumdan daha verimli olan ilk silikon güneş pilini üretmiş ve patentini almıştır [32,34]. İlk pratik güneş pili, 1954 yılında ABD’deki Bell laboratuvarları tarafından, uzay programı projesi için uzun süreli enerji kaynağına ihtiyaç duyulduğunda geliştirilmiştir. Aynı yıl Chapin, silikon tek kristal hücre için %6’lık bir güneş dönüşüm verimliliğini elde etmiştir. 1955 yılında Western Electric, silikon fotovoltaik teknolojileri için ticari lisanslar satmaya başladı. 1958 yılına gelindiğinde gelişen teknolojiler sayesinde karasal güneş ışığı altında silikon hücre verimliliği %14’e ulaşmıştı [33]. Fotovoltaik hücrelerin ilk uygulaması 1958 yılının Mart ayında Vanguard I isimli uzay aracında 100 cm²’lik bir alanda 0.1 W güç üretme kapasitesine sahip ilk fotovoltaik hücreler kullanılmıştır. 1970’lerin sonlarında yaşanan petrol krizi sonucunda alternatif enerji kaynaklarına olan ilgi artmış ve bu durum, fotovoltaik hücrelerin araştırma-geliştirme (AR-GE) ve üretim faaliyetlerinin hızlandırmıştır. 1985 yılında, New South Wales Üniversitesi’nde gerçekleştirilen çalışmalar sonucunda %20 verimlilik oranında çalışan silisyum PV hücreleri geliştirilmiştir. 2000’li yıllara gelindiğinde, yapılan

arařtırmalar sayesinde fotovoltaik hücreslerin verimlilięi %40 seviyesine kadar yükseltilmiřtir [35].

3.2. Fotovoltaik Sistemlerin Hücre Yapısı ve Çalışma Prensibi

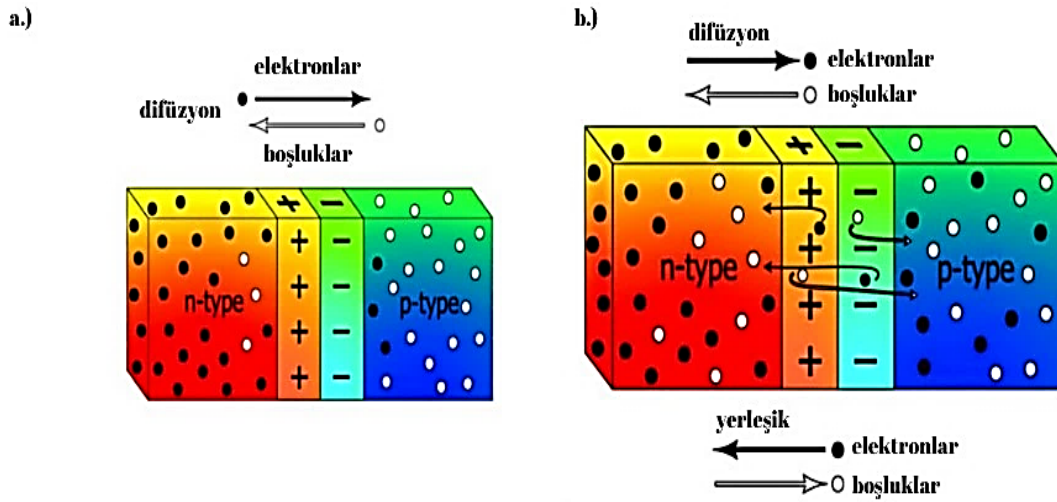
3.2.1. Fotovoltaik Sistemlerin Hücre Yapısı

Fotovoltaik hücreler, farklı yarı iletken malzemelerin birleřimiyle oluřturdukları elektriksel alanda, güneřten gelen fotonların enerjisini elektronlara aktararak elektrik akımı üreten enerji dönüřüm araçlarıdır [36]. Fotovoltaik hücrelerin yüzey şekilleri genellikle kare, dikdörtgen ve daire şeklinde olup, alanları 60-160 cm² arasında olup ortalama 100 cm² 'dir. Kalınlıkları ise 0.1mm-0.4 mm arasında deęiřmektedir [37]. Bu hücrelerde, silisyum (Si), kadmiyum tellür (CdTe), galyum arsenit (GaAs) ve bakır indiyum galyum selenit (CIGS) gibi yarı iletken malzemeler kullanılmaktadır [38]. Fotovoltaik hücrelerde kullanılan yarı iletken malzemeler arasında, silisyum; güneř ışığını elektrik enerjisine dönüřtürme kapasitesinin yanı sıra, bolluęu, dayanıklılıęı, verimlilięi ve düşük maliyeti sayesinde en yaygın kullanılan malzemedir.

Fotovoltaik hücrelerin kullanılabilmesi için yarıiletken maddelerin “n” ya da “p” tipi katkılanmaları gereklidir. Katkılama süreci, saf yarı iletken eriyik içerisine istenilen katkı maddelerinin kontrollü bir şekilde eklenmesiyle yapılır ve elde edilen yarı-iletkenin “n” ya da “p” tipi olması katkı maddesinin türüne baęlıdır [37]. Fotovoltaik hücrelerde en yaygın kullanılan yarı iletken malzeme olan silisyum, atom numarası 14 ve valans bandındaki deęerlik elektron sayısı 4 olan bir elementtir. N-tipi silisyum elde etmek için, silisyum erięine periyodik cetvelin 5A grubu elementlerinden bir tanesi (fosfor vs.) eklenmektedir. Silisyum elementinin dıř yörüngesinde 4 deęerlik elektron bulunurken, fosfor elementinin dıř yörüngesinde 5 deęerlik elektron sayısı bulunmaktadır. Fosforun deęerlik elektron sayısı 5 olduęundan, fosfor elementinin fazladan olan bir elektronu kristal yapıya verilir. Bu nedenle, fosfor gibi 5A grup elementlerine “verici” veya “n-tipi” katkı maddesi olarak adlandırılmaktadır. P-tipi silisyum elde etmek için, silisyum erięine periyodik cetvelin 3A grubu elementlerinden bir tanesi (alüminyum, indiyum, bor vs.) eklenmektedir. Bu elementlerin deęerlik elektron sayısı 3 olduęu için silisyumla reaksiyona girdiğinde bir elektron eksiklięi oluřmaktadır. Eksik kalan elektron yerlerine

“hol” veya “boşluk” olarak adlandırılmaktadır. Bu boşlukların pozitif yük taşıdığı var sayılmaktadır. Bu şekilde elde edilen p-tipi yarı iletken malzemede kullanılan 3A grubu elementlerine “p-tipi” veya “alıcı” katkı maddesi olarak adlandırılmaktadır [36,39].


Yarı iletkenlerin P ve N tipi ana malzemelerine gerekli katkı maddeleri eklenerek yarı iletken eklemler oluşturulur. B u eklemlerde, elektronlar “n” tipi yarı iletkende holler “p” tipi yarı iletkende çoğunluk taşıyıcısıdır. P ve N tipi yarı iletkenler birleşmeden önce p-tipinde negatif enerji seviyeleri ile hol sayıları ve n-tipinde pozitif enerji seviyeleri ile elektron sayıları eşittir, yani nötr durumdadırlar ve elektrik akımı oluşturmazlar. PN eklem oluştuğunda, n-tipindeki elektronlar, p-tipine doğru akım oluştururlar ve her iki tarafta da yük dengesi oluşana kadar devam eder. Eklem bölgesinde, yani PN tipi maddenin ara yüzeyinde, p bölgesi tarafında negatif, n bölgesi tarafında pozitif yük birikir. Bu bölgeye "geçiş bölgesi" ya da "yükten arındırılmış bölge" denir. Bu bölgede oluşan elektrik alan, “yapısal elektrik alan” olarak adlandırılmaktadır [39].Geçiş bölgesi ve elektrik alanı genel gösterimi Şekil 3.1’de verilmiştir.



Şekil 3. 1. Yarı iletken malzemelerde difüzyon ve n-tipi ile p-tipi yarı iletkenlerin birleşim bölgesinde oluşan geçiş bölgesini gösteren diyagramlar. (a) Diyagramı, n-tipi ve p-tipi yarı iletkenler birleşmeden önceki durumu gösterirken, (b) diyagramı, birleşim sonrası oluşan yapısal elektrik alanı ve geçiş bölgesini göstermektedir [40]

3.2.2. Fotovoltaik Hücresinin Çalışma Prensibi

Fotovoltaik hücreler, güneş ışığını elektrik enerjisine çeviren yarı iletken cihazlardır [41]. Bu cihazların güneş pili olarak işlev görebilmesi için yarı iletken birleşim bölgesinde fotovoltaik dönüşüm gerçekleşmelidir. Bu dönüşüm iki aşamalıdır: İlk aşamada, ışığın birleşim bölgesine düşmesiyle elektron-hol çiftleri oluşturulur. İkinci aşamada ise, bu elektron-hol çiftleri ayrıştırılarak enerji dönüşümü gerçekleştirilmektedir [42].




Şekil 3. 2. Fotovoltaik sistemlerin çalışma prensibi [43]

Fotovoltaik hücrenin üzerine düşen fotonlar, yarı iletken malzemelerin PN eklem bölgesine ulaştığında elektronlara çarparak ve serbest yük çiftleri oluşturmaktadır. Uyarılan negatif yüklü (-) elektronlar, geride pozitif yüklü (+) boşluklar bırakır ve bu yük taşıyıcıları, eklem bölgesinde oluşturulan doğal iç ters elektrik alan tarafından çoğunlukla buldukları bölgelere doğru itilmektedir. Bu doğal iç ters elektrik alanı, enerji kazanan yük taşıyıcılarının hareket yönünü belirleyen bir enerji engeli işlevi görmektedir [39]. Sonuç olarak, fotonlarla etkileşime giren negatif yüklü elektronlar n-bölgesinde, pozitif yüklü boşluklar ise p-bölgesinde toplanır ve böylece bir gerilim üretir. Yani, n-tipi yarı iletkenin üzerine düşen fotonlar, elektronları uyarır ve bu elektronlar, p-tipi yarı iletken bölgesine doğru hareket eder. Bu hareket, yarı iletkenler arasındaki PN eklem bölgesinde bir elektrik alanı oluşturur ve elektronların tek yönlü hareketini sağlamaktadır. Böylece doğru akım (DA) üretilir. Bu süreç, güneş ışığının elektrik enerjisine dönüşümünü

mümkün kılar ve fotovoltaik hücrelerin temel işleyiş mekanizmasını tanımlar [36]. Şekil 3.2’de fotovoltaik sistemlerin çalışma prensibi gösterilmiştir.


Ayrıca, güneş enerjisinden elektrik enerjisi elde etmek için kullanılan fotovoltaik hücrelerde, tek bir hücreden elde edilen enerji miktarı genellikle yetersizdir. Bu hücrelerin ürettiği güç, devreden geçen akımın büyüklüğüne bağlı olarak değişir. Akımı artırmak için, fotovoltaik yapıdaki elektron ve boşluk sayısını çoğaltmak gereklidir, bu da hücrelerin yüzey alanını genişleterek mümkün olmaktadır. Sistem çıkışındaki gücü artırmak için, Şekil 3.3’te gösterildiği gibi güneş hücreleri paralel veya seri bağlantılarla birleştirilmektedir. Bu bağlantılarla oluşturulan yapılar fotovoltaik modül olarak adlandırılır. Fotovoltaik hücreler bir araya gelerek modülleri, modüller ise seri veya paralel bağlantılarla panelleri oluşturmaktadır. Paneller birleştirilerek daha büyük güç üniteleri olan dizileri meydana getirmektedir [36,44].



Şekil 3. 3. Fotovoltaik hücreden, modül, panel ve dizi oluşumu [44]

3.3. Fotovoltaik Panel Yapısı

Fotovoltaik panellerin, deęişken iklim kořullarına karřı dayanıklılıklarını artırmak için özel kapsülleme yöntemleri uygulanmıştır. Bu yöntemler sayesinde, paneller darbelere, elektriksel tehlikelere, hava kořullarına ve neme karřı korunmaktadır. Kapsüllemiş bir fotovoltaik panel, modülün hem fiziksel hem de elektriksel bütünlüğünü koruyan çeşitli bileşenlerden meydana gelmektedir [45]. Fotovoltaik panelin ön yüzeyinde ışınları soęuran 150 mikron kalınlığında bir kaplama bulunmaktadır. Şekil 3.4'te gösterilen panel, dıştan içe doğru sırasıyla alüminyum çerçeve, temperlenmiş cam, EVA, solar hücre, EVA, hücre sırt folyosu ve bağlantı kutusundan oluşmaktadır [46]. PV panellerin en üst katmanında, genellikle 2mm veya 3mm kalınlığında termal olarak temperlenmiş beyaz cam kullanılmaktadır. Bu cam tabakası, PV hücrelerini darbelere karřı korur ve panelin dayanıklılığını artırır. İkinci ve dördüncü katmanlarda yer alan EVA (Etilen Vinil Asetat), 0.5mm ile 0.7mm kalınlığında bir kapsülleme malzemesi olarak işlev görmektedir. EVA, PV hücreleri ile cam ve arka levha arasında sıkıştırarak hücrelerin korunmasına ve izolasyonuna yardımcı olmaktadır. Hücre sırt folyosu olarak kullanılan PVF (Polyvinyl Fluoride Film) ise 0.5mm kalınlığında olup, panelin arka yüzeyini kaplar ve ek koruma sağlamaktadır. Tüm bu katmanları bir arada tutmak ve yapıyı darbelere karřı daha da güçlendirmek için alüminyum çerçeve kullanılmaktadır. Ayrıca, elektriksel bağlantıların yapılabilmesi için bağlantı kutusu bulunmaktadır [25,45].



Şekil 3. 4. Fotovoltaik modül yapısı [46]

3.4. Fotovoltaik Sistemlerin Verimini Etkileyen Arıza Çeşitleri

Fotovoltaik paneller, alüminyum çerçeve ve cam laminasyon ile donatılmış olarak, yağmur, rüzgâr, kar gibi çeşitli çevresel koşullara karşı koruma sağlamaktadır. Ancak bu koruyucu önlemler, panellerin uzun vadede maruz kalabileceği tüm dış etkenlere karşı tam bir güvence sunamayabilir. Örneğin, kurulum sırasında panelin kırılması veya çatlaması, şiddetli fırtınalar, dolu yağışları, karlanma, böcek izleri, düşen ağaç dallarının çarpması, yapraklar, kir, kuşların düşmesi veya termomekanik gerilim nedeniyle oluşan hasarlar panellerin yüzeyine zarar verebilmektedir [11]. Fotovoltaik sistemlerdeki hasarlar, akım akışını engelleyerek ve güneş modüllerinin güç verimliliğini azaltarak santralin performansını ve güvenliğini tehlikeye atabilir [5]. Bu durum, santralin performansını olumsuz etkileyebilecek kritik arızalara yol açmaktadır. Bu arızalar, kapsülleme arızası, arka tabaka yapışma arızası, hücre çatlakları, delaminasyon, hotspot arızası, invertör arızaları, bağlantı kutusu arızası, bypass diyot arızası, modül uyumsuzlukları, modüllerin kısa devresi, kablo hasarı ve gölgelenme olarak sınıflandırılabilir [47,48]. Özellikle hotspot ve bypass diyot arızaları, fotovoltaik sistemlerde üretim kapasitesini etkileyerek enerji verimliliğinde en fazla kayba neden olan arızalardır.


3.4.1. Hotspot Arızası

Fotovoltaik sistemlerde, bazı güneş hücrelerinde modül gölgelenmesi, uyumsuz hücreler, diyot arızası, hücre çatlakları, arızalı veya dirençli lehimlemeler, kuş pislikleri, yapraklar, toz lekeleri ve hasarlı ambalaj gibi faktörler hücrelerin işlevini engelleyerek diğer güneş hücrelerine kıyasla daha yüksek sıcaklıklara ulaşmaktadır [48,49]. Bu durum seri bağlı güneş paneli hücrelerinden biri, diğerlerine kıyasla daha düşük akım ürettiğinde, bu hücrede gerilim tersine döner ve hücrenin yük olarak çalışmasına ve dolayısıyla akım ile sıcaklığın artmasıyla hotspot arızalarının oluşumuna neden olmaktadır [50].

Hotspot arızaları, genellikle kısmen bloke edilen panellerin ışığı normal şekilde absorbe edememesiyle başlar. Böylece, silikon yarı iletkenlerin fotoelektrik etkisi engellenir ve panellerde ısı birikmeye başlar. İç direnç gibi güç tüketimi parçaları, akımın ısı üretmesine neden olur ve zamanla bu ısı birikir. [51]. Uzun süreli ısı birikimi sonucunda hotspot etkisi altında kalan hücre, sıcaklığı 150°C'nin üzerine çıkması durumunda

hücrenin tamamen bozulmasına yol açabilir [24]. Bu hücreler, enerji üretmek yerine ısı dağıttığından, PV sisteminin toplam enerji verimliliğinde %15'e kadar bir kayıp beklenir [6].

Hotspot arızalarının oluşumu, güneş enerjisi sistemlerindeki güç üretimini ciddi şekilde azaltabilir ve hücre bozulmasını hızlandırabilir [52]. Bu durum, enerji kaynağının kesilmesine veya yangın riskinin artmasına yol açabilir [51]. Bu sebeplerden ötürü, hotspot etkisi, fotovoltaik sistemlerin güvenliği ve verimliliği için önemli bir sorundur. Hotspot arızalarına sahip güneş panellerinin tespit edilip yenileriyle değiştirilmesi, fotovoltaik (PV) sistemlerinin ömrünü uzatır ve güç kaybını minimum düzeye indirir. Ancak, çoğu hotspot genellikle sıradan optik görüntülerde fark edilemeyecek kadar küçük olduğundan, hotspot arızalarının doğru bir şekilde tespiti için termografik görüntülerin alınması ve analiz edilmesi gerekmektedir [52]. Şekil 3.5'te güneş enerji santralinde meydana gelen hotspot arızanın termal kamera ile alınan görüntüsü verilmiştir.




Şekil 3. 5. Hotspot arızası termal kamera görüntüsü

3.4.2. Bypass Diyot Arızası

Fotovoltaik sistemlerde, gölgelenme veya sıcak nokta hataları gibi durumlarda karşılaşılan güç kayıplarını en aza indirmek ve sistemin genel verimliliğini korumak amacıyla bypass diyotlar kullanılmaktadır [53]. Bypass diyotlar, güneş hücresi dizilerinin

pozitif ve negatif çıkış terminalleri arasına ters yönlü olarak bağlanır ve genellikle küçük gruplar halinde seri bağlı hücreler için kullanılır [54]. Bu diyotlar, termal aşırı yükü ve sıcak noktaların oluşumunu önlemek için modüllerin ara bağlantı devresi içindeki hücrelerin alt dizileri ile köprülenir ve seri bağlı hücre dizilerinde her bir hücre aynı akımı taşıırken, gölgelenme durumunda bu hücrelerin taşıyabileceği maksimum akımın azalmasını engeller. Böylece çıkış gücündeki düşüş en aza indirilir ve sistemin maksimum güç çıkışı muhafaza edilir [54,55].

Ancak, bypass diyot üzerindeki gerilim düştüğünde veya ters polarite durumu sona erdiğinde, diyot kesim durumuna geçer ve akım taşımaz hale gelir. Bypass diyotlar ters polarite koşulları altında çalışırken, üzerinden geçen sızıntı akımı sıcaklıkla birlikte artabilir ve diyotlar belli bir güç tüketimi yapabilir. Bu durum, diyotlar için yeterli soğutma sağlanamadığı takdirde yüksek sıcaklıklarda kalmasına ve eğer yeterli dayanıma sahip değilse bozulmalarına yol açabilir [24]. Şekil 3.6'da tek gölgeli hücreli PV modülde oluşan bypass diyot arızası verilmiştir.




Şekil 3. 6. Tek gölgeli hücreli PV modül [54]

Ayrıca, bypass diyotlarının yıkıcı arıza modları, güvenlik sorunlarına ve ciddi performans kayıplarına yol açmaktadır. Bu arıza modları arasında arklanma, elektrostatik boşalma ve termal kaçak yer almaktadır. Arklanma, diyotun içindeki elektriksel izolasyonun bozulması sonucu oluşan elektrik arkıdır. Genellikle aşırı voltaj durumlarında meydana

gelir ve diyotun hızla bozulmasına yol açmaktadır. Elektrostatik boşalma, genellikle yıldırım çarpması veya üretimdeki yetersiz koruma nedeniyle, diyotlardan büyük akım geçmesiyle gerçekleşir. Termal kaçak, yetersiz ısı dağılımı sonucu oluşur. Bu da diyottan fazla akım geçmesine ve aşırı ısınmasına neden olmaktadır. Bu kaçak süreç, diyotun zarar göreceği kadar yüksek sıcaklıklara ulaşana kadar devam eder. Sürekli yüksek sıcaklıkta çalışma veya termal döngüler nedeniyle bypass diyotlarında kademeli bozulma meydana gelmektedir. Bypass diyotların yıkıcı arıza modları, aşırı sıcaklıklar ve sıcaklık dalgalanmaları, yarı iletken bağlantıları ve kontakları bozar ve sonuçta arızalanmalarına neden olur [56]

Bypass diyot arızalandığında, güneş panelinin elektriksel performansı ciddi şekilde etkilenmektedir Arızalı bir bypass diyota sahip bir fotovoltaik modül, sağlam bir bypass diyota sahip modüle göre voltajında yaklaşık olarak %33 oranında düşüş yaşar [57]. Bypass diyotunun arızalanması, güneş hücrelerinde ısı birikimine ve sıcak noktaların oluşmasına neden olabilir. Bu durum, PV modüllerinde yüzey sıcaklığının artmasına ve yangın riskine yol açabilir [58]. Bu tür bir arıza, sıcaklık farkı sayesinde termografi yöntemiyle kolayca tespit edilebilmektedir [24]. Şekil 3.7’de güneş enerji santralinde meydana gelen bypass diyot arızasının termal kamera ile alınan görüntüsü verilmiştir.



Şekil 3. 7. Bypass diyot arızası termal kamera görüntüsü


3.5. Termografi Yöntemi

Termal kameralar çeşitli sektörlerde kullanılan, yüzeylerin ya da parçaların normalin üzerindeki ısı farklarını ölçebilen çok yönlü bir tanı cihazıdır [19]. Bu cihazlar, nesnelere yayılan ve gözle görülmeyen kızılötesi radyasyonu ölçmeye yarayan optik lensler ve kızılötesi sensörlerden oluşmaktadır [20,21].

Termal kameralar, sensörler aracılığıyla sıcaklığı mutlak sıfırın ($0\text{ K} = -273^{\circ}\text{C}$) üzerindeki sıcaklığa sahip nesnelere tarafından yayılan kızılötesi radyasyonu ölçer [22]. Kızılötesi radyasyonu, nesnelere atom ve molekül düzeyindeki titreşimlerinden kaynaklanan bir tür elektromanyetik radyasyondur. Bu radyasyon, nesnenin sıcaklığına bağlı olarak farklı dalga boylarında yayılır ve bu dalga boyları sensörler tarafından algılanarak sıcaklık ölçümlerine dönüştürülür [23].

Termal kameralarda kullanılan termografi yöntemi, nesnelere yaydığı gözle görülmeyen kızılötesi enerjisini esas alarak, elektromanyetik spektrumun kızılötesi bölümündeki (yaklaşık 900-14000 nanometre veya 0,9- 14 μm) ışınımı tespit eder ve bu ışınımdan renkler ve şekillerle oluşturulan resimler aracılığıyla nesnenin genel yapısını görüntüler [59]. Termografi yöntemiyle, sıcaklık değişimindeki farklılıklar termal kameralarda görselleştirilerek farklı kategorilerde sınıflandırılmasına yardımcı olur [23].

Termal kamera ile elde edilen görüntülerde sıcaklık durumuna bağlı olarak renk dağılımı olmaktadır. Görüntülerde bulunan nesnelere renk dağılımına göre çok sıcak noktalar açık renkli soğuk olan noktalarda ise koyu renkle göstererek sorunun kaynağını kolaylıkla bulmaya yardımcı olur. Soğuk olan bölgelerde mavi renk ile gösterirken sıcak olan bölgeleri sarı renk ile göstermektedir [60]. Örneğin, Şekil 3.8'de bulunan PV panellerde sıcak nokta hatalarını gösteren görüntüde, aşırı ısınan bölgeler hatalı kısımları sarı renk ile vurgulandığı gözlemlenmektedir.



Şekil 3. 8. Termal kamera ile temassız sıcaklık ölçümü

Termografi yöntemi, yüzeylerin sıcaklık farklılıklarını görselleştirmenin yanı sıra, sürekli veya belirli zaman aralıklarında yapılan ölçümlerle konvektif ısı transferini verimli bir şekilde değerlendirmek amacıyla da kullanılmaktadır [59]. Bu yöntem, enerji sektöründe termal izleme ile elektrik sistemlerinin performansını optimize etmek, bina termal izolasyonunu değerlendirmek; sağlık sektöründe vücut sıcaklığı analizleri yapmak ve savunma alanında termal kameralar aracılığıyla çevresel izleme sağlamak gibi birçok alanda kullanılmaktadır [19].

Ayrıca, sürekli olarak elde edilen termal veriler sayesinde potansiyel arızaların erken tespiti ve önleyici bakım uygulamaları da mümkün olmaktadır. Özellikle PV sistemlerde, termografi yöntemi hata tespiti ve performans izleme amacıyla yaygın bir şekilde kullanılmaktadır. PV sistemlerde modül laminasyonu öncesinde, modüle uygulanan ters polariteli voltajın etkisiyle ortaya çıkan sıcak noktaları ve hücrelerde bulunan yarı iletken malzemelerin üretim sürecindeki potansiyel kusurlarından kaynaklanan şöntlerin varlığını önceden belirlenebilir ve düzeltilebilir [61]. Bu yöntem aynı zamanda, PV sistemlerdeki sıcak nokta ve bypass diyot arızalarının tespitinde en etkili yöntemdir.


4. DERİN ÖĞRENME TABANLI SEGMENTASYON YÖNTEMLERİ

Derin öğrenme, verilerden karmaşık özelliklerin otomatik olarak çıkarılmasını sağlayan, birden fazla katmanlı mimarilere sahip yapay sinir ağı algoritmalarını içeren bir makine öğrenme tekniğidir [62,63]. Bu algoritmalar, bir veya daha fazla girdi ve çıktı verisine sahip olup, işlemlerini ardışık olarak kullanılan çok sayıda işlem katmanı ile gerçekleştirilen yapılardır. Ardışık her katman bir önceki katmandan aldığı çıktıyı kendi katmanı için girdi olarak kullanmaktadır [64,65]. Ayrıca birden fazla katmanlı yapı içinde, görüntülerden elde edilen özellikler sinir ağı katmanları aracılığıyla çıkarılmaktadır. Bu katmanlı yapı, gizli katmanlarda öznitelik çıkarımı yaparak eğitim sürecinde ağırlık değerlerini ortaya çıkarmaktadır [66].

Derin öğrenme algoritmalarının katmanlı yapısı, büyük veri setlerini işleyerek geleneksel yöntemlere kıyasla daha tutarlı ve güçlü sonuçlar elde etmektedir [64]. Bu algoritmalar, büyük veri kümelerindeki karmaşık ilişkileri belirleyerek genelleştirilmiş modeller oluşturabilmektedir. Geleneksel makine öğrenimi yöntemlerinin aksine, derin öğrenme manuel özellik mühendisliğine olan ihtiyacı azaltır ve otomatik özellik çıkarımı yaparak küçük veri kümelerinde dahi yüksek doğruluk sağlayabilmektedir [67].

Derin öğrenme algoritmaları, çeşitli veri türleri üzerinde tahminleme, sınıflandırma ve analiz gibi farklı uygulama alanlarında kullanılmakta ve doğrusal olmayan verilerdeki karmaşık ilişkileri modelleme yeteneği sayesinde sınıflandırma ve tanıma konularında üstün performans sergilemektedir [68,69]. Bu algoritmaların yüksek performansı, günümüzde konuşma tanıma, görsel nesne algılama, bilgisayarlı görme, doğal dil işleme, robotik ve otonom araçlar gibi çeşitli alanlarda kullanılmaktadır [62]. Derin öğrenmeye öğrenmeye dayalı mimariler bulunmaktadır. Bunlar, Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN), Uzun-Kısa Süreli Hafıza Ağları (LSTM), Sınırlı Boltzmann Makineleri (RBM), Derin İnanç Ağları (DBN), Derin Oto-Kodlayıcı (AE) mimarileridir [70].

Evrişimli Sinir Ağları (CNN), çok boyutlu veri dizileri üzerinde işlem yapmak için tasarlanmış, birçok katmandan oluşan derin öğrenme tekniğidir. Görüntü analizi ve sınıflandırma alanında kullanılan çok katmanlı ileri beslemeli evrişimli sinir ağları, hayvanların görme merkezinden esinlenerek geliştirilmiştir [71]. Bu algoritmalar, görüntülerin özelliklerini belirginleştirmek amacıyla filtreleme işlemine dayalı bir yapıya sahiptir. CNN, farklı boyut ve değerlerdeki filtreler kullanarak etkin bir şekilde öznitelik çıkarma işlemi gerçekleştirmektedir [70]. Girilen verilere göre kendi özniteliklerini hiyerarşik olarak basitten karmaşığa doğru çıkaran CNN, ilk katmanlarda kenar ve köşe bilgisi gibi basit öznitelikler elde ederken, ilerleyen katmanlarda görüntüye ait daha detaylı öznitelikler elde etmektedir. Bu dinamik yapı sayesinde, CNN'nin sınıflandırma işlemlerinde yüksek başarı elde edilmesini sağlamıştır [72]. Ayrıca, CNN'leri görüntü tanıma ile sınırlı değildir. Bu mimariler, nesne tanıma, yüz tanıma, ses tanıma, nesne algılama, görüntü sınıflandırma, görüntü restorasyonu, otonom sürüş ve tıbbi görüntü analizi gibi birçok uygulama alanında yaygın olarak kullanılmaktadır. CNN mimarileri, Şekil 4.1'de gösterildiği gibi işlevsel olarak sırasıyla giriş katmanı, evrişim (konvolüsyon) katmanı, aktivasyon katmanı, havuzlama katmanı, tam bağlı katmanlar ve sınıflandırma katmanı bulunmaktadır [73].

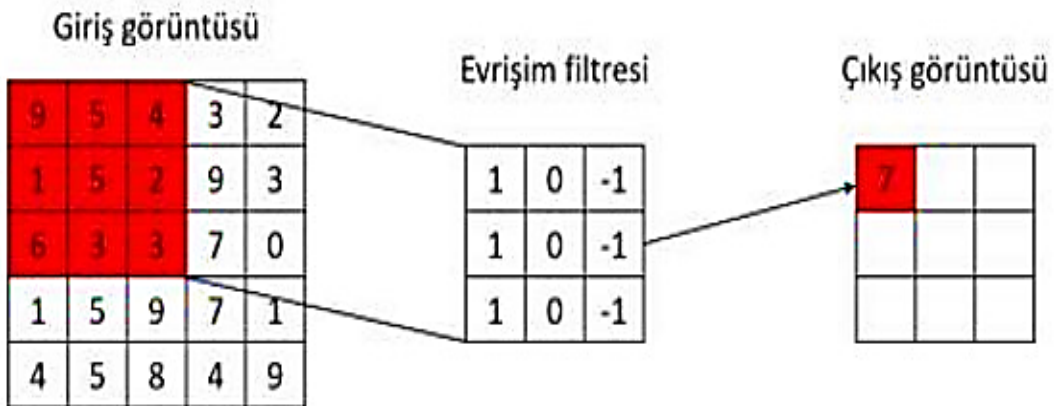


Şekil 4. 1. CNN mimarisini genel gösterimi [72]

Giriş Katmanı: Giriş katmanında video, ses ve görüntü verilerini içerebilir. CNN mimarisinin ilk adımı olan bu katman, verilerin işlenerek diğer katmanlara aktarılmasını sağlar. Sistem performansını ve tahmin doğruluğunu artırmak, aynı zamanda aşırı uyumu

önlemek için girdi verilerine ön işleme ve veri artırma teknikleri bu katmanda uygulanmaktadır [72].

Konvolüsyon (Evrışim) Katmanı: Evrişim Katmanı, bir girdi görüntüsünün tümünde kaydırılarak uygulanan ve bu görüntüden özellikler çıkarmak için kullanılan filtrelerin (örneğin 3×3 , 5×5 , 7×7 gibi farklı boyutlarda) bulunduğu bir katmandır. Evrişim, bir filtrenin görüntü matrisi üzerinde kaydırılması ile gerçekleştirilir. Her bir kaydırma adımında, filtre tarafından kapsanan girdi görüntüsünün bölgesi üzerinde bir evrişim işlemi gerçekleştirilir ve bu işlem sonucunda öznitelik haritaları oluşturulur. Bu öznitelik haritaları, görüntünün belirli özelliklerini (örneğin kenarlar, köşeler, doku vb.) temsil eder ve sonraki katmanlara aktarılır [74]. Evrişim filtresinin görüntü üzerinde uygulanması ile ilgili Şekil 4.2’de bir örnek verilmiştir.




Şekil 4. 2. Evrişim işlemi ile ilgili örnek bir uygulama [75]

Şekil 4.2’de evrişim işlemi, 3×3 boyutundaki bir filtre matrisinin, 5×5 boyutundaki tek kanallı bir giriş görüntüsü matrisi üzerinde kaydırılmasıyla gerçekleştirilir. Filtre, giriş görüntüsünün üzerinde sağa, sola, aşağı ve yukarı doğru hareket ettirilerek uygulanır. Her bir konumda, filtre katsayıları ile giriş görüntüsündeki karşılık gelen pencerelerin değerleri çarpılır ve bu çarpımların toplamı, çıkış görüntüsünün ilgili elemanı olarak hesaplanır. Bu süreç, giriş görüntüsünün tüm alanına uygulandığında, belirgin ve yüksek seviyeli özellikleri ortaya çıkaran yeni bir görüntü elde edilmesini sağlar.

Aktivasyon Katmanı: CNN'nin temel bileşenlerindedir ve ReLU (Düzeltilmiş Doğrusal Birim), derin öğrenme modellerinde tercih edilen bir aktivasyon fonksiyonudur. ReLU fonksiyonunun en belirgin özelliği, giriş verisindeki negatif değerleri sıfıra çekerek ağı daha hızlı öğrenmesini sağlamasıdır. Bu fonksiyon, genellikle konvolüsyon katmanlarından sonra uygulanır ve CNN nöronlarının çıktılarını düzenleyen bir doğrultucu birim olarak işlev görür. Denklem 1'de ReLU fonksiyonunun matematiksel ifadesi verilmiştir [75].

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (4.1)$$

Havuzlama Katmanı: Derin öğrenme modelinde boyut azaltma işlevini yerine getiren önemli bir katmandır. Bu katmanlar, modelin boyutunu azaltarak, öğrenme sürecini hızlandırır ve hesaplama maliyetini düşürür. Boyut azaltma işlemleri genellikle bilgi kaybına yol açsa da havuzlama katmanları bu kaybı minimize ederken, modelin aşırı uyumunu önleyici bir etki göstermektedir. Evrişimli sinir ağlarında kullanılan filtreler aracılığıyla, girdi matrisi üzerinde gezdirilir ve piksellerin maksimum, ortalama veya minimum değerleri alınarak bir havuzlanmış öznitelik haritası oluşturulur. Bu süreç, modelin genelleştirme kabiliyetini artırır ve eğitim veri setindeki istenmeyen gürültülerin model üzerindeki etkisini azaltır [75,76]. Şekil 4.3'te 4×4 boyutundaki görüntü üzerinde 2×2 pencere boyutunda maksimum, minimum ve ortalama havuzlama işlemlerinin uygulandığı ile ilgili bir örnek verilmiştir.



Şekil 4. 3. Havuzlama işlemi ile ilgili örnek bir gösterimi [75]

Tam Bağlı Katman: Evrişim, aktivasyon ve havuzlama işlemleri sonucunda elde edilen çok boyutlu özellik haritalarını tek boyutlu bir vektöre dönüştürme işlevini görür. Bu katman, önceki katmanlar tarafından işlenen öznitelikleri düzleştirerek sınıflandırma için kullanılabilir hale getirir. Düzleştirme işlemi, çok boyutlu matrisleri tek boyutlu bir vektöre çevirir ve bu sayede modelin farklı boyutlardaki özellikleri entegre etmesini sağlamaktadır. Tam bağlı katmanın kullanımı, ağır karmaşık veri yapılarını anlamasına ve daha doğru tahminler yapmasına olanak tanımaktadır. Ayrıca, sınıflandırma katmanına geçiş yapmadan önce gerekli olan yüksek seviyeli özniteliklerin çıkarılmasını sağlamaktadır [73,74].

Sınıflandırma Katmanı: CNN modelinin son katmanıdır ve önceki katmanlar tarafından elde edilen özelliklerin sınıflandırılmasını sağlar. Bu katman, sınıflandırma işleminde olasılıksal bir yaklaşım kullanarak, her bir sınıf için 0 ile 1 arasında bir değer üretir. Bu değerler, giriş verisinin hangi sınıfa ait olduğunu belirlemek için kullanılır. Softmax fonksiyonu matematiksel ifadesi denklem 2 de verilmiştir [75].

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{k=1}^K e^k} \quad (4.2)$$

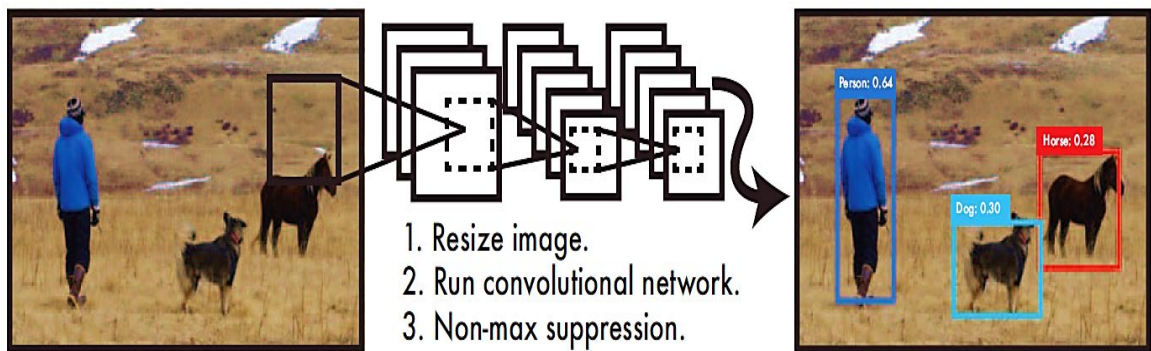
3.6. Bölgesel Tabanlı Segmentasyon Modelleri

Bölgesel tabanlı segmentasyon yöntemleri, görüntülerdeki hataları bir dikdörtgen ile temsili olarak tespit etmektedirler. Bu dikdörtgen; hatalı bölgeyi kapsayacak şekilde tanımlanmaktadır. Bu yaklaşıma dayalı en yaygın olarak YOLO algoritması kullanılmıştır.

3.6.1. YOLO Algoritması

YOLO, sınırlayıcı kutuları ve sınıf olasılıklarını tahmin etmek için tek bir sinir ağını kullanan, GoogLeNet'ten ilham alan CNN tabanlı bir derin öğrenme algoritmasıdır [77,78]. 2016 yılında "You Only Look Once: Unified, Real-Time Object Detection" başlıklı makalede Joseph Redmon, Santosh Divvala, Ross Girshick ve Ali Farhadi tarafından nesne tespitine yeni bir yaklaşım olarak YOLO (You Only Look Once) algoritması nesne tespiti alanında yeni bir yaklaşım olarak sunulmuştur [79]. YOLO

modeli, tek bir ağ yapısında nesneleri algılama, sınıflandırma ve tek aşamalı dedektör olarak çalışabilir [80]. YOLO algoritması, girdi görüntüsünü $S \times S$ (5x5, 9x9, 17x17 vb.) boyutundaki ızgaralara bölerek nesne tespiti yapmaktadır. Her ızgara hücresi kendi içindeki nesnelere sınıfını ve konumunu belirler. Bu işlemi yapan her hücre, o nesnenin sınıf bilgisini, yüksekliğini ve genişliğini bularak çevresine sınırlayıcı kutu (bounding box) çizmektedir [81]. Her bölgedeki nesnelere bulunma olasılığını bir güven puanı ile belirlenmektedir. Güven puanı, $P_c * IoU$ formülü ile hesaplanır, burada P_c , nesnenin tahmin edilen kutusunda olma olasılığını temsil eder. Eğer bu olasılık 1 ise, nesne var demektir; 0 ise, nesnenin bulunmadığı anlamına gelmektedir. IoU (Intersection over Union), tahmin edilen kutu ile gerçekteki kutu arasındaki kesişim oranını ifade etmektedir [82,83]. Bu oran ne kadar yüksekse, güven puanı da o kadar yüksek olur. Bu, algoritmanın nesnelere doğru bir şekilde tespit edip etmediğini değerlendirmek için önemlidir. YOLO algoritması, görüntüdeki nesnelere sınıfını ve konumunu ayrı ayrı tahmin etmek yerine, bunları tek bir regresyon problemi olarak ele alır ve görüntüyü tek bir seferde nöral ağdan geçirerek hem hızlı hem de doğru sonuçlar elde edilmektedir [79]. Tek bir ağ yapısı içerisinde bulunan tüm algılama hattı, diğer sinir ağı mimarilerinin çoğundan daha yüksek doğrudan algılama performansı sunmaktadır [77]. Şekil 4.4'te YOLO'nun tespit sistemi görülmektedir. Bu yöntemi kullanarak, tek bir evrişimli ağın aynı anda birden fazla sınırlayıcı kutu ve bu kutular için sınıf olasılıklarını aynı anda tahmin etmektedir [79].



Şekil 4. 4. YOLO nesne tespit sistemi [79]

YOLO'nun birleşik mimarisi, nesne tespitinde son derece hızlıdır. YOLO'nun ilk versiyonu, saniyede 45 kare hızında görüntü işleyebilmektedir. Aynı zamanda, ağın daha küçük bir versiyonu olan Fast YOLO versiyonu ise saniyede 155 kare gibi yüksek bir

hızda görüntü işleyebilme yeteneğine sahiptir [79]. Bu model genellikle tek aşamalı modellere göre genellikle daha basit, hızlı ve güvenilir doğruluk sonuçları sunmaktadır [80]. YOLO mimarisi, farklı boyutlarda ve hızlarla çalışan farklı modeller geliştirilmiştir. Bu modeller sırasıyla YOLO, YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOv6, YOLOv7, YOLOv8, YOLOX ve YOLOR şeklinde sıralanmaktadır. Literatür çalışmaları incelendiğinde, YOLOv3, YOLOv4, YOLOv5 modellerinin en yaygın kullanılan modeller olduğu gözlemlenmiştir [80]. Bu çalışmada da YOLOv5, YOLOv6, YOLOv7, YOLOv8 modellerinin kullanılmaktadır.

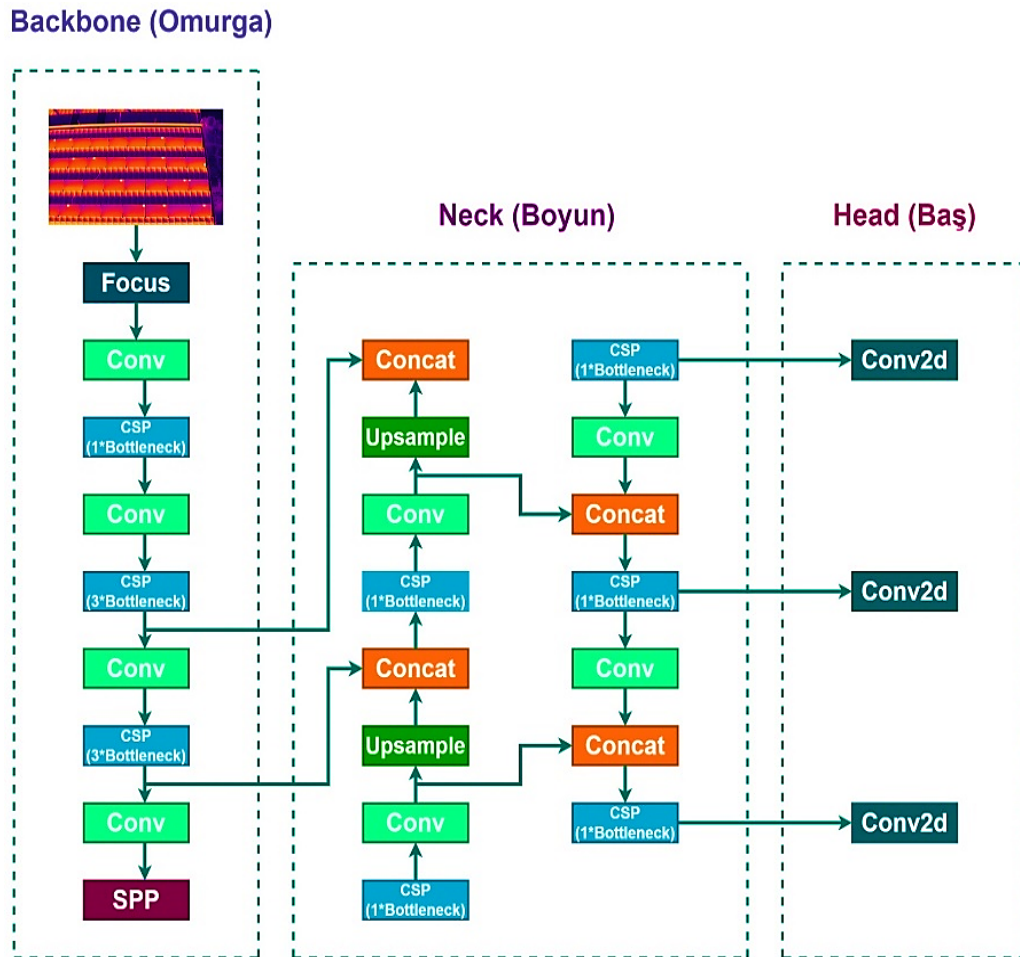
3.6.2. YOLOv5 Algoritması

YOLOv5 algoritması Joseph Redmon tarafından geliştirilen YOLO algoritmasının devamı niteliğindedir. YOLOv5 mimarisi, Phil Wang, Glenn Jocher ve Alexey Bochkovskiy gibi araştırmacılardan oluşan bir ekip tarafından yönetilen Ultralytics adlı bir yapay zekâ araştırma şirketi tarafından geliştirilmiştir. Bu model, 2020 yılında tek aşamalı hedef tanıma algoritması olarak piyasaya sürülmüştür ve açık kaynaklı bir yazılım olarak Github'da yayınlanmıştır. YOLOv5 algoritması, PyTorch kütüphanesi üzerinde yeni bir eğitim ortamı altında derlenerek geliştirilmiştir [78].

YOLOv5 ağ mimarisi omurga (backbone), boyun (neck) ve baş (head) kısmı olmak üzere üç ana bölümden oluşmaktadır [78]. Omurga kısmında, CSPDarknet (Cross Stage Partial Darknet) adlı özel bir mimari kullanılır. CSPDarknet, özellik çıkarımı için giriş verilerini işler ve ağırlı temel özniteliklerini çıkarır. Ayrıca, omurga üzerindeki ESA (Efficient Spatial Attention) katmanı, giriş görüntüsünün farklı ölçeklerdeki öznitelik bilgilerini çıkarmak için kullanılır. Bu sayede, ağırlı daha geniş bir bağlamda nesnelere algılanması ve sınıflandırması mümkün olur. Boyun kısmında özel bir mimari olan PANet (Path Aggregation Network) kullanılmaktadır. PANet, omurga tarafından sağlanan görüntü özelliklerini etkili bir şekilde bir araya getirir ve farklı görüntü bölgelerindeki bu özellikleri birleştirerek öznitelik haritası oluşturur. CSPDarknet'ten gelen temel öznitelik haritaları, PANet'in etkisiyle daha da zenginleştirilir ve karmaşık görüntülerin algılanmasına olanak tanır. Ayrıca, PANet öznitelik haritalarını tahmin katmanına taşınmadan önce düzenleyerek nesne sınıflandırma ve konumlandırma görevlerinde daha hassas ve doğru sonuçlar elde edilmesine katkıda bulunur. Baş kısmında ise, YOLO

katmanı, öznitelik haritasını kullanarak nesne tespiti görevini gerçekleştirir. Bu katman, her bir sınırlayıcı kutu için koordinatları ve sınıf olasılıklarını çıkararak nesnelerin konumlarını ve sınıflarını tahmin eder [77,78,84].

Bu üç katmanın birleşimi, giriş resmindeki nesnelerin tespiti ve sınıflandırılması için CSPDarknet özellik çıkarımını yapar, PANet bu özellikleri birleştirir ve YOLO katmanı sınıf, puan, nesnenin konumu ve boyutu gibi çeşitli çıktıları sağlayarak nesne algılama görevini tek bir model içinde tamamlar [77]. YOLOv5 mimarisinin genel gösterimi Şekil 4.5'te verilmiştir.



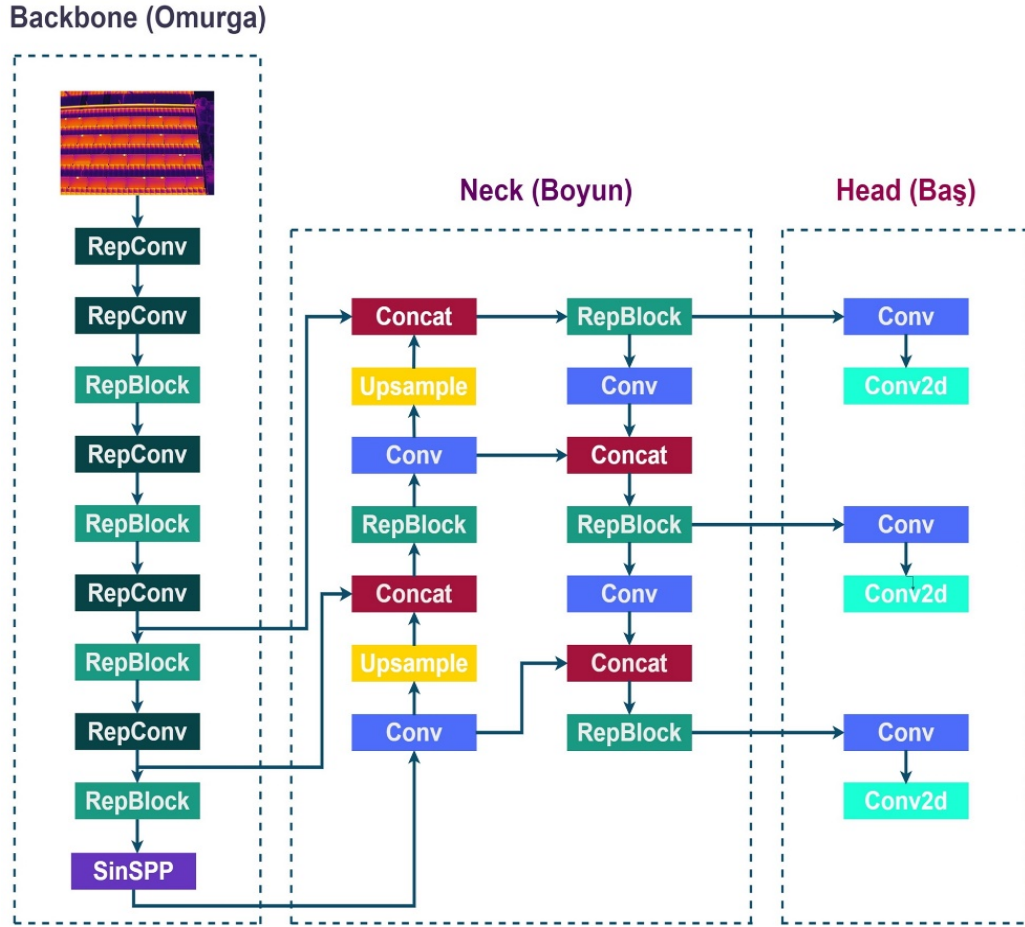
Şekil 4. 5. YOLOv5 mimari model [78]

YOLOv5 algoritması, boyut ve model parametrelerinin miktarına göre artan dört farklı ağ modeli mimarisine ayrılabilir. Bunlar; YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x mimarileridir. Bu mimariler arasında YOLOv5s ağı en hızlı hesaplama hızına ve en

düşük ortalama kesinlik özelliğine sahiptir. YOLOv5x ağı ise YOLOv5s ağının tam tersi özelliğine sahiptir [78]. Ayrıca, bu ağ modelinin önceki sürümlere kıyasla algılama doğruluğu ve hızı oldukça yüksektir [77].

3.6.3. YOLOv6 Algoritması

YOLOv6 modeli, Meituan Görsel Zekâ Departmanı tarafından 2022 yılında “YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications” adlı makale ile tanıtıldı [85]. YOLOv6 modeli, çoklu nesnelere üzerinde iyi bir algılama performansı ve yüksek çıkarım hızı ile önerilmiştir [86]. YOLO serisinin yeni ve geliştirilmiş bir versiyonu olup daha yüksek doğruluk, daha hızlı performans ve daha fazla ölçeklenebilirlik özelliği sunmaktadır. Ayrıca, Python programlama dili kullanılarak PyTorch kütüphanesi ile yazılmıştır [77]. YOLOv6 modeli, omurga (backbone), boyun (neck) ve baş (head) yapısını donanıma göre yeniden tasarlayarak çeşitli iyileştirmeler ve yeni yöntemler ile sunulmuştur [85]. YOLO mimarilerinden daha az parametre kullanarak daha yüksek doğruluk elde etmek için EfficientRep tabanlı yeni bir omurga tasarlanmıştır. EfficientRep omurga, donanımın bilgi işlem gücünden yeterince yararlanarak çıkarım gecikmesinde önemli bir azalma sağlarken aynı zamanda temsil yeteneğini de artırmaktadır [85,87]. Boyun kısmında, Rep-PAN mimarisi kullanılmıştır. Omurgadan gelen özellik haritalarını birleştirerek çok ölçekli bir piramit yapısı oluşturur. Bu sayede, küçük ve orta uzaklıktaki nesnelere daha iyi algılanmasını sağlamaktadır [87]. Baş kısmı, sınıflandırma ve konumlandırma dallarını ayırarak, hesaplama maliyeti düşük ve çıkarım gecikmesi az olan bir yapıdır. Nesne tespit etmek için çapa içermeyen bir dedektör benimsemektedir. Bu dedektör, sabit boyutlu çapalar yerine, nesne sınırlayıcı kutularının dört kenarına olan uzaklığı tahmin eder. Bu sayede, nesne tespitinin farklı görüntülerde ve koşullarda doğru sonuçlar elde etmesini sağlamaktadır [85,87]. YOLOv6 mimarisinin genel gösterimi Şekil 4.6’da verilmiştir.

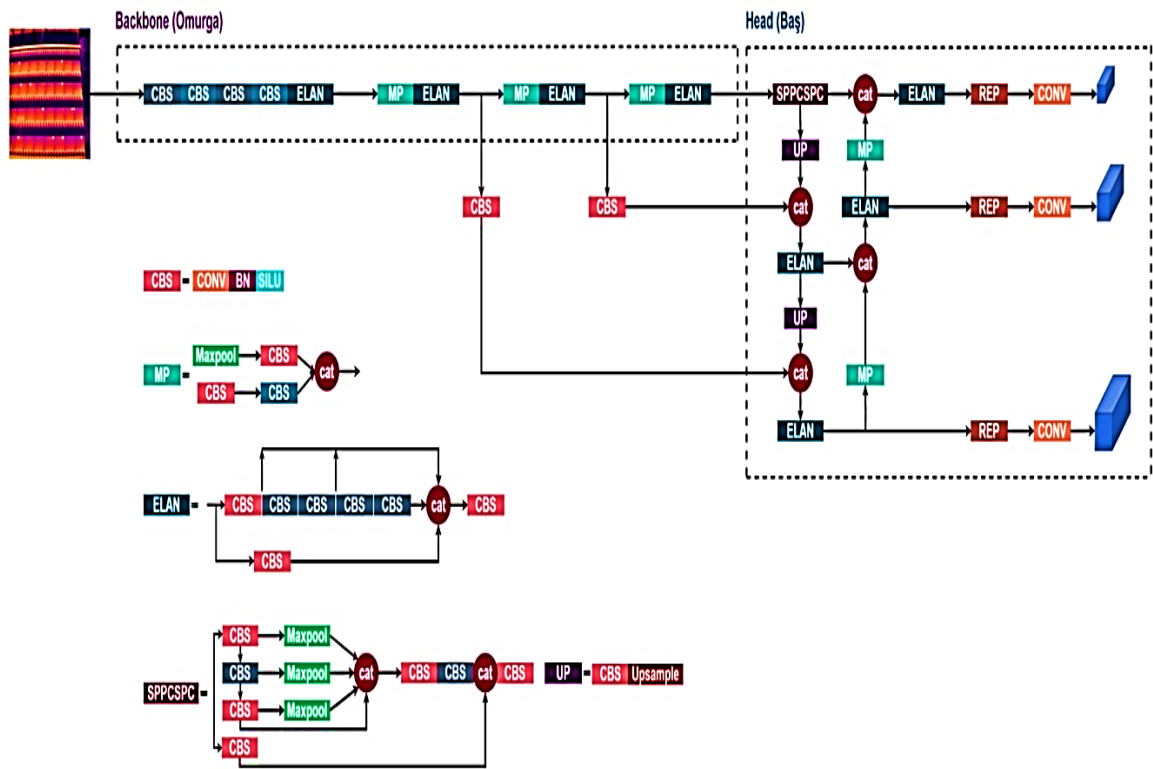


Şekil 4. 6. YOLOv6 mimari modeli [86]

3.6.4. YOLOv7 Algoritması

YOLOv7 algoritması, OpenCV AI Kit (OAK) tarafından geliştirilen bir sürümdür ve ilk olarak 2022 yılının temmuz ayında piyasaya sürülmüştür [88]. YOLO serisi algoritması içinden geliştirilmiş algılama hızı en hızlı ve en doğru gerçek zamanlı nesne dedektörü olduğu iddia ediliyor [89]. YOLOv7 uçtan uça gerçek zamanlı YOLOv5'e benzer bir yapıya sahiptir. Ancak YOLOv7 de evrişimli katmanlar kullanır ve bu da YOLOv7'yi evrişimli bir ağ yapar [90]. YOLOv7 algoritması, PyTorch kütüphanesi ile geliştirilmiştir. Ayrıca derin öğrenme modelinin oluşturulması ve eğitilmesi için TensorFlow derin öğrenme çerçevesinde kullanılabilir. PyTorch çerçeve algoritması akademisyenlerin araştırmalarında, TensorFlow çerçeve algoritması ise mühendislerin uygulama geliştirmesinde elverişlidir [90]. YOLOv7 ağ mimarisi girdi, omurga (backbone) ve baş (head) kısmı olmak üzere üç ana bölümden oluşmaktadır [91]. Girdi kısmında, modele aktarılan görüntüler veya videolardan oluşmaktadır. Giriş resmi, veri geliştirme yoluyla

önceden işlenerek özellik çıkarımı için omurgaya girer. Omurga kısmında, girdi verilerinden özellik çıkarımında kullanılan önceden eğitilmiş bir ağıdır [91,92]. YOLOv7 algoritmasının ağ modelinin omurga ağı temel olarak evrişim, ELAN modülü, MPCConv modülü ve SPPCSPC modülü katmanlarından oluşur [92]. Baş kısmında, son aşamadaki işlemler gerçekleştirilir. Katman özellik haritalarına sınırlayıcı kutuları uygulanarak çıktılar oluşturulmaktadır. Bu çıktılar: nesne etiketleri, sınırlayıcı kutu çizimleri ve nesne tespit skorlarıdır [91]. YOLOv7 mimarisinin genel gösterimi Şekil 4.7’de verilmiştir.

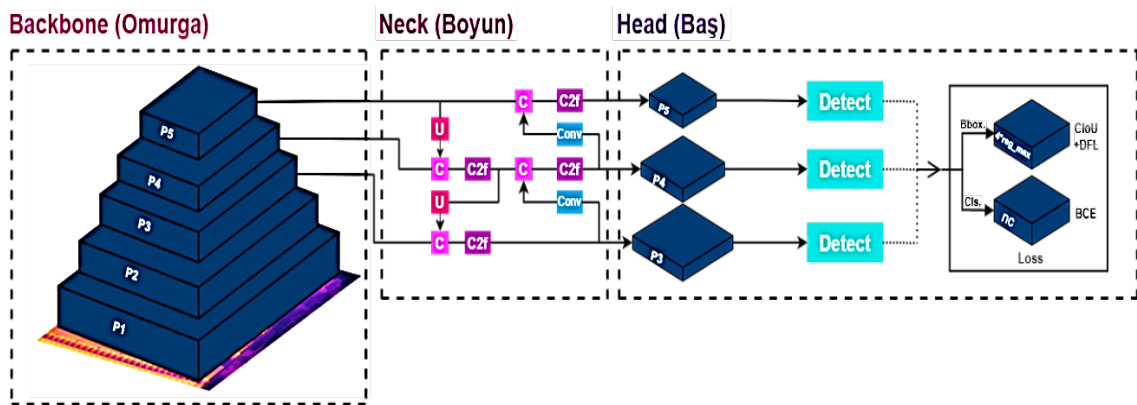


Şekil 4. 7. YOLOv7 mimari modeli [93]

3.6.5. YOLOv8 Algoritması

Ocak 2023'te YOLOv5'i geliştiren Ultralytics şirketi tarafından piyasaya sürüldü [94]. YOLOv8 algoritması, yüksek doğruluk ve hız elde ettiği kanıtlanmış son teknoloji bir nesne algılama modelidir [95]. YOLOv8 algoritmasının ağ mimarisi omurga (backbone), boyun (neck) ve baş (head) kısmı olmak üzere üç ana birleşenden oluşmaktadır [96]. YOLOv8 algoritması yeni bir mimariye, iyileştirilmiş evrişimli katmanlara omurga ve daha gelişmiş bir algılama kafasına sahiptir [95]. Omurga, giriş görüntüsünün öznitelik

haritalarını çıkarır. YOLOv8 omurga ağı, katmanlar arasındaki bilgi akışını iyileştiren ve modeldeki parametre sayısını azaltan Cross Stage Partial (CSP) mimarisini temel alır. CSP, ağın derinliğini ve genişliğini artırarak performansını iyileştirmeye yardımcı olur. Ayrıca, CSP mimarisıyla hesaplama maliyetini azaltmasını sağlamaktadır [96]. YOLOv8 algoritması, özellik çıkarma sürecini iyileştirmek için YOLOv7 ağından daha hızlı ve daha hassas olan Darknet-53 omurga ağını kullanır. Darknet-53, 53 katmanlı evrişimli bir sinir ağıdır ve evrişimsel ağı nedeniyle önceki sürümlerden daha etkilidir [95,97]. Boyun kısmında, omurgadan gelen öznitelik haritalarını işleyerek ve farklı ölçeklerdeki nesnelere algılamak için birleştiren bir bileşendir. YOLOv8, boyun için Feature Pyramid Network (FPN) ve Path Aggregation Network (PAN) mimarileri kullanılmıştır. YOLOv5'ten ilham alınarak, FPN'nin üstten alta özellik bilgisini artırmak için üst örneklem (upsample) işlemi gerçekleştirdiği, PAN'ın ise alttan üste doğru özellik bilgisi elde etmek için alt örneklem (downsample) işlemi gerçekleştirdiği belirtiliyor. Bu iki özellik çıkışı, çeşitli boyutlardaki görüntüler için kesin tahminleri sağlamak amacıyla birleştirilir [98]. Baş, giriş görüntüsündeki her nesnenin konumunu ve sınıfını tahmin eder [96]. YOLOv8 algoritması nesne algılama doğruluğunu ve hızını iyileştiren bir modeldir. YOLOv8 mimarisi boyut ve model parametrelerinin miktarına göre artan beş ağ modeli mimarisine ayrılmaktadır. Bunlar; YOLOv8n-seg, YOLOv8s-seg, YOLOv8m-seg, YOLOv8l-seg ve YOLOv8x-seg mimarileridir [97]. YOLOv8 mimarisinin genel gösterimi Şekil 4.8'de verilmiştir.




Şekil 4. 8. YOLOv8 mimari modeli [96]

3.7. Pksel Tabanlı Segmentasyon Modelleri

Pksel seviyesinde hata tespitine dayalı geliştirilen yöntemler, görüntülerdeki hataların tam olarak konumlarını pksel seviyesinde tespit etmektedir. Bu yaklaşımda, bölge seviyesinde hata tespit yaklaşımına göre hata konumu net olarak ortaya koyulmaktadır. Bu sayede küçük veya düzensiz yüzey hataları net bir şekilde tespit edilebilmektedir. Pksel seviyesinde yüzey hata tespiti için genellikle U-Net ve U-Net tabanlı hibrit modeller kullanılmıştır.

3.7.1. U-Net

U-Net, biyomedikal görüntü bölütleme için geliştirilen bir CNN modelidir [99]. Bu model, 2015 yılında Olaf Ronneberger, Philipp Fischer ve Thomas Brox tarafından “U-Net: Convolutional Networks for Biomedical Image Segmentation” makalesiyle tanıtılmıştır. U-Net mimarisi, U harfine benzeyen bir yapıya sahiptir. U-Net, giriş görüntüsünü U şeklindeki mimari ile işleyerek, görüntünün her bir pkselinin hangi sınıfa ait olduğunu belirlemektedir [100]. Şekil 4.9’da U-Net mimarisi gösterilmiştir.



Şekil 4. 9. U-Net mimarisi [99]

U-Net mimarisi simetrik olup sol tarafında daralan yol ve sağ tarafında genişleyen bir yoldan oluşmaktadır. Sol tarafı, giriş görüntüsünden öznitelik çıkaran kodlayıcı (encoder), sağ tarafı ise öznitelikleri birleştirerek çıktı görüntüsünü oluşturan kod çözücüden (decoder) oluşmaktadır. Kodlayıcı bölümü, giriş görüntüsünden öznitelik çıkarmak için evrişim katmanları ve maksimum havuzlama katmanlarından oluşur. Her adımda, iki 3x3 evrişim katmanı, bir ReLU aktivasyon fonksiyonu ve bir 2x2 maksimum havuzlama katmanı işlemi uygulanır. Kodlayıcının ilk katmanında 64 adet öznitelik haritası kullanılmaktadır. Kodlayıcının sonraki katmanlarında öznitelik haritası sürekli olarak iki katına çıkar ve görüntünün boyutu küçülür. Kod çözücü bölümü, öznitelikleri birleştirerek çıktı görüntüsünü oluşturmak için yukarı evrişim katmanları ve evrişim katmanlarından oluşur. Her adımda, bir 2x2 yukarı evrişim katmanı, kodlayıcıdan gelen özellik haritasıyla birleştirme işlemi ve iki 3x3 evrişim katmanı uygulanır. Kod çözücünün ilk katmanında 1024 adet öznitelik haritası kullanılmaktadır. Kod çözücünün sonraki katmanlarında öznitelik haritası sayısı sürekli olarak yarıya iner. Son katmanda, bir 1x1 evrişim katmanı ile her 64 bileşenli öznitelik vektörü istenen sınıf sayısına eşlenir. Bu ağ içerisinde 23 tane evrişimsel katman bulunmaktadır [99].

5. VERİ SETİ

3.8. Veri Setlerinin Analiz Edilmesi

Yenilenebilir enerji sistemleri içerisinde, güneş panellerine olan artan talep sonucunda, çeşitli arızalar ve bunların sonucunda oluşan verim kayıpları gözlemlenmiştir. Bu arızaları tespit etmek için çeşitli yöntemler mevcuttur. Sistemlerdeki verim kayıplarını minimize etmek adına, güneş enerji panellerinin bakımlarının düzenli aralıklarla yapılması önemlidir. Sayıca fazla olan PV sistemlerin arızalarının bireysel olarak tespiti, mevcut insan gücü ile yetersiz kalmaktadır. Ayrıca, güneş panellerinin coğrafi konumlarından kaynaklanan ulaşım zorlukları, PV sistemlerin bakım, onarım ve kontrol sürelerini geciktirmektedir. Bu nedenle, PV panellerinin testlerinin daha hızlı ve kolay bir şekilde yapılabilmesi amacıyla termografi yöntemi kullanılmaktadır. Termografi yöntemi, güneş panellerinin yüzey sıcaklığını uzaktan algılayarak, potansiyel arızaların erken tespit edilmesini sağlamaktadır.


Bu çalışmadaki veriler Elazığ ili ve çevresinde bulunan güneş enerji santrallerinden alınmıştır. Veri seti, bir güneş tarlasındaki PV panellerinden toplanan 388 adet termal görüntülerden oluşmaktadır. Bu görüntüler, DJI Mavic 2 Enterprise Dual termal kameralı drone kullanılarak elde edilmiştir. DJI Mavic 2 Enterprise Dual, endüstriyel ve acil durum operasyonları için özel olarak tasarlanmış bir drone modelidir. Bu model zorlu arazi koşullarında ve kritik operasyonlarda kullanıcıya büyük avantajlar sağlamaktadır. Ayrıca, FLIR termal sensörleri ile donatılmış olup, yüksek çözünürlüklü termal ve görsel kameraların bir arada sunulduğu çift kameralı bir sistemle donatılmıştır. Şekil 5.1’de DJI Mavic 2 Enterprise Dual termal kameralı drone gösterilmiştir.



Şekil 5.1. DJI Mavic 2 Enterprise Dual termal kameralı drone

Termal kamera, 640×512 piksel çözünürlüğünde 30Hz kare hızında termal görüntüleme yapabilir ve 1/2.3 CMOS sensör ve 48 MP etkin piksel görüntü çözünürlüğüne sahip görsel kamera özelliğine sahiptir. Ayrıca, $16\times$ optik ve $32\times$ dijital zoom yapabilme yeteneği ile geniş alanları tarayabilir ve RTK modülü ile santimetre düzeyinde konumlandırma doğruluğu bulunmaktadır. Bu özellikler, termal görüntülerin yüksek çözünürlükte ve doğrulukta olmasını sağlayarak, arıza tespitindeki hassasiyeti artırmaktadır. Ayrıca, bu drone -10°C ile 40°C arasındaki çalışma sıcaklıklarında etkili bir şekilde görev yapabilmektedir.

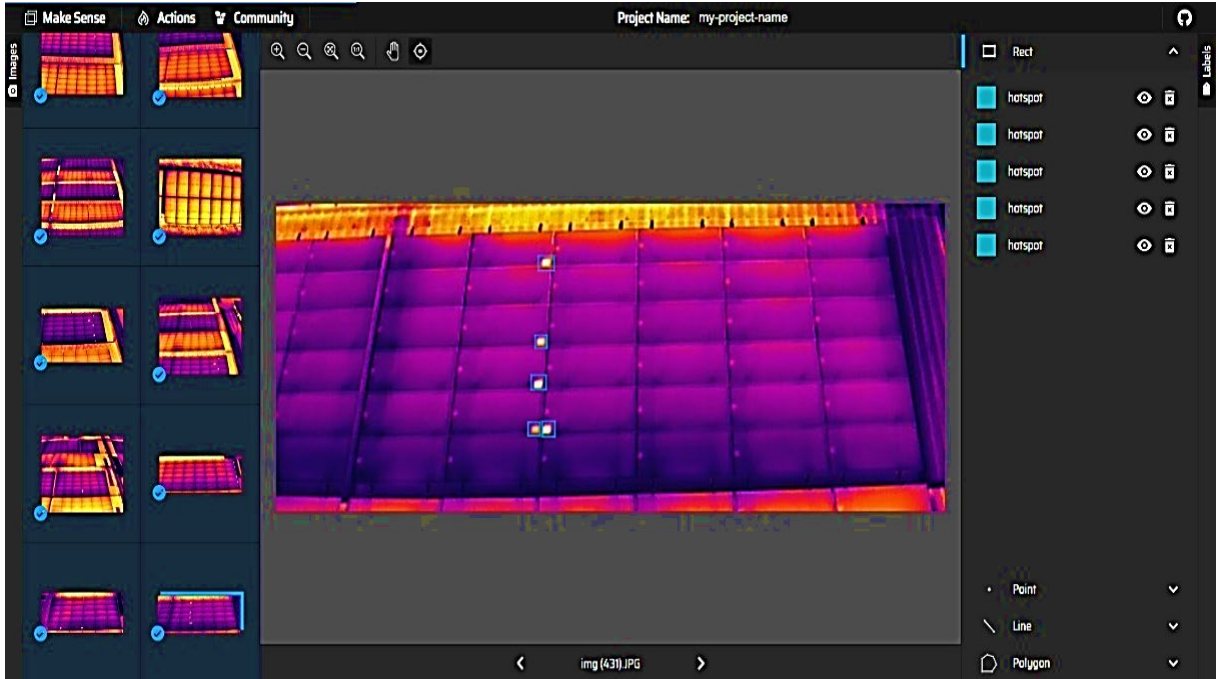
Güneş panellerinin arıza tespiti için DJI Mavic 2 Enterprise Dual termal kameralı drone kullanılarak elde edilen 388 görüntü ile özgün bir veri seti oluşturuldu. Bu veri seti, gerçek dünya koşullarında çekilmiş yüksek çözünürlüklü güneş paneli görüntülerinden oluşmaktadır. Veri seti, farklı güneş paneli türlerini içermektedir. Hotspot arızası için veri setinde toplamda 100 adet ve bypass diyot arızası için toplamda 288 adet güneş paneli arızalı görüntüsünden oluşmaktadır. Her görüntü, ışık koşullarının ve çevresel faktörlerin değişebileceği gerçek dünya senaryolarını yansıtmaktadır. Görüntüler farklı açılardan çekilmiş ve farklı çözünürlüklerde mevcuttur. Her görüntü, bir veya daha fazla hotspot ve bypass diyot arızası içermektedir. Arızalar, farklı büyüklüklere, şekillere ve konumlara sahiptir. Elde edilen veri setindeki örnek görüntüler Şekil 5.2’de verilmiştir.



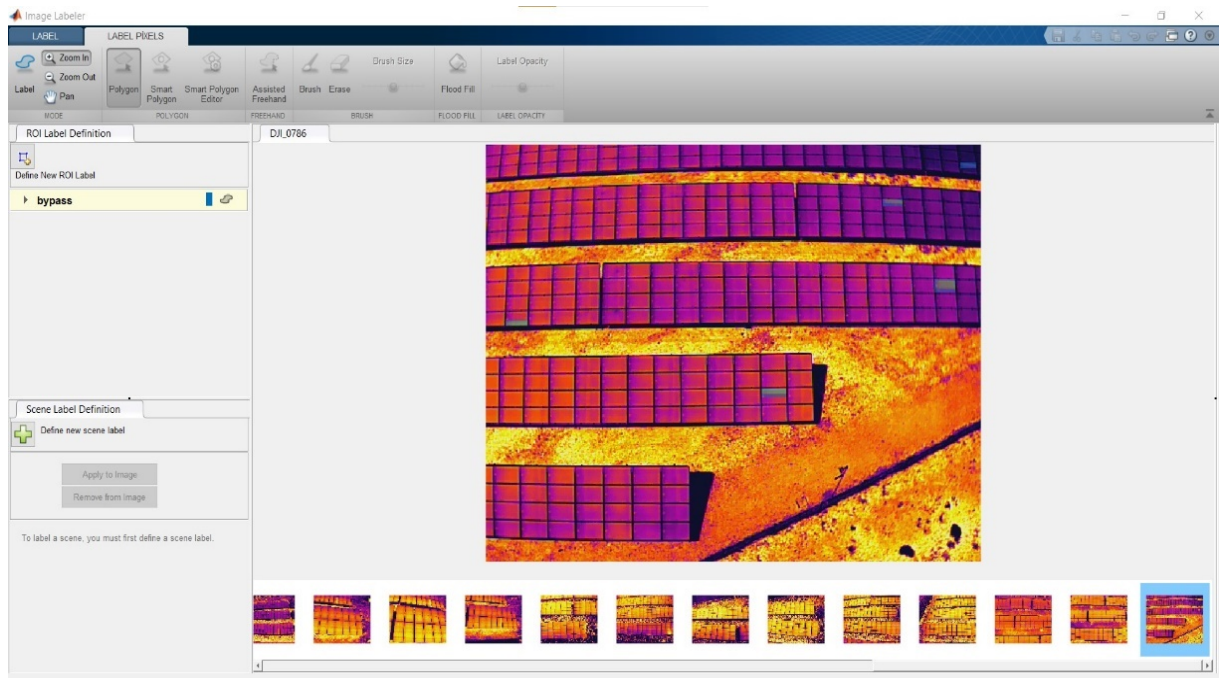
Şekil 5.2. Veri setindeki örnek görüntüler

3.9. Veri Setlerinin Etiketlenmesi

CNN tabanlı bölgesel (YOLO) ve piksel tabanlı (U-Net) algoritmalarının veri setini doğru bir şekilde tanıyabilmesi için, kullanılan görüntülerin hassas bir şekilde sınıflandırılması gerekmektedir. Bu sınıflandırma işlemine etiketleme denir. Etiketleme işlemi, veri setindeki görüntülerde bulunan nesnelerin tanımlanması, bu nesnelerin sınırlarının belirlenmesi ve açıklamaların eklenmesi sürecidir. Veri setinin etiketlenmesi sırasında, fotovoltaik panellerin hücrelerindeki hotspot arızaları için MakeSense isimli veri etiketleme programı, modüllerdeki bypass diyot arızaları için ise MATLAB'ın Image Labeler aracı kullanılmıştır. MakeSense veri etiketleme programı ile fotovoltaik panellerde hotspot arızası bulunan 100 adet arızalı görüntü, MATLAB'ın Image Labeler etiketleme aracı ile ise bypass diyot arızası bulunan 288 adet arızalı görüntü etiketlenmiştir. MakeSense veri etiketleme programı ve MATLAB'ın Image Labeler etiketleme aracı kullanılarak, görüntülerde bulunan hotspot ve bypass diyot arızalı pikseller işaretlenmiş ve bu arızaları tanımlamak için sınırlayıcı kutular oluşturulmuştur. Bu kutulara, etiketler ve arıza türleri açıklamaları eklenmiştir. Etiketleme işleminin bitmesinin ardından YOLO ve U-Net algoritmalarında eğitim işlemine geçilmektedir. Şekil 5.3'te hotspot arızası için MakeSense programı ile yapılan etiketleme, Şekil 5.4'te ise bypass diyot arızası için MATLAB'ın Image Labeler aracı ile yapılan etiketleme işlemi gösterilmiştir.



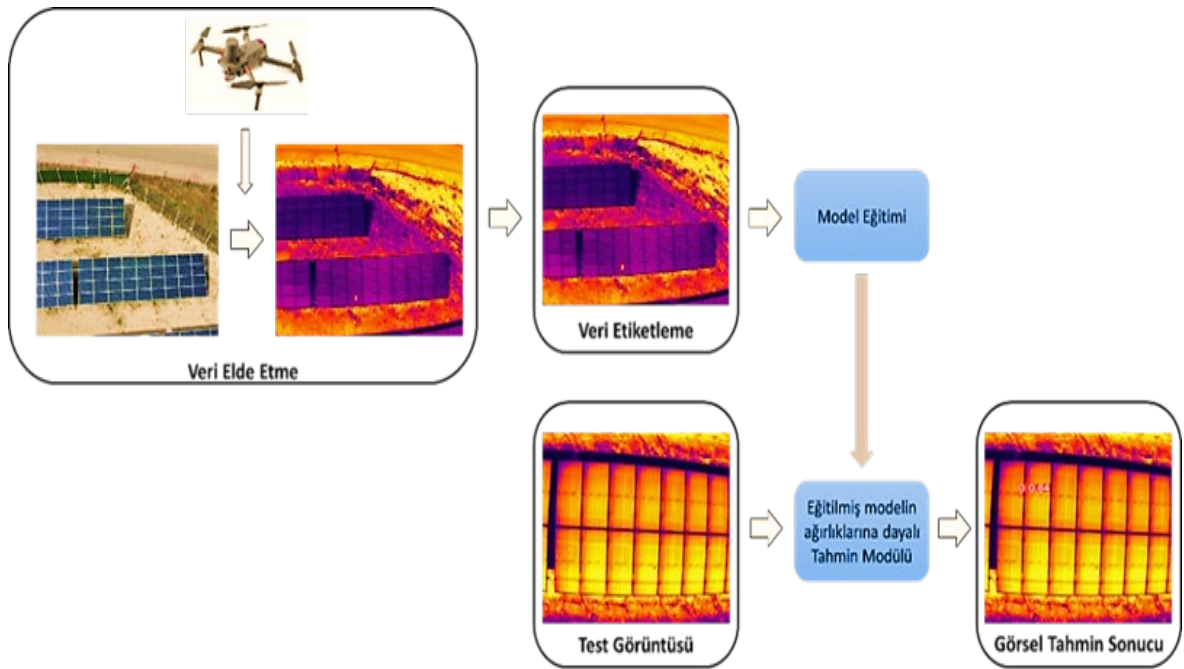
Şekil 5.3. Hotspot arızası MakeSense Etiketlenmesi



Şekil 5.4. Bypass diyot arızası MakeSense Etiketlenmesi

6. BULGULAR VE TARTIŞMA

Bu bölümde, bir önceki bölümde detaylandırılan veri seti, bölgesel ve piksel tabanlı yöntemlere yönelik hotspot ve bypass diyot tespiti için yapılan çalışmanın deneysel çalışması ve sonuçları hakkında bilgiler verilmektedir. Yapılan deneysel çalışmanın genel akış diyagramı genel akış diyagramı Şekil 6.1’de verilmiştir.



Şekil 6.1. Yapılan çalışmanın genel akış diyagramı

Deneysel çalışmalarda, Python yazılım platformunu, 128 GB RAM ve NVIDIA Quadro P6000 grafik kartı ile donatılmış yüksek performanslı bir iş istasyonunu kullanıldı.

3.10. Hotspot Hata Tespiti

Bu çalışmada, güneş enerjisi santrallerindeki PV modüllerinde sıcak nokta tespiti amacıyla YOLO algoritmalarının etkinliği ve avantajları incelenmiştir. Araştırmada, YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 algoritmalarının performansları karşılaştırılmış ve en yüksek başarıyı sağlayan model belirlenmiştir. Deneyler sonucunda,

insansız hava aracı ile elde edilen 100 görüntünün %80'i eğitim kümesi, %20'si ise test kümesi olarak kullanılarak YOLO algoritmalarının karşılaştırmaları yapılmıştır. Ayrıca, eğitim kümesindeki görüntü sayısını artırmak için yatay ve dikey dönüşüm, parlaklık değişimi ve görüntü döndürme gibi veri artırma teknikleri uygulanmış ve toplamda 240 görüntü elde edilmiştir. Bu yöntemle, modelin daha iyi eğitilmesi ve test performansının artırılması hedeflenmiştir.

Deneysel çalışmalarda, YOLO algoritmalarının performansını değerlendirmek için Duyarlılık, Özgüllük ve Ortalama Duyarlılık (mAP) değerleri kullanılmıştır. Bu değerler ile ilgili matematiksel formüller Denklem (1-3)'de verilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (6.1)$$

$$\text{Özgüllük} = \frac{TP}{TP+FP} \quad (6.2)$$

$$\text{mAP} = \frac{1}{n} \sum_{k=1}^n AP_k \quad (6.3)$$

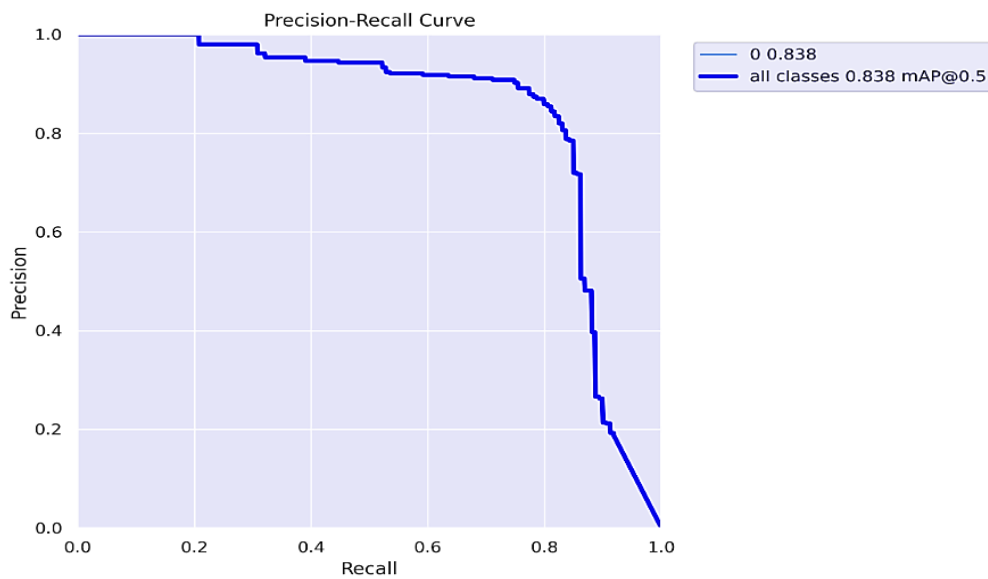
Burada TP karmaşıklık matrisindeki doğru pozitiflerin, FP hatalı pozitiflerin ve FN hatalı negatiflerin sayılarını göstermektedir.

Güneş panellerindeki sıcak nokta kusurlarının tespiti amacıyla uyarlanan YOLO algoritmalarının eğitim aşamasında, eğitim tur sayısı (epoch) 100, parti boyutu (batch size) 16, öğrenme hızı (learning rate) 0.0001 ve optimizasyon algoritması olarak Stochastic Gradient Descent (SGD) parametreleri kullanılmıştır. Bu deneysel çalışmanın sonuçları, performans değerlendirme kriterlerine göre Tablo 6.1'de sunulmuştur.

Tablo 6. 1. YOLO modellerinin performansları (%)

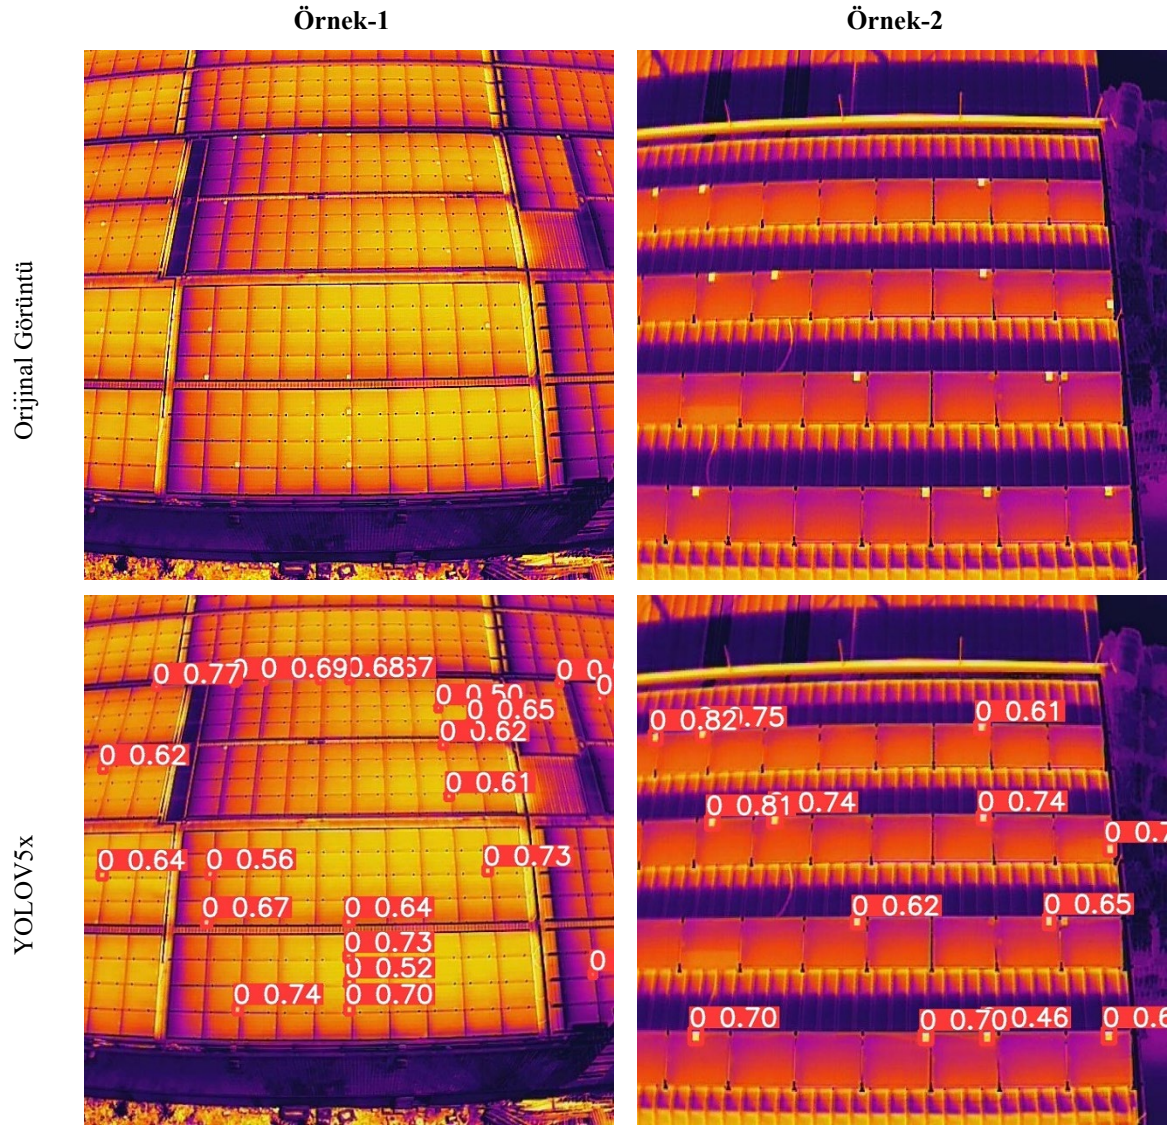
Model	Versiyon	Özgüllük	Duyarlılık	mAP@.5
YOLOV5	X	62,60	53,50	52,90
	X6	87,40	65,30	75,20
YOLOV6	M	-	-	59,98
	L6	-	-	67,46
YOLOV7	X	72,54	69,77	68,79
YOLOV8	N	80,20	76,30	79,00
	M	87,30	73,50	78,50
	X	88,70	80,50	83,80

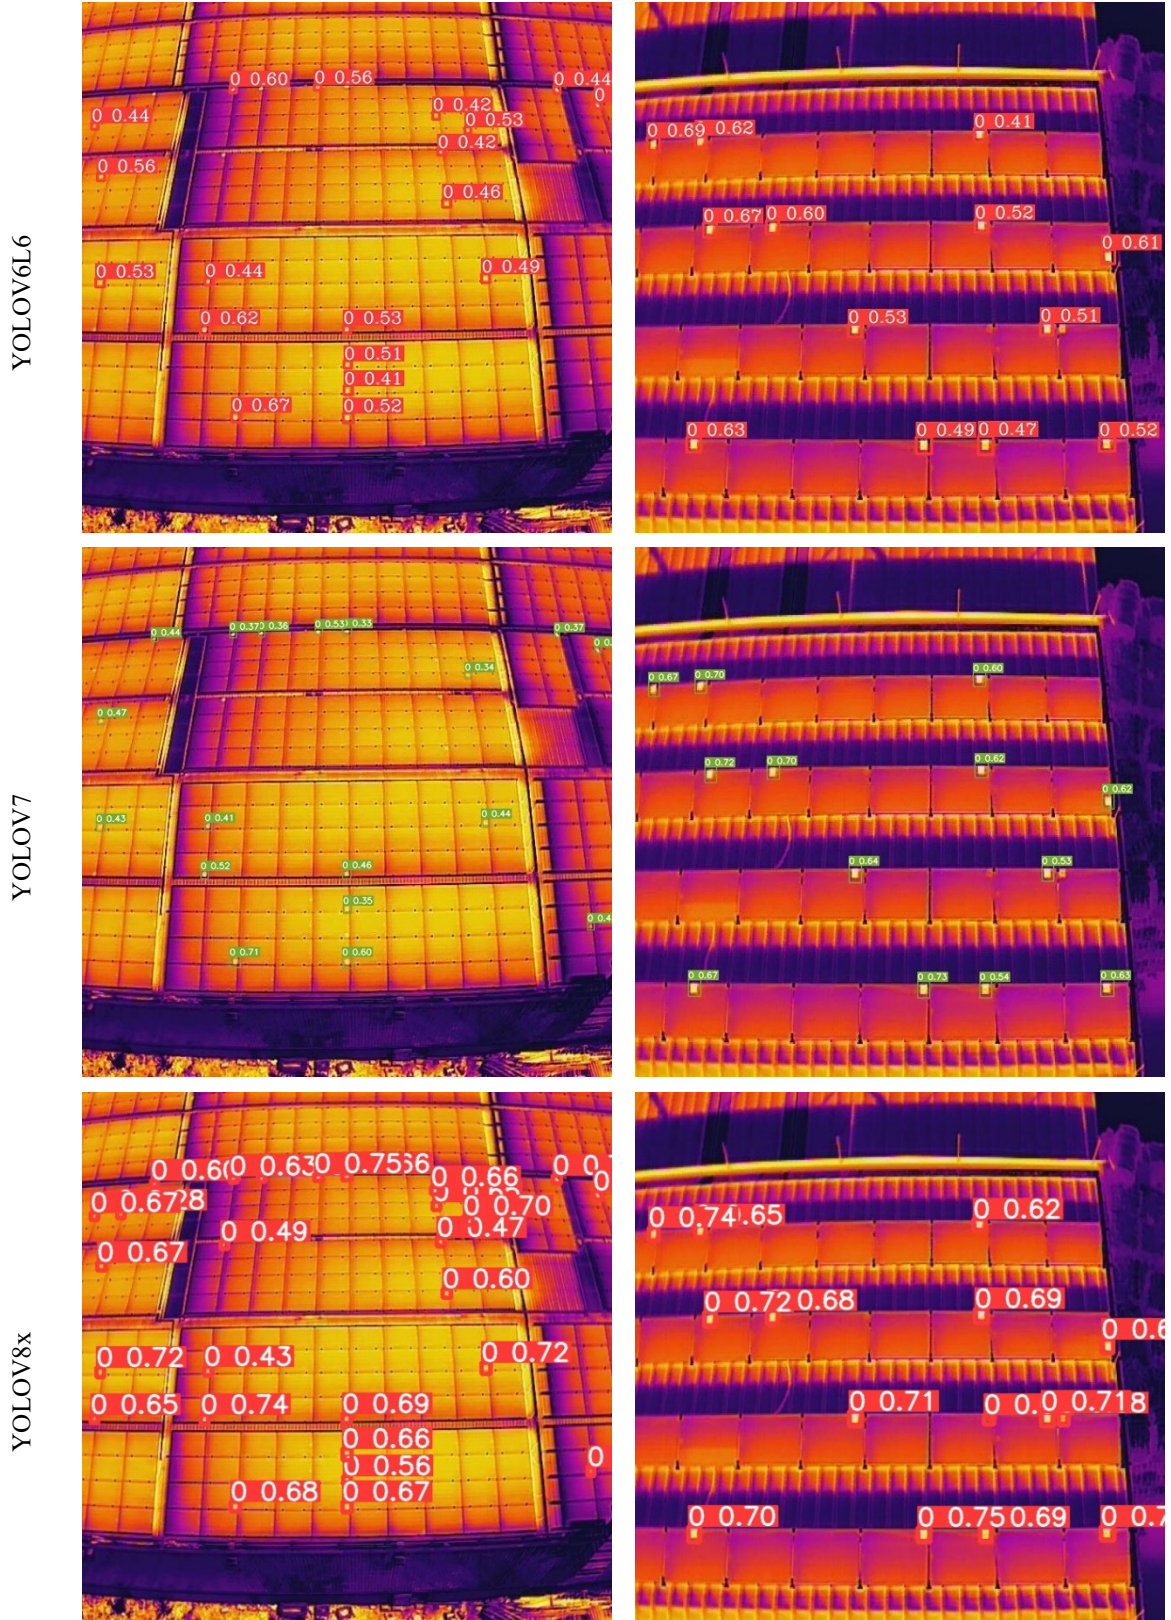
Tablo 6.1'de, YOLO algoritmasına dayalı YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 modellerinin ve bu modellere ait versiyonların performans sonuçları sunulmuştur. Bu sonuçlara göre, en iyi performans YOLOv8x modeli ile elde edilmiş olup, %88,7 özgüllük, %80,5 duyarlılık ve %83,8 mAP değerlerine ulaşılmıştır. İkinci en iyi performans ise YOLOv5x modeli tarafından sergilenmiştir. Ayrıca, tüm YOLO modellerinin performans sonuçları incelendiğinde, en kapsamlı versiyonlarının en yüksek performansı gösterdiği görülmüştür. En yüksek performansa sahip olan YOLOv8x modelinin özgüllük-duyarlılık eğrisi ise Şekil 6.2'de gösterilmiştir.



Şekil 6.2. Önerilen modelin özgüllük-duyarlılık eğrisi


Tablo 1'de belirtilen YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 modellerinin en yüksek performans gösteren versiyonlarına ait görsel sonuçlar Şekil 6.3'te sunulmuştur.





Şekil 6.3. YOLO modellerinin görsel tahmin sonuçları

Şekil 6.3’de görüleceği üzere, en iyi performansı gösteren YOLOv8x modeli, neredeyse tüm sıcak nokta hatalarını doğru bir şekilde tespit etmiştir. Veriler detaylı incelendiğinde, tespit sonuçlarının %0 ile %75 arasında dağıldığı gözlemlenmiştir. Bu sonuçlar, modelin tek bir sınıfı (var/yok) tespit etme görevini başarıyla yerine getirdiğini göstermektedir. Bu değerlendirme, modelin güneş panellerini başarıyla tespit etme yeteneğini ortaya koymaktadır. Ayrıca, %50’nin üzerindeki tespit sonuçları, modelin görevini etkin bir şekilde yerine getirdiğini ve güneş panellerini doğru şekilde tanımladığını göstermektedir. Bu bulgular, modelin sıcak nokta kusurlarını tespit etmedeki başarı ve güvenilirliğini vurgulamaktadır. Ayrıca, modelin eğitim ve kayıp grafiklerine Şekil 6.4’te yer verilmiştir.



Şekil 6. 4. YOLOv8 modelinin eğitim/kayıp grafikleri

Şekil 6.4’te sunulan grafiklerden anlaşılacağı üzere, modelin doğruluğunu artırma ve kaybı azaltma yönünde olumlu bir eğilim gözlenmektedir. Grafikler incelendiğinde, eğitim sürecinin başlangıcından itibaren modelin hızla öğrenmeye başladığı ve bu öğrenmenin 100 iterasyon sonrasında yavaşladığı görülmektedir. Ayrıca, grafikler modelin öğrenme hızının başlangıçta daha yüksek olduğunu ve zamanla yavaşladığını göstermektedir.

Deneysel çalışmalar kapsamında, modelimizin performansını çeşitli açılardan değerlendirmek için iki farklı yaklaşım benimsendi. İlk olarak, veri seti %80 eğitim ve %20 test olarak bölündü ve modelin bu veri seti üzerindeki performansı incelendi. Bu yaklaşım, modelin temel performansını belirlememizde önemli bir rol oynadı. İkinci olarak, daha fazla güvenilirlik sağlamak amacıyla 10 kat çapraz doğrulama yöntemi kullanıldı. Her bir çapraz doğrulama katmanı, veri setini 10 eşit parçaya böldü ve her bir parça sırayla test verisi olarak kullanıldı, geri kalanlar ise eğitim verisi olarak kullanıldı. Bu yöntem, modelin performansının varyasyonunu daha ayrıntılı bir şekilde analiz etmemizi sağladı. YOLOv8 algoritmasının performansını değerlendirdiğimizde elde ettiğimiz sonuçlar oldukça tatmin ediciydi. Bu model, güneş paneli tespiti görevinde %79 özgüllük, %78 duyarlılık ve %81 mAP gibi yüksek performans değerleri üretti. Bu sonuçlar, YOLOv8 algoritmasının güneş paneli kusurlarını etkili bir şekilde tespit edebildiğini ve güvenilir sonuçlar üretebildiğini açıkça göstermektedir. Bu başarı, güneş enerjisi santrallerindeki sıcak nokta kusurlarının tespiti konusundaki potansiyel uygulamaları daha da vurgulamaktadır.

3.11. Bypass Diyot Hata Tespiti

Bu çalışmada, güneş enerjisi santrallerindeki PV modüllerinde bypass diyot hata segmentasyonu için farklı katman derinlikleri ve filtre sayılarına sahip dört farklı U-Net modeli uygulanmıştır: U-Net-V1, U-Net-V2, U-Net-V3, U-Net-V4, U-Net-V5 ve U-Net-V6. Bu U-Net modellerinin ayrıntılı yapısı ve özellikleri Tablo 6.2'de sunulmuştur. Tablo 6.2'de her bir modelin katman derinliklerini ve filtre sayılarını göstermektedir. Katman derinliği, U-Net mimarisindeki enkoder ve dekoder bölümlerindeki konvolüsyonel ve örnekleme katmanlarının sayısını ifade etmektedir. Farklı katman derinlikleri, U-Net modellerinin çeşitli özellik çıkarım yeteneklerine sahip olmasını sağlar. Benzer şekilde, filtre sayıları da U-Net modellerinin öğrenme kapasitesini belirleyen kritik bir faktördür. Filtre sayısı, her bir katmandaki konvolüsyonel filtrelerin sayısını ifade eder. Daha yüksek filtre sayıları, daha fazla özellik haritasının üretilmesini ve daha karmaşık özelliklerin öğrenilmesini sağlar.

Tablo 6. 2. U-Net modelleri

Modeller	Filtre Sayısı	Atlama Bağlantısı	Katman Sayısı
U-Net-V1	[64,128,256]	512	3
U-Net-V2	[64,128,256,512]	1024	4
U-Net-V3	[32,64,128,256]	512	4
U-Net-V4	[32,64,128,256,512]	1024	5
U-Net-V5	[16,32,64,128,256]	512	5
U-Net-V6	[16,32,64,128,256,512]	1024	6

Farklı katman derinliklerine sahip bu U-Net modelleri, bypass diyot hata tespitinde kullanılmış ve performansları karşılaştırılmıştır. Katman sayılarındaki farklılıkların, modellerin özellik çıkarma yeteneklerini etkilediği gözlemlenmiştir.

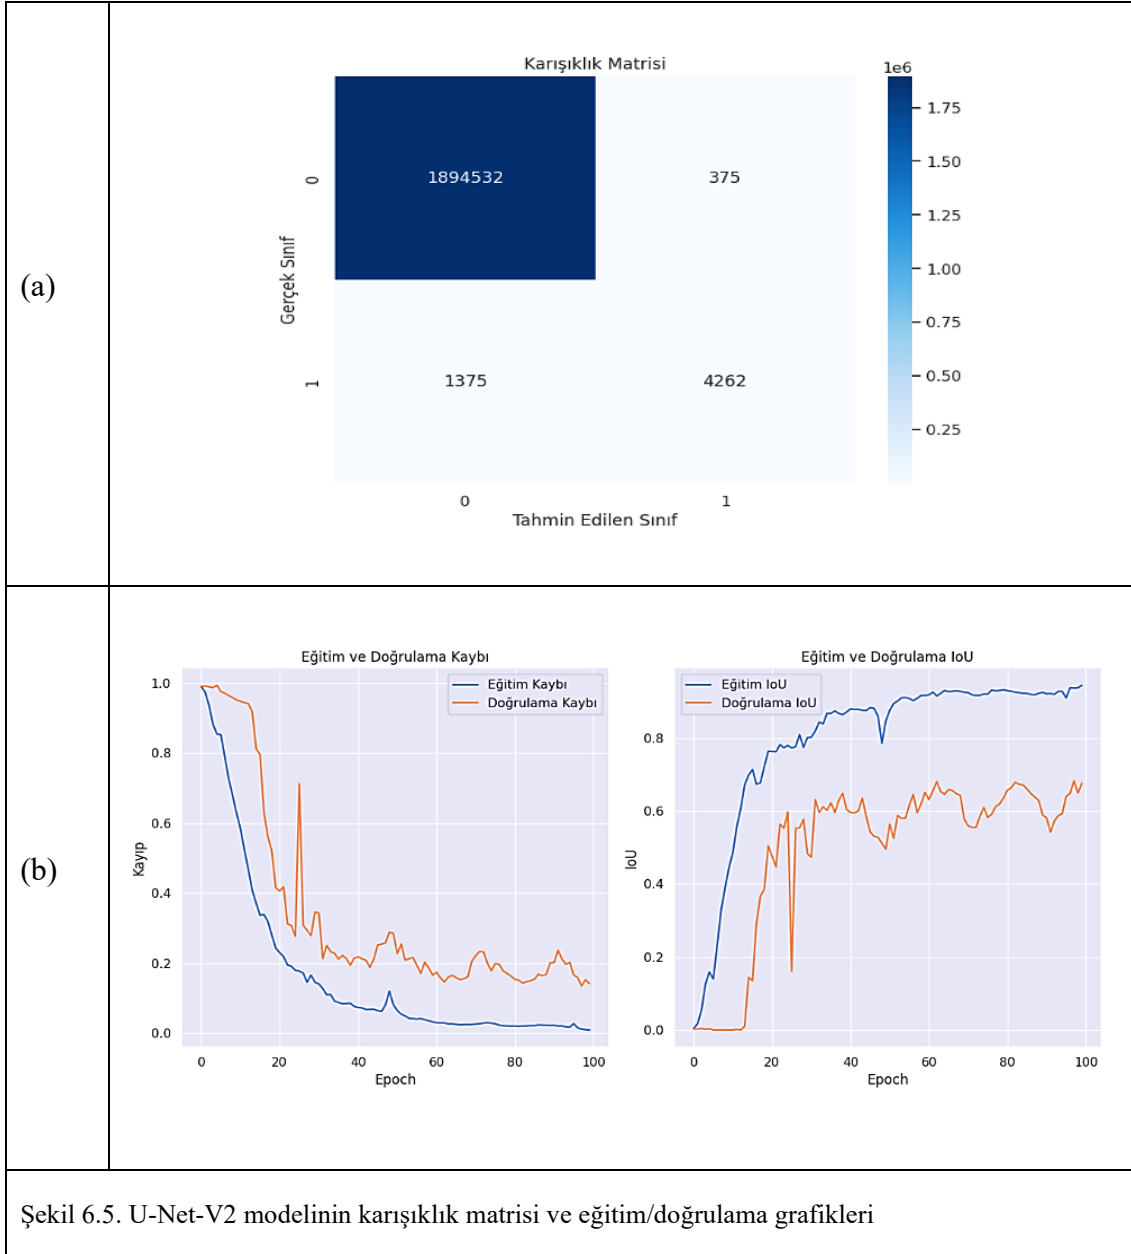
Deneysel çalışmalarda, insansız hava aracı ile elde edilen 288 görüntünün %80'i eğitim kümesi, %20'si ise test kümesi olarak kullanılmıştır. Ayrıca, eğitim kümesindeki görüntü sayısını artırmak için yatay ve dikey dönüşüm, parlaklık değişimi ve görüntü döndürme gibi veri artırma teknikleri uygulanmış ve toplamda 693 görüntü elde edilmiştir. Bu yöntemle, modelin daha iyi eğitilmesi ve test performansının artırılması hedeflenmiştir. Güneş panellerindeki bypass diyot kusurlarının tespiti amacıyla uyarlanan U-Net algoritmalarının eğitim aşamasında, eğitim tur sayısı (epoch) 200, parti boyutu (batch size) 16, öğrenme hızı (learning rate) 0.0001 ve optimizasyon algoritması olarak Stochastic Gradient Descent (SGD) parametreleri kullanılmıştır. Çalışmamızda uygulanan bu modellerin performansını değerlendirmek için F1-Score, AUC ve IOU performans parametreleri kullanılmıştır. Her bir model için bulunan performans ölçüt değerleri Tablo 6.3'te sunulmuştur.

Tablo 6. 3. Geliştirilen U-Net modellerinin performans sonuçları

Modeller	F1-Score	AUC	IOU
U-Net-V1	0.8009	0.8583	0.6679
U-Net-V2	0.8297	0.8779	0.7089
U-Net-V3	0.7693	0.8298	0.6250
U-Net-V4	0.7657	0.8330	0.6204
U-Net-V5	0.7070	0.7924	0.5468
U-Net-V6	0.6668	0.7763	0.5002

Tablo 6.3'te, farklı katman ve filtre sayılarına dayalı olarak geliştirilen U-NET mimarilerinin performans sonuçları sunulmuştur. Bu sonuçlara göre, en yüksek performans U-Net-V2 mimarisi ile elde edilmiştir; %87,79 AUC, %82,97 F1-Score ve %70,89 IOU değerlerine ulaşılmıştır. İkinci en iyi skor U-Net-V1 ile elde edilirken, en düşük performans U-Net-V6 ile kaydedilmiştir. Genel olarak, katman sayısı arttıkça performansın düştüğü gözlemlenmiştir.

Tablo 6.3'ten elde edilen sonuçlara dayalı olarak en iyi performansa sahip U-Net-V2 mimarisinin karışıklık matrisi ve loss kaybı grafikleri Şekil 6.5'te verilmiştir.



Bu sayısal sonuçlara ek olarak görsel sonuçlar Şekil 6.6’da gösterilmiştir. Şekil 6.6 incelendiğinde, bazı sonuçlarda modellerin bypass diyot bulunduğu konumu kısmen doğru tespit ettiği, ancak boyutlarda farklılıklar olduğu görülmüştür. Bazılarında ise modellerin benzer sonuçlar verdiği ve UNet-V2 modelinin daha iyi performans gösterdiği belirlenmiştir. Bu bulgular, bypass diyot hata tespitinde model seçiminin sonuçları üzerinde etkili olduğunu göstermektedir.

	0	15	24	10	19
Orjinal					
Efket					
U-Net-V1					
U-Net-V2					
U-Net-V3					
U-Net-V4					
U-Net-V5					
U-Net-V6					

Şekil 6.6. Önerilen U-Net tabanlı modellerin görsel sonuçları

7. SONUÇLAR VE ÖNERİLER

Son yıllarda, ülkemizde ve küresel düzeyde güneş panellerinin kurulum kapasitesi önemli ölçüde artmıştır. Bu artışla birlikte, güneş panellerinin verimliliğini etkileyen bakım ve onarım önlemlerine duyulan ihtiyaç da artmıştır. Güneş panelleri, çevresel faktörlerden korunması için genellikle alüminyum çerçeve ve cam laminasyon gibi yöntemlerle üretilmektedir. Ancak, bu tedbirler üretim ve kullanım süreçlerinde güvenilirlik, güç düşüşü, sert iklim koşulları, bazı çevresel faktörler ve arızalar sebebiyle yetersiz kalabilmektedir. PV sistemlerinin verimini olumsuz yönde etkileyen bu etmenleri hücre hatası, modül hatası ve panel hatası gibi kategorilere ayırabiliriz. Bu etmenler, panellerin akım akışını engelleyerek üretim gücünü ve verimliliğini azaltmaktadır. Ayrıca, PV sistemlerinin çıkış gücünü potansiyel olarak %50'ye kadar düşürebilmektedir. Bu nedenle, güneş enerjisi üretim santrallerinde, maksimum verimi sağlamak amacıyla panellerin bakımlarının düzenli aralıklarla yapılması ve arızalı ünitelerin değiştirilmesi veya onarılması güneş panellerinin uzun ömürlü ve verimli olmasını sağlamak için önemlidir.

Bu tez çalışması kapsamında güneş panellerinin verimliliğini otomatik olarak izlemek ve arızaları erken tespit etmek için derin öğrenme tabanlı segmentasyon yaklaşımı bir sistem tasarlanmıştır. Sistem, derin öğrenme ve veri analitiği tekniklerini kullanarak, güneş panellerinin işletim verilerini analiz ederek operatörlere hızlı geri bildirim sağlamaktadır. Çalışmada, hotspot arızasını tespit etmek için bölgesel tabanlı YOLO modeli ve bypass diyot arızasını tespit etmek için piksel tabanlı U-Net modeli kullanılmıştır. Bu iki yaklaşımın kombinasyonu, farklı hata türlerinin aynı anda tespit edilmesini sağlamaktadır.

Tez kapsamında kullanılan görsel veriler, Elazığ ili ve çevresinde bulunan güneş enerji santrallerinden alınmıştır. Veri seti, bir güneş tarlasındaki PV panellerinden toplanan 388 adet termal görüntülerden oluşmaktadır. Bu görüntüler, DJI Mavic 2 Enterprise Dual termal kameralı drone kullanılarak elde edilmiştir. Elde edilen görüntüler, MakeSense

veri etiketleme programı ile fotovoltaik panellerde hotspot arızası bulunan 100 adet arızalı görüntü, MATLAB'ın Image Labeler etiketleme aracı ile ise bypass diyot arızası bulunan 288 adet arızalı görüntü etiketlenmiştir. Deneysel çalışmalarda, ilk olarak hotspot arızası için etiketlenmiş güneş paneli görüntüleri kullanılarak arızaların tespiti amacıyla uygulanan YOLO algoritmalarının performansları karşılaştırılmıştır. Bu karşılaştırma sonucunda YOLOv8x algoritmasının %88,7 özgüllük, %80,5 duyarlılık ve %83,8 mAP değerleri ile diğer modellere göre daha iyi bir sonuç verdiği gözlemlenmiştir. Yapılan ikinci deneysel çalışmada ise güneş paneli görüntülerinde etiketlenen bypass diyot arızası görüntüleri kullanılarak bypass diyot kusurlarının tespiti amacıyla farklı katman derinliklerine sahip U-Net modelleri, bypass diyot hata tespitinde kullanılmış ve performansları karşılaştırılmıştır. Bu karşılaştırma sonucuna göre, en yüksek performans U-Net-V2 mimarisi ile elde edilmiştir; %87,79 AUC, %82,97 F1-Score ve %70,89 IOU değerlerine ulaşılmıştır. Bu çalışma, güneş panellerinin verimliliğini artırmak ve arızaları erken tespit etmek için derin öğrenme tabanlı çözümlerin etkinliğini göstermiştir. Önerilen sistem, güneş enerji santrallerinde güneş enerji santrallerinde otomatik olarak kusurlu panellerin ayrıştırılması/bakımı amacıyla kullanılabileceğini göstermiştir.

Gelecek çalışmalarda, SSD ve Faster R-CNN gibi farklı nesne tespiti algoritmaları kullanılarak güneş panellerindeki kusurların tespiti için en iyi algoritmanın belirlenmesi planlanmaktadır. Ayrıca, bu çalışmada sunulan en iyi performansa sahip YOLO algoritması, uzaktan algılama teknikleri ile entegre edilerek, güneş panellerindeki kusurların tespiti için daha kapsamlı bir çözüm için odaklanılacaktır.

KAYNAKLAR

- [1] International Energy Agency (IEA). CO2 Emissions in 2022- IEA, Paris, France: 2023.
- [2] International Energy Agency (IEA). Renewables 2022: Analysis and Forecast to 2027- IEA. Paris, France: 2022.
- [3] Taşkın O. Kusurlu güneş panelinde (PV) verimlerin ölçülmesi. Uludağ University Journal of The Faculty of Engineering. 2019; 24(1): 289–298.
- [4] Kumar A, Kumar K, Kaushik N, Sharma S, Mishra S. Renewable energy in India: Current status and future potentials. Renewable and Sustainable Energy Reviews. 2010; 14(8): 2434–2442.
- [5] Açıkgöz H, Korkmaz D. Elektrolüminesans görüntülerde arızalı fotovoltaik panel hücrelerin evrişimli sinir ağı ile otomatik sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi. 2022; 34(2): 589–600.
- [6] Dhimish M. Defining the best-fit machine learning classifier to early diagnose photovoltaic solar cells hot-spots. Case Studies in Thermal Engineering. 2021; 25: 100980.
- [7] Güneş- T.C. enerji ve tabii kaynaklar bakanlığı n.d. <https://enerji.gov.tr/bilgi-merkezi-enerji-gunes>.
- [8] GEPA n.d. <https://gepa.enerji.gov.tr/MyCalculator/>.
- [9] Kocakuşak R. Yenilenebilir enerji kaynaklarından güneş enerjisinin, Türkiye’deki önemi ve GES kurulum araştırması. Yüksek lisans tezi, Maltepe Üniversitesi, Sosyal Bilimler Enstitüsü. 2018.
- [10] Altuntop N, Erdemir D. Dünyada ve Türkiye ’de güneş enerjisi ile ilgili gelişmeler. Mühendis ve Makine. 2013; 54(639): 69–77.
- [11] Deitsch S, Christlein V, Berger S, Buerhop-Lutz C, Maier A, Gallwitz F, Riess, C. Automatic classification of defective photovoltaic module cells in electroluminescence images. Solar Energy. 2019; 185: 455–468.
- [12] Ali MU, Khan HF, Masud M, Kallu KD, Zafar A. A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography. Solar Energy. 2020; 208: 643–651.

- [13] Naveen Venkatesh S, Sugumaran V. Machine vision based fault diagnosis of photovoltaic modules using lazy learning approach. *Measurement*. 2022; 191: 110786
- [14] Otamendi U, Martinez I, Quartulli M, Olaizola IG, Viles E, Cambarau W. Segmentation of cell-level anomalies in electroluminescence images of photovoltaic modules. *Solar Energy*. 2021; 220: 914–926.
- [15] Bu C, Liu T, Li R, Shen R, Zhao B, Tang Q. Electrical pulsed infrared thermography and supervised learning for PV cells defects detection. *Solar Energy Materials and Solar Cells*. 2022; 237:111561.
- [16] Turhan Ş, Çetiner İ. Fotovoltaik sistemlerde performans değerlendirmesi. 6. Ulusal Çatı & Cephe Sempozyumu. 2012.
- [17] Boztepe M. Fotovoltaik güç istemlerinde verimliliği etkileyen parametreler. *EMO İzmir Şubesi Aylık Bülteni*. 2017: 13–17.
- [18] Dandıl E, Gürgen E. Yapay sinir ağları kullanılarak fotovoltaik panel güç çıkışlarının tahmini ve sezgisel algoritmalar ile karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*. 2019; (16): 146–158.
- [19] Çalışan M, Türkoğlu İ. Termal kameralar ve uygulamaları n.d.
- [20] Glavaš H, Vukobratović M, Primorac M, Muštran D. Infrared thermography in inspection of photovoltaic panels. In *2017 International Conference on Smart Systems and Technologies (SST)*. 2017: 63–68.
- [21] Chou YC, Yao L. Automatic diagnosis system of electrical equipment using infrared thermography. *SoCPaR 2009- Soft Computing and Pattern Recognition*. 2009: 155–160.
- [22] Cipriani G, Boscaino V, Di Dio V, Cardona F, Zizzo G, Di Caro S, Sa'ed, J. Application of thermographic techniques for the detection of failures on photovoltaic modules. In *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)*. 2019:1–5.
- [23] Ali MU, Saleem S, Masood H, Kallu KD, Masud M, Alvi MJ, Zafar, A. Early hotspot detection in photovoltaic modules using color image descriptors: An infrared thermography study. *International Journal of Energy Research*. 2021; 46(2): 774–785.
- [24] Ceylan İ, Yıldız G, Ergün A, Gürel AE. PV panellerin termografi yöntemi ile incelenmesi. 2019: 580–592.
- [25] Kaycı B. Güneş panellerinin dört rotorlu İHA kullanılarak termografi yöntemiyle derin öğrenme tabanlı hata tespit ve teşhisi (Doctoral dissertation). 2021.

- [26] Henry C, Poudel S, Lee S-W, Jeong H. Automatic detection system of deteriorated PV modules using drone with thermal camera. *Applied Sciences*. 2020; 10(11): 1–16.
- [27] Han SH, Rahim T, Shin SY. Detection of faults in solar panels using deep learning. 2021 International Conference on Electronics, Information, and Communication (ICEIC), IEEE. 2021: 1–4.
- [28] Ren Y, Yu Y, Li J, Zhang W. Design of photovoltaic hot spot detection system based on deep learning. *J Phys Conf Ser*. 2020; 1693(1): 012075.
- [29] Niazi KAK, Akhtar W, Khan HA, Yang Y, Athar S. Hotspot diagnosis for solar photovoltaic modules using a Naive Bayes classifier. *Solar Energy*. 2019; 190: 34–43.
- [30] Constantin A-I, Marin D, Angheliță P, Tiberiu Șerban I, Morari C, Iosif G. On-site performances evaluation of photovoltaic panels affected by bypass activated diodes detected with thermal cameras. 2023 13th International Symposium on Advanced Topics in Electrical Engineering (ATEE). 2023: 1–5.
- [31] Dhimish M, Holmes V, Mather P, Sibley M. Novel hot spot mitigation technique to enhance photovoltaic solar panels output power performance. *Solar Energy Materials and Solar Cells*. 2018; 179: 72–79.
- [32] Sayın S, Koç İ. Güneş enerjisinden aktif olarak yararlanmada kullanılan fotovoltaik (PV) sistemler ve yapılar da kullanım biçimleri. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*. 2011; 26(3): 89–106.
- [33] Kumar M, Kumar A. Performance assessment and degradation analysis of solar photovoltaic technologies: A review. *Renewable and Sustainable Energy Reviews*. 2017; 78: 554–587.
- [34] Singh GK. Solar power generation by PV (photovoltaic) technology: A review. *Energy*. 2013; 53: 1–13.
- [35] Özçelik S. Fotovoltaik (PV) teknolojileri. *Gazi Üniversitesi Ders Notu* n.d.
- [36] Çelik A, Koç F. Polikristal tür bir fotovoltaik panelin I-V karakteristiğinin analitik modellenmesi ve deneysel validasyonu. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*. 2020; 8(4): 2491–2515.
- [37] Çanka Kılıç F. Güneş enerjisi, Türkiye’deki son durumu ve üretim teknolojileri. *Mühendis ve Makine*. 2015; 56(671): 28–40.
- [38] Meral ME, Dinçer F. A review of the factors affecting operation and efficiency of photovoltaic based electricity generation systems. *Renewable and Sustainable Energy Reviews*. 2011; 15(5): 2176–2184.

- [39] Yenilenebilir Enerji Teknolojileri. Güneş Pillerinde Üretilen Doğru Akımın Temelleri. Millî Eğitim Bakanlığı, Ankara: 2012.
- [40] Al-Alwani MAM, Mohamad AB, Ludin NA, Kadhum AbdAH, Sopian K. Dye-sensitised solar cells: Development, structure, operation principles, electron kinetics, characterisation, synthesis materials and natural photosensitisers. *Renewable and Sustainable Energy Reviews*. 2016; 65: 183–213.
- [41] Vidyanandan KV. An overview of factors affecting the performance of solar PV systems. *Energy Scan*. 2017; 27(28): 216.
- [42] Öztürk HH. Güneş enerjisinden fotovoltaik yöntemle elektrik üretiminde güç dönüşüm verimi ve etkili etmenler. *Elektrik Tesisat Ulusal Kongre ve Sergisi Bildirileri 2017*; 1:1–14.
- [43] Meral ME, Dinçer F. A review of the factors affecting operation and efficiency of photovoltaic based electricity generation systems. *Renewable and Sustainable Energy Reviews*. 2011; 15(5): 2176–2184.
- [44] Karagözoğlu L, Duranay ZB. Investigation of maximum power point tracking methods in photovoltaic systems. *International Journal of Innovative Engineering Applications*. 2023; 7(1): 86–95.
- [45] Çiçek O, Karatay S. Küçük & orta ölçekli fotovoltaik (PV) modül üretimi için dijital PID sıcaklık denetimli laminatör deney kiti tasarımı ve üretimi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*. 2018; 6(4): 814–823.
- [46] Selbaş R, Çetin H. Fotovoltaik güneş santrallerinin verimlerinin değişiminin incelenmesi. *Uluslararası Sürdürülebilir Mühendislik ve Teknoloji Dergisi*. 2022; 6(1): 10–17.
- [47] Bakır H. Çatı tipi güneş enerji sisteminde kızılötesi termal teşhis ile arıza tespiti ve önemi. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 2023; 6(1): 90–105.
- [48] Akram MW, Li G, Jin Y, Chen X. Failures of photovoltaic modules and their detection: A Review. *Appl Energy*. 2022; 313: 118822.
- [49] Dağlı A, Karaköse E, Durmus A. Solar panellerde arıza analizi. In: *SETSCI-Conference Proceedings*. 2019; 4(1): 479–481.
- [50] Bakır H. FV panellerde arıza tespiti ve analizi. *Rumeli 1ST International Scientific Research Conference On Sustainable Engineering And Technology*. 2022: 290–294.

- [51] Sun T, Xing H, Cao S, Zhang Y, Fan S, Liu P. A novel detection method for hot spots of photovoltaic (PV) panels using improved anchors and prediction heads of YOLOv5 network. *Energy Reports*. 2022; 8: 1219–1229.
- [52] Chen J, Li Y, Ling Q. Hotspot detection for thermographic images of solar panels. 2020 Chinese Control And Decision Conference (CCDC), IEEE. 2020: 4651–4655.
- [53] Teo JC, Tan RHG, Mok VH, Ramachandaramurthy VK, Tan C. Impact of bypass diode forward voltage on maximum power of a photovoltaic system under partial shading conditions. *Energy*. 2020; 191:116491.
- [54] Vieira R, de Araújo F, Dhimish M, Guerra M. A comprehensive review on bypass diode application on photovoltaic modules. *Energies (Basel)*. 2020; 13(10): 2472.
- [55] Herrmann W, Wiesner W, Vaassen W. Hot spot investigations on PV modules-new concepts for a test standard and consequences for module design with respect to bypass diodes. *Conference Record of the Twenty Sixth IEEE Photovoltaic Specialists Conference- 1997*, IEEE; n.d. 1129–1132.
- [56] Aghaei M, Fairbrother A, Gok A, Ahmad S, Kazim S, Lobato K, Oreski G, Reinders A, Schmitz J, Theelen M. Review of degradation and failure phenomena in photovoltaic modules. *Renewable and Sustainable Energy Reviews*. 2022; 159: 112160.
- [57] Ko SW, Ju YC, Hwang HM, So JH, Jung Y-S, Song HJ, Song HE, Kim SH, Kang GH. Electric and thermal characteristics of photovoltaic modules under partial shading and with a damaged bypass diode. *Energy*. 2017; 128: 232–243.
- [58] AbdulMawjood K, Refaat SS, Morsi WG. Detection and prediction of faults in photovoltaic arrays: A review. 2018 IEEE 12th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG 2018), IEEE. 2018: 1–8.
- [59] Çaylı A, Akyüz A, Baytorun AN, Üstün S, Boyacı S. Seralarda ısı kaybına neden olan yapısal sorunların termal kamera ile belirlenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Doğa Bilimleri Dergisi*. 2016; 19(1): 5.
- [60] Durgut A, Akçay Ö. Termal kamera ile ekran kartının 3 boyutlu modelinin oluşturulması. *Anadolu University Journal of Science and Technology-A Applied Sciences and Engineering*. 2016; 17(1): 51–63.
- [61] Cipriani G, Boscaino V, Di Dio V, Cardona F, Zizzo G, Di Caro S, et al. Application of thermographic techniques for the detection of failures on photovoltaic modules. 2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), IEEE; 2019: 1–5.

- [62] Türkoğlu M, Hanbay D. Plant disease and pest detection using deep learning-based features. *Turkish Journal of Electrical Engineering and Computer Sciences*. 2019; 27(3): 1636–1651.
- [63] Yüksel N, Börklü HR, Sezer HK, Canyurt OE. Review of artificial intelligence applications in engineering design perspective. *Engineering Applications of Artificial Intelligence*. 2023;118.
- [64] Arslankaya S, Toprak Ş. Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*. 2021; 13(1): 178–192.
- [65] Karataş G, Demir Ö, Şahingöz ÖK. Deep learning in intrusion detection systems. In *2018 International Congress on Big Data, Deep Learning and Fighting Cyber Terrorism (IBIGDELFT)*. 2018: 113–116.
- [66] Doğan F, Türkoğlu İ. Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*. 2018; 1(1): 10–21.
- [67] Deng Z, Wang T, Zheng Y, Zhang W, Yun Y-H. Deep learning in food authenticity: Recent advances and future trends. *Trends in Food Science & Technology*. 2024; 144: 104344.
- [68] Du X, Chen S, Liu Z, Wang J. Multiple userids identification with deep learning. *Expert Systems with Applications*. 2022; 207: 117924.
- [69] Safarlı S, Gürel U, Öz Y. Derin öğrenme ile *Aspergillus* mantar türlerinin sınıflandırılması. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*. 2023; 4(3): 15–21.
- [70] Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2019; 10(2): 409–445.
- [71] Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*. 2017; 3(3): 47–64.
- [72] Dağlı İ, Öztürk A. Görüntü sınıflandırmada derin öğrenme yöntemlerinin karşılaştırılması. *Konya Journal of Engineering Sciences*. 2021; 9(4): 872–888.
- [73] Aslan M. Derin öğrenme ile şeftali hastalıklarının tespiti. *Avrupa Bilim ve Teknoloji Dergisi*. 2021; (23): 540–546.
- [74] Aslan M. Derin öğrenme tabanlı otomatik beyin tümör tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 2022; 34(1): 399–407.

- [75] Türkoğlu M, Hanbay K, Saraç Sivrikaya I, Hanbay D. Derin evrimsel sinir ağı kullanarak kayısı hastalıklarının sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*. 2020; 9(1): 334–345.
- [76] Demir FB, Yılmaz E. X-ray görüntülerinden Covid-19 tespiti için derin öğrenme temelli bir yaklaşım. *Avrupa Bilim ve Teknoloji Dergisi*. 2021; (32): 627–632.
- [77] Kıvrak O, Gürbüz MZ. YOLOv3, YOLOv4 ve YOLOv5 algoritmalarının performans Karşılaştırması: Kümes hayvan tanıma için bir vaka çalışması. *European Journal of Science and Technology*. 2022; (38): 392–397.
- [78] Sevi M, Aydın İ, Akın E. YOLOv5 ile topluluk öğrenmesine dayalı olarak ray yüzeyindeki kusurların tespiti. *Demiryolu Mühendisliği*. 2023; (17): 115–132.
- [79] Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: Unified, real-time object detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016: 779–788.
- [80] Tevfik Ağdaş M, Gülseçen S. Güvenlik kameralarında otomatik silah ve bıçak tespit sistemi: karşılaştırmalı YOLO modelleri. *European Journal of Science and Technology* 2022; (41): 16–22.
- [81] Atik ME, Duran Z, Özgünlük R. Comparison of YOLO versions for object detection from aerial images. *International Journal of Environment and Geoinformatics*. 2022; 9(2): 87–93.
- [82] Yılmaz S. Beyin tümörü tanıları için YOLOv7 algoritması tabanlı karar destek sistemi tasarımı. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*. 2023; 6(1): 47–56.
- [83] Lu S, Wang B, Wang H, Chen L, Linjian M, Zhang X. A real-time object detection algorithm for video. *Computers & Electrical Engineering*. 2019; 77: 398–408.
- [84] Chen Z, Wu R, Lin Y, Li C, Chen S, Yuan Z, et al. Plant disease recognition model based on improved YOLOv5. *Agronomy*. 2022; 12: 365.
- [85] Wei J, Qu Y. Lightweight improvement of YOLOv6 algorithm for small target detection. 2023.
- [86] Azizah AN, Fatichah C. Tajweed-YOLO: Object detection method for Tajweed by applying HSV color model augmentation on mushaf images. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*. 2023; 7(2): 236–245.
- [87] Li C, Li L, Jiang H, Weng K, Geng Y, Li L, Ke Z, Li Q, Cheng M, Nie, W. YOLOv6: A single-stage object detection framework for industrial applications. *ArXiv Preprint ArXiv:220902976*. 2022.
- [88] Dewi C, Chen APS, Christanto HJ. Deep learning for highly accurate hand recognition based on Yolov7 model. *Big Data and Cognitive Computing*. 2023; 7(1): 53.

- [89] Tang F, Yang F, Tian X. Long-distance person detection based on YOLOv7. *Electronics*. 2023; 12(6): 1502.
- [90] Jin L, Shi L, Li D, Liu K, Zhong M, Pang Y. Real-time fault diagnosis and method of photovoltaic module based on intelligent UAV cruise. 2023.
- [91] Karadağ B, Arı A. Akıllı mobil cihazlarda YOLOv7 modeli ile nesne tespiti. *Politeknik Dergisi*. 2023; 26(3): 1207–1214.
- [92] Chen Z, Chen X, Ren K. An improved network for pedestrian-vehicle detection based on YOLOv7 2023.
- [93] Cao L, Zheng X, Fang L. The semantic segmentation of standing tree images based on the Yolo V7 deep learning algorithm. *Electronics*. 2023; 12(4): 929.
- [94] Terven J, Córdova-Esparza D-M, Romero-González J-A. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. 2023; 5(4): 1680–1716.
- [95] Aboah A, Wang B, Bagci U, Adu-Gyamfi Y. Real-time multi-class helmet violation detection using few-shot data sampling technique and yolov8. *ArXiv Preprint*. ArXiv:230408256 2023.
- [96] Phan QB, Nguyen TT. A novel approach for PV cell fault detection using YOLOv8 and particle swarm optimization. 2023 IEEE 66th International Midwest Symposium on Circuits and Systems (MWSCAS). 2023: 634–638.
- [97] Ahmed D, Sapkota R, Churuvija M, Karkee M. Machine vision-based crop-load estimation using YOLOv8. *ArXiv Preprint*. 2023:1–23.
- [98] Ju R-Y, Cai W. Fracture detection in pediatric wrist trauma X-ray images using YOLOv8 algorithm. *ArXiv Preprint* ArXiv:230405071. 2023.
- [99] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany*, Springer Verlag. 2015: 234–241.
- [100] Punn NS, Agarwal S. Modality specific U-Net variants for biomedical image segmentation: a survey. *Artificial Intelligence Review*. 2022; 55(7): 5845–5889.