

T.C.
BALIKESİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR VE BİLİŞİM MÜHENDİSLİĞİ ANABİLİM DALI



**DERİN ÖĞRENME ALGORİTMALARI KULLANARAK
ELEKTROLÜMİNESANS GÖRÜNTÜLERİ İLE FOTOVOLTAİK
HÜCRELERDE KUSUR TESPİTİ**

FARUK ÖZEL

YÜKSEK LİSANS TEZİ

Jüri Üyeleri: Prof. Dr. Ayhan İSTANBULLU (Tez Danışmanı)

Doç. Dr. Hüseyin GÜNEŞ

Doç. Dr. İlyas ÖZER

BALIKESİR, ŞUBAT – 2026

ETİK BEYAN

Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak tarafımda hazırlanan “**Derin Öğrenme Algoritmaları Kullanılarak Elektrolüminesans Görüntüleri ile Fotovoltaik Hücrelerde Kusur Tespiti**” başlıklı tezde;

- Tüm bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Kullanılan veriler ve sonuçlarda herhangi bir değişiklik yapmadığımı,
- Tüm bilgi ve sonuçları bilimsel araştırma ve etik ilkelere uygun şekilde sunduğumu,
- Yararlandığım eserlere atıfta bulunarak kaynak gösterdiğimi,

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

Faruk ÖZEL

(imza)

**Bu tez çalışması Balıkesir Üniversitesi Bilimsel Araştırma Koordinatörlüğü tarafından
(BAP 2025/044) numaralı proje ile desteklenmiştir.**

ÖZET

**DERİN ÖĞRENME ALGORİTMALARI KULLANARAK
ELEKTROLÜMINESANS GÖRÜNTÜLERİ İLE FOTOVOLTAİK
HÜCRELERDE KUSUR TESPİTİ
YÜKSEK LİSANS TEZİ
FARUK ÖZEL
BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR VE BİLİŞİM MÜHENDİSLİĞİ ANA BİLİM DALI
(TEZ DANIŞMANI: PROF. DR. AYHAN İSTANBULLU)
BALIKESİR, ŞUBAT – 2026**

Güneş enerjisi santrallerinin artan kurulum kapasitesi, fotovoltaik modüllerin işletme ömrü ve verimliliğinin sürdürülebilirliğini kritik bir mühendislik problemi hâline getirmiştir. Üretim ve işletme süreçlerinde hücre yüzeyinde oluşan mikro çatlaklar ve deformasyonlar zamanla ciddi enerji kayıplarına neden olmaktadır. Endüstriyel standart olan Elektrolüminesans görüntüleme tekniğinin manuel analizi ise yüksek uzmanlık gerektirmekte ve zaman maliyeti oluşturmaktadır. Bu tez çalışmasında, PV hücre kusurlarının otonom, gerçek zamanlı ve piksel hassasiyetinde tespiti için YOLOv11 nesne tespiti algoritması ile temel segmentasyon modeli SAM 2'yi birleştiren hibrit bir derin öğrenme mimarisi önerilmiştir. Önerilen yöntem, YOLOv11 aracılığıyla kusur konumunu sınırlayıcı kutularla belirlemekte ve bu koordinatları kutu istemi olarak SAM 2'ye ileterek kusurların morfolojik sınırlarını maskeleymektedir. Performansı doğrulamak amacıyla, tek aşamalı YOLOv11-seg modeli referans alınarak karşılaştırmalı analizler yapılmıştır. Eğitim ve test süreçleri, 7 farklı kusur sınıfını içeren toplam 13.631 görselden oluşan kapsamlı veri havuzu üzerinde, %80-10-10 optimum dağılım stratejisiyle gerçekleştirilmiştir. Deneysel bulgulara göre, hibrit yapının ön aşamasını oluşturan YOLOv11, kusur konumlandırma %95,71 (0.9571) mAP@0.50 değerine ulaşarak tek aşamalı YOLOv11-seg modelini (0.9245) net bir şekilde geride bırakmıştır. Hız ve uygulanabilirlik metrikleri incelendiğinde, YOLOv11'in görüntü başına 1.38 milisaniye çıkarım süresi ve saniyede 720 kare (FPS) işleme hızı ile referans modele kıyasla yaklaşık 2,6 kat daha hızlı çalıştığı tespit edilmiştir. Bu çalışmada önerilen YOLOv11+SAM 2 yapısı, yüksek tespit doğruluğu ve gerçek zamanlı işlem çevikliğini bir araya getirirken, sıfır-atış özelliği sayesinde araştırmacıları zahmetli çokgen etiketleme süreçlerinden kurtarmış; endüstriyel kalite kontrol uygulamaları için maliyet-etkin ve yüksek doğruluklu bir otonom sistem ortaya koymuştur.

ANAHTAR KELİMELER: Derin öğrenme, elektrolüminesans, fotovoltaik hücre, görüntü işleme, kusur tespiti, segmentasyon, yapay zeka

ABSTRACT

DEFECT DETECTION IN PHOTOVOLTAIC CELLS USING ELECTROLUMINESCENCE IMAGES AND DEEP LEARNING ALGORITHMS

**MSc THESIS
FARUK ÖZEL**

**BALIKESIR UNIVERSITY INSTITUTE OF SCIENCE
COMPUTER AND INFORMATION ENGINEERING
(SUPERVISOR: PROF. DR. AYHAN İSTANBULLU)
BALIKESIR, FEBRUARY- 2026**

The increasing installation capacity of solar power plants has made the sustainability of the operational lifetime and efficiency of photovoltaic modules a critical engineering problem. Micro-cracks and deformations occurring on the cell surface during production and operational processes cause significant energy losses over time. The manual analysis of Electroluminescence imaging, which is the industrial standard, requires high expertise and is highly time-consuming. In this thesis, a hybrid deep learning architecture combining the YOLOv11 object detection algorithm and the foundation segmentation model SAM 2 is proposed for the autonomous, real-time, and pixel-level precise detection of PV cell defects. The proposed method determines the defect locations using bounding boxes via YOLOv11 and transmits these coordinates as "box prompts" to SAM 2, thereby masking the morphological boundaries of the defects. To verify the performance, comparative analyses were conducted using the single-stage YOLOv11-seg model as a reference. The training and testing processes were carried out on a comprehensive dataset consisting of a total of 13,631 images containing 7 different defect classes, utilizing an optimal 80-10-10 data split strategy. According to the experimental findings, YOLOv11, which constitutes the preliminary stage of the hybrid structure, achieved a 95.71% (0.9571) mAP@0.50 score in defect localization, clearly outperforming the single-stage YOLOv11-seg model (0.9245). When speed and applicability metrics were examined, it was determined that YOLOv11 operated approximately 2.6 times faster compared to the reference model, with an inference time of 1.38 milliseconds per image and a processing speed of 720 frames per second (FPS). In conclusion, the YOLOv11+SAM 2 architecture proposed in this study combines high detection accuracy and real-time processing agility, while freeing researchers from laborious polygon annotation processes thanks to its zero-shot capability, thereby presenting a cost-effective and highly accurate autonomous system for industrial quality control applications.

KEYWORDS: Deep learning, electroluminescence, photovoltaic cell, image processing, defect detection, segmentation, artificial intelligence

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	vi
KISALTMALAR LİSTESİ	vii
ÖNSÖZ VE TEŞEKKÜR	viii
1. GİRİŞ	1
2. LİTERATÜR İNCELEMESİ	3
3. TEORİK ÇERÇEVE VE MODELLEME	7
3.1 Görüntü İşleme.....	7
3.1.1 Görüntü ön işleme teknikleri	7
3.2 Fotovoltaik Hücre Yapısı ve Kusur Mekanizmaları	9
3.3 Elektrolüminesans Görüntüleme Tekniğinin Teorik Temelleri.....	11
3.4 Derin Öğrenme Tabanlı Nesne Tespiti	13
3.5 Her Seyi Bölütleyen Model (Segment Anything Model - SAM ve SAM2).....	15
3.5.1 Temel SAM mimarisi ve çalışma prensibi	15
3.5.2. SAM 2	16
3.6 YOLOv11 + SAM2 Tabanlı Modelleme Yaklaşımı.....	19
3.7 YOLOv11-seg Yaklaşımı	20
4. METODOLOJİ	22
4.1 Veri Seti	22
4.2 Özellik Çıkarma ve Seçim Teknikleri.....	24
4.3 Akış Diyagramı	26
4.4 Model Doğrulama ve Optimizasyon.....	26
4.4.1 Model performans ölçütleri	27
4.4.1.1 Karmaşıklık matrisi (confusion matrix)	27
4.4.1.2 Kesişim - birleşim oranı (intersection over union - IoU)	28
4.4.1.3 Kesinlik (precision)	28
4.4.1.4 Duyarlılık (recall)	28
4.4.1.5 F1 skor	29
4.4.1.6 Ortalama kesinlik (average precision - AP) ve ortalama hassasiyetin ortalaması (Mean Average Precision - mAP)	29
4.4.1.7 Doğruluk (accuracy)	30
4.4.1.8 Kayıp fonksiyonları (Loss functions)	30
4.4.2 Hiperparametre optimizasyonu	31
4.4.2.1 Izgara arama (grid search)	31
4.4.2.2 Rastgele arama (random search).....	31
4.4.2.3 Bayesyan (Bayesian) optimizasyonu.....	32
4.4.3 Çapraz doğrulama ve performans artırma stratejileri.....	32
4.4.3.1 Veri artırma (data augmentation)	33
4.4.3.2 Düzenleştirme (regularization) teknikleri	34
4.4.3.3 Erken durdurma (early stopping).....	34
4.4.3.4 Topluluk (ensemble) modeller.....	35
4.4.3.5 Transfer öğrenimi	35
4.5 Deneysel Ortamı.....	36

İÇİNDEKİLER (devam)

4.5.1 Donanım ve yazılım altyapısı.....	36
4.5.2 Model eğitim parametreleri	37
5. BULGULAR.....	39
5.1 Çıktı Sonuçları	39
5.2 Model Performans Analizi.....	45
6. SONUÇ VE ÖNERİLER.....	49
6.1 Sonuçlar	50
6.2 Gelecek Çalışmalar için Öneriler.....	52
7. KAYNAKLAR	Hata! Yer işareti tanımlanmamış.
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: Fotovoltaik modül yapısı	9
Şekil 3.2: Elektrolüminesans (EL) görüntüleme tekniğinin şematik çalışma prensibi	12
Şekil 3.3: Fotovoltaik modüllerde zamana bağlı güç kaybı (degradation) mekanizmaları ve kusurların performans üzerindeki uzun vadeli etkileri.....	12
Şekil 3.4: Yolo11 akış diyagramı	14
Şekil 3.5: SAM algoritma mimarisi.....	16
Şekil 3.6: SAM2 model mimarisi.....	17
Şekil 3.7: SAM ve SAM2 Uygulamalarında şematik karşılaştırmalı analizi.....	18
Şekil 3.8: YOLOv11 + SAM2 hibrit yaklaşım modeli	19
Şekil 4.1: Akış diyagramı	26
Şekil 4.2: Karmaşıklık matrisi değer gösterim tablosu	27
Şekil 4.3: Elektrolüminesans görüntüleme ve test düzeneğinin şematik diyagramı	37
Şekil 5.1: Farklı veri seti dağılımlarına göre modellerin sınıflandırma performansını gösteren normalleştirilmiş karmaşıklık matrisleri: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).	39
Şekil 5.2: Farklı modellerin 200 devir (epoch) boyunca eğitim ve doğrulama kayıpları ile performans metriklerinin değişimi: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).	40
Şekil 5.3: Farklı modellerin hassasiyet-duyarlılık eğrisi ve mAP@0.5 değerleri: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).	42
Şekil 5.4: Farklı modellerin F1 Skoru- Güven eşiği değişim eğrileri: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).	44
Şekil 5.5: Hibrit modelin test veri seti üzerindeki örnek tahminleri: (a) yatay yer değiştirme kusuru (b) uzun ve kavisli çatlak segmentasyonu (c) çoklu yıldız çatlak kusurları.....	48
Şekil 6.1: Yoğun hata içeren saha görüntüsü üzerinde standart YOLOv11 + SAM 2 tespiti ile hibrit yöntemin karşılaştırmalı analizi.	50

TABLO LİSTESİ

Sayfa

Tablo 2.1: Akademik araştırma tablosu	3
Tablo 3.1: YOLOv11, YOLOv11-seg, SAM ve SAM 2 modellerinin karşılaştırmalı analizi.....	21
Tablo 4.1: YOLO modellerinin eğitim ve derleme ayarları.....	37
Tablo 5.1: YOLOv11-seg ve YOLOv11+SAM2 modellerinin iki farklı veri bölünmesinde sınıf bazlı kutu mAP@50–95 karşılaştırması.....	46
Tablo 6.1: Farklı Veri Seti Dağılımlarına Göre YOLOv11 ve YOLOv11-seg Modellerinin Test Başarımı (mAP@50) Karşılaştırması	49

KISALTMALAR LİSTESİ

AP	: Ortalama Hassasiyet (Average Precision)
ASFF	: Uyarlanabilir Özellik Alanı Birleştirme (Adaptive Spatial Feature Fusion)
BAFPN	: Çift Yönlü Dikkat Özellik Piramit Ağı (Bidirectional Attention Feature Pyramid Network)
C2PSA	: Kanal Bazlı Piramit Sıkıştırma ve Uyarma Dikkati (Channel-wise Pyramid Squeeze-and-Excitation Attention)
CCD	: Yük Bağlı Aygıt (Charge Coupled Device)
CMOS	: Tümlenici Metal Oksit Yarı İletken (Complementary Metal Oxide Semiconductor)
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Networks)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
DFL	: Dağılım Odaklı Kayıp (Distribution Focal Loss)
EL	: Elektrolüminesans (Electroluminescence)
FF	: Doluluk Faktörü (Fill Factor)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
FPN	: Özellik Piramit Ağı (Feature Pyramid Network)
GAN	: Üretken Çekişmeli Ağlar (Generative Adversarial Networks)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
IEA-PVPS	: Uluslararası Enerji Ajansı Fotovoltaik Güç Sistemleri Programı
IoU	: Kesişim–Birleşim Oranı (Intersection over Union)
Isc	: Kısa Devre Akımı
IR	: Kızılötesi (Infrared)
ITO	: İndiyum Kalay Oksit (Indium Tin Oxide)
LED	: Işık Yayan Diyot (Light Emitting Diode)
mAP	: Ortalama Hassasiyetin Ortalaması (Mean Average Precision)
PV	: Fotovoltaik (Photovoltaic)
RAM	: Rastgele Erişimli Bellek (Random Access Memory)
RNN	: Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
SAM	: Her Şeyi Bölütleyen Model (Segment Anything Model)
SGDM	: Momentum Tabanlı Stokastik Gradyan İnişi (Stochastic Gradient Descent with Momentum)
SPFF	: Uzaysal Piramit Havuzlama – Hızlı (Spatial Pyramid Pooling-Fast)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
ViT	: Görüntü Transformatörü (Vision Transformer)
Voc	: Açık Devre Gerilimi
YOLO	: Sadece Bir Kez Bak (You Only Look Once)

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması hem akademik hem de kişisel gelişim sürecimde önemli bir dönüm noktası olmuştur. Bu yolculuk boyunca bilgi, emek ve destekleriyle yanımda olan hocalarıma, aileme ve sevdiklerime şükran borçluyum. Öncelikle, yüksek lisans eğitimim ve tez sürecim boyunca bilimsel bakış açımı geliştirmeme katkı sağlayan, yönlendirmeleri ve yapıcı eleştirileriyle çalışmanın biçimlenmesinde etkili olan değerli danışmanım Prof. Dr. Ayhan İstanbullu'ya teşekkür ederim. Hayatım boyunca gerek özel hayatımda gerekse eğitim hayatımda yoluma dokunan, bana rehberlik eden tüm öğretmenlerime ve üniversitemin kıymetli akademik kadrosuna, kazandırdıkları bilgi, değer ve bakış açıları için müteşekkirim. Her koşulda yanımda olan, sevgisi ve desteğiyle beni ayakta tutan aileme içten teşekkürlerimi sunarım. En büyük ve en özel teşekkürü ise hayatımın en kıymetli yol arkadaşı olan sevgili eşim Fatma Feyza Özel'e borçluyum. Tez sürecinin en yoğun ve yorucu dönemlerinde gösterdiği büyük anlayış, bitmeyen sabır, moral ve motivasyon desteği, bu çalışmanın tamamlanmasında belirleyici olmuştur. Her zaman yanımda olarak bana güç verdiği, inancını ve sevgisini hiç eksiltmediği için kendisine gönülden, defalarca teşekkür ediyorum. Bu çalışmanın, fotovoltaiik hücrelerde kusur tespiti ve derin öğrenme temelli görüntü işleme alanına mütevazı da olsa bir katkı sağlaması dileğiyle...

Balıkesir, 2026

Faruk Özel

1. GİRİŞ

Dünya genelinde fotovoltaik (PV) güneş enerjisi sistemlerinin yaygınlaşmasıyla birlikte, sistemlerin güvenilirliğini ve verimliliğini uzun vadede korumak önem kazanmıştır (IEA-PVPS, 2018). Çünkü PV hücreler, üretim sürecinden taşıma ve işletme koşullarına kadar birçok aşamada mikro çatlaklar, malzeme bozulmaları veya ara bağlantı kopmaları gibi yapısal kusurlara maruz kalabilmektedir (Allied Vision, 2022; Al Mahdi et al., 2024). Bu kusurlar başlangıçta önemsiz görülsede zamanla ilerleyerek ciddi verim kayıplarına ve güvenlik risklerine yol açabilmektedir. Bu durum ise son kullanıcıda zaman ve maliyet kayıplarına yol açmaktadır. Özellikle kristal silikon tabanlı PV hücrelerde silikon işleme süreçlerindeki zorluklar, kristal örgü kalitesindeki hatalar veya panelin taşınması ve montajı sırasında oluşan mekanik gerilim gibi etkenler, mikro düzeyde kusurların gelişmesine zemin hazırlamaktadır (Allied Vision, 2022). Gözle görünen veyahut görünmeyen tüm kusurların erken tespiti, enerji üretimindeki beklenmedik kayıpları en aza indirmek ve sistem ömrünü uzatmak açısından temel gerekliliktir. Günümüzde PV sistemlerde geleneksel I-V eğrisi (açık devre gerilimi (Voc), kısa devre akımı (Isc), en yüksek güç noktası (MPP), en yüksek güç (Pmax), doluluk faktörü (Fill Factor – FF) son olarak verimlilik ve performans kaybı) ölçümleri ve uzaktan izleme yöntemleri yaygın biçimde kullanılmaktadır. Ancak bu yöntemler, özellikle görünür olmayan mikro boyuttaki hasarların veya şöntlenmiş bölgelerin ortaya konmasında yetersiz kalabilmektedir (IEA-PVPS, 2018). Bu noktada Elektrolüminesans (EL) görüntüleme tekniği, hücrelerin iç yapısındaki mikro çatlaklar ve ölü bölgeler gibi ince detayları doğrudan gözler önüne sermesiyle öne çıkmaktadır (Allied Vision, 2022). EL yönteminde, modüle belirli doğru akım uygulanarak hücrelerin kızılötesi spektrumda yaydığı ışınım özel kameralarla yakalanmaktadır. Bu sayede, çıplak gözle veya standart termal yöntemlerle saptanması güç olan kusurların yüksek hassasiyetle belirlenmesi sağlanmaktadır (IEA-PVPS, 2018; Hussain et al., 2023).

Öte yandan, PV hücrelerin işletme koşullarındaki performans sorunlarını hızlı ve temassız şekilde tespit edebilmek için Kızılötesi (IR) termografi kameraları da yaygın biçimde kullanılmaktadır (Jahn et al., 2018). IR görüntüleme yöntemi, özellikle sıcak nokta oluşumu, kısmi gölgelenme veya bağlantı kopukluğu gibi kusurları, çalışan paneller üzerinde doğrudan gözlemleyebilme avantajı sunmaktadır. Drone platformlarına entegre edilen yüksek çözünürlüklü IR kameralar sayesinde, büyük ölçekli güneş enerjisi santralleri

kısa sürede taranarak problemlı panellerın konumları hızla tespit edılebılmektedir (Gallardo-Saavedra et al., 2020; Høiaas et al., 2022). Ayrıca karanlık ortamlarda harıcı uyarımla gerçekleştirilen IR çekimleri de farklı arıza tiplerine ilişkin tamamlayıcı bilgiler sağlamaktadır (Abdelhamid et al., 2014).

Derin öğrenme algoritmaları son yıllarda hem EL hem de IR görüntülerinde fotovoltaik kusurların otomatik tespitinde ufuk açıcı gelişmelere olanak tanımıştır (Ding et al., 2024; Khanam et al., 2025). Özellikle You Only Look Once (YOLO) gibi tek adımlı nesne tanıma modelleri, mikro çatlak, lehim hatası ve kirlilik gibi çok çeşitli kusurları gerçek zamanlı ve yüksek doğruluk oranlarıyla tanımlayabilmektedir (Ameerdin et al., 2024). Bu modellerde, milisaniyeler düzeyindeki çıkarım süreleri sayesinde geniş ölçekli PV santrallerin taranması daha kısa sürede ve daha verimli şekilde gerçekleştirilebilmektedir (Fernández et al., 2020). Bu sayede nadir görülen veya küçük boyutlu kusurlar dahi yüksek hassasiyetle tespit edilebilmektedir (Khanam et al., 2025). Ayrıca konvolüsyonel sinir ağları (CNN) aracılığıyla kusur tespiti ve tekrarlayan sinir ağları (RNN) ile arıza eğilimi tahmini gibi yaklaşımların birlikte kullanılması, büyük ölçekli tarlalarda bakım süreçlerini hızlandıran bütünsel denetim sistemlerinin geliştirilmesine olanak tanımaktadır (Al-Waisy et al., 2022). Tüm bu gelişmeler göz önüne alındığında yeni geliştirilen yöntemler sayesinde, büyük PV santrallerde verimlilik kayıplarının sebebi hızlıca belirlenip giderilmekte, böylece toplam enerji üretimi artırılmakta ve bakım maliyetleri düşürülmektedir (Hussain et al., 2023). Akademik açıdan bakıldığında ise, farklı arıza modlarının kökenini daha iyi anlamamızı sağlayan detaylı veriler, güneş hücresi malzemeleri ve üretim süreçlerinin iyileştirilmesine katkı sunmaktadır (Allied Vision, 2022).

Bu tez çalışmasında, IR kamera kullanılarak elde edilen elektrolüminesans görüntülerinin kendine özgü veri seti ile geliştirilen hibrit model tabanlı yöntem ile analiz edilip fotovoltaik hücre kusurlarının tespit edilmesi üzerinde durulacaktır. Böylelikle, güneş panellerinin kalitesini ve güvenilirliğini artırmaya yönelik, en düşük maliyetli, hızlı ve otomatik bir denetim sistemi geliştirilmesine katkı sağlanması amaçlanmaktadır.

2. LİTERATÜR İNCELEMESİ

Güneş enerjisi teknolojilerinin hızla yayılmasıyla birlikte, PV modüllerin güvenilirliğini ve verimliliğini korumak zorunluluk haline gelmiştir. EL görüntüleme, PV hücrelerindeki mikro-çatlaklar ve diğer hasarlar gibi ince kusurları yüksek çözünürlükte tespit etme yeteneği sayesinde endüstriyel denetimin vazgeçilmezi olmuştur. Ancak, bu görüntülerin manuel olarak incelenmesi uzmanlık gerektiren, maliyetli ve zaman alıcı süreçtir. Bu nedenle, derin öğrenme yaklaşımları, PV kusur tespitini otomatikleştirme yarışında en önemli araç olarak öne çıkmıştır. Tablo 2.1’de bu alandaki önemli çalışmaların metodolojik çeşitliliğini, kullandıkları veri büyüklüklerini ve ulaştıkları başarı oranlarını özetlenmektedir.

Tablo 2.1: Akademik araştırma tablosu

Kaynak	Veri Büyüklüğü	Doğruluk (%)	Yöntem
Deitsch et al., (2019)	2624 hücresi görüntüsü	88.42%	VGG-19 CNN
Akram vd., (2019)	2624 EL görüntüsü	93.02	Light CNN
Rahman et al., (2020)	-	-	MAU-Net
Demirci vd., (2021)	2624 (ELPV)	94.52%	DFB-SVM
Su et al., (2021)	3629 EL	98.70%	BAF-Detector
Tang et al., (2022)	5000 EL görüntüsü	95%	ConvNet
Fan et al., (2022)	-	-	ResNet-based TL
Huang et al., (2022)	2624	88.6%	PSOPruner
Wang et al., (2022)	2223	96.17%	ResNet152-Xception
Khosa et al., (2023)	2624	94.3%	Customized CNN
Jerome et al., (2023)	600	100.00%	DenseNet-201 + IBK
Chen et al., (2023)	1837	87.5%	UNet-VGG16
Mazen et al., (2023)	1400	77.7%	Improved YOLOv5
Du et al., (2024)	4500	77.9%	YOLOv8-CCT
Tella et al., (2025)	2624	73.02%	Ensemble CNN
Wang and Cheng (2025)	PVEL-AD	91.7%	MRA-YOLOv8

Tablo 2.1 (devam)

Not: VGG-19 CNN, VGG-19 tabanlı bir evrişimsel sinir ağı; Light CNN, düşük parametrelili hafif bir evrişimsel ağ mimarisini; MAU-Net, çoklu dikkat mekanizmaları içeren bir U-Net tabanlı segmentasyon ağı; DFB-SVM, derin özelliklere dayalı bir destek vektör makinesi yaklaşımını; BAF-Detector, Faster R-CNN, FPN ve BAFPN bileşenlerini içeren çok ölçekli bir tespit sistemini; ConvNet, standart bir derin evrişimsel sinir ağı; ResNet-based TL, transfer öğrenme ile eğitilmiş ResNet mimarisini; PSOPruner, parçacık sürü optimizasyonu tabanlı CNN budama yöntemini; ResNet152–Xception, iki farklı CNN mimarisinin özellik füzyonuna dayalı hibrit bir ağı; Customized CNN, fotovoltaiik hücre kusurları için özel olarak tasarlanmış bir evrişimsel ağı; DenseNet-201 + IBK, DenseNet-201 tarafından çıkarılan özelliklerin k-en yakın komşu sınıflandırıcısı ile değerlendirilmesini; UNet-VGG16, VGG16 enkoderli bir U-Net segmentasyon modelini; Improved YOLOv5, GAM, ASFF, DIOU ve TTA bileşenleriyle geliştirilmiş bir YOLOv5 sürümünü; YOLOv8-CCT, CNN, Transformer ve PSA tabanlı hibrit bir YOLOv8 mimarisini; Ensemble CNN, voting ve bagging stratejileriyle birleştirilmiş CNN modellerini; MRA-YOLOv8 ise MBCANet, ResBlock ve AMPDIOU bileşenlerini içeren çok çözünürlüklü dikkatli bir YOLOv8 mimarisini ifade etmektedir.

Literatür, PV kusur tespitine yönelik ilk büyük metodu derin öğrenme ile atmıştır. Deitsch ve arkadaşları (2019), VGG-19 tabanlı CNN kullanarak, manuel özelliklere dayalı geleneksel SVM kıyasla daha yüksek doğruluk (%88,42 vs. %82,44) elde ederek derin öğrenmenin üstünlüğünü kanıtlamıştır. Bu durum analizin manuel uzmanlıktan otomatik sistemlere kaydığının güçlü işaretidir. Aynı dönemde, Akram ve arkadaşları (2019), Light CNN adı verilen hafif mimari önererek bu alana hız kazandırmıştır. Gerçekleştirilen model, veri artırma tekniklerini kullanarak, 2624 hücre görüntüsünden oluşan veri setinde %93,02 gibi yüksek doğruluk elde etmiş ve en önemlisi, bunu sıradan CPU bilgisayarında gerçek zamanlı hızda (8,07 ms) tahmin yaparak başarmıştır. Bu tür hafif mimariler, laboratuvar ortamından endüstriyel üretime geçiş için kritik önem taşımaktadır. Çünkü daha az hesaplama gücü ve zaman gerektirir. Daha sonraki çalışmalar, sınıflandırma doğruluğunu daha da artırmak için derin ağların gücünü geleneksel yöntemlerle birleştirmeye odaklanmıştır. Demirci ve arkadaşları (2021), VGG, ResNet ve DarkNet gibi önceden eğitilmiş derin sinir ağlarından özellikler çıkarmıştır. Bu derin özellikleri geleneksel sınıflandırıcı olan SVM ile birleştirmiştir. Bu hibrit yaklaşım, 2 sınıflı veri kümesinde %94,52 gibi kayda değer doğruluk elde etmiştir. Bu klasik makine öğrenimi yöntemlerinin, derin öğrenme ile çıkarılan güçlü özniteliklerle birleştiğinde, özellikle dengesiz veri setlerinde dahi başarılı olabileceğini göstermiştir. Wang et al., (2022), ResNet152 ve Xception ağlarının avantajlarını birleştiren ve Dikkat Mekanizması (CA) ekleyen hibrit modelle ikili sınıflandırmada %96,17 gibi üst düzey doğruluk elde etmiştir. Kusurun geometrik bilgisini çıkarmak için Rahman et al., (2020) Çoklu Dikkat U-Net (MAU-net) ile çatlak segmentasyonunda hız ve kaliteyi artırırken (75 ms test süresi), Chen et al., (2023) Fine-tuned UNet kullanarak çatlak uzunluğu gibi nicel özellikler elde etmiştir (%87,5 F1 Skoru). En güncel çalışmalar, Fan et al., (2022)'nin transfer öğrenme ile polikristalin

hücrelerde mikroçatlak tespitini %11,6 oranında artırması ve YOLOv8 mimarisinin Transformer ve Dikkat Mekanizması (CCT, PSA, MBCANet) ile birleştirilmesiyle (Du et al., 2024; Wang and Cheng 2025) %91,7 mAP50 gibi yüksek hassasiyetli çoklu kusur tespitine odaklanmıştır. Bu evrim, PV denetim sistemlerinin artık sadece kusurlu hücreleri belirlemekle kalmayıp, aynı zamanda hızlı, otomatik ve piksel düzeyinde kusur konum ve tipini tespit edebildiğini göstermektedir.

Klasik sınıflandırma modelleri, sadece hücrenin "kusurlu" olduğunu söylerken, modern uygulamalar kusurun tam yerini, boyutunu ve şeklini haritalamayı gerektirmektedir. Chen et al., (2023), PV hücrelerindeki çatlakların otomatik olarak semantik segmentasyonunu (piksel düzeyinde sınıflandırma) yapmak için fine-tuned UNet modelini kullanmıştır. Bu model, çatlak çizgilerini, baraları ve karanlık alanları piksel ölçeğinde etiketleyerek ortalama %87,5 F1 Skoru elde etmiştir. Bu yaklaşım, çatlak uzunluğu ve parlaklık gibi nicel özelliklerin çıkarılmasına olanak tanımaktadır. Su et al., (2021), özellikle ağ derinleştikçe kaybolan multiskala kusurları tespit etmek için BAF-Detector (Faster RCNN+FPN tabanlı) önermiştir. Bu model, çatlak, bara kesintisi ve siyah çekirdek gibi kusurların tespitinde %88,07 mAP ve sınıflandırmada %98,70 F-Ölçüsü elde ederek multiskala kusur tespitinde önemli ilerleme sağlamıştır.

En yeni çalışmalar, endüstriyel üretim hatlarında hızlı ve hassas çalışabilen, çoklu kusur tipini aynı anda tespit edebilen sistemlere odaklanmıştır. Mazen et al., (2023), gerçek zamanlı tespit için geliştirilmiş YOLOv5 modelini (GAM, ASFF ve DIOU-NMS modülleri eklenerek) kullanmıştır. 1400 görüntülük ELDDS1400C5 veri kümesi üzerinde %77,7 mAP@0.5 skoruna ulaşmıştır. Bu sonuç, hatta YOLOv8 modelini dahi küçük farkla geride bırakmıştır (%77,5). Daha yeni çalışma olan Wang et al., (2025), YOLOv8 tabanlı MRA-YOLOv8 ağını, MBCANet ve artık blokları (ResBlock) birleştirerek PVEL-AD veri kümesi üzerinde %91,7 mAP50 elde etmiştir. Bu büyük ve karmaşık veri setlerinde dahi yüksek hassasiyeti koruma çabasını yansıtmaktadır. Du ve Lv (2024) de benzer şekilde YOLOv8 mimarisine dönüştürücü (transformer) ve dikkat mekanizması (PSA, CCT) entegre ederek PVEL-AD veri kümesinde %77,9 mAP50 ile gerçek zamanlı tespit yeteneklerini güçlendirmiştir. Jerome ve arkadaşları (2023), DenseNet-201'den çıkarılan derin öznitelikleri geleneksel k-En Yakın Komşu (IBK) sınıflandırıcısıyla birleştirerek, altı farklı kusur tipinde (salyangoz izi, cam kırılması, vb.) %100.00 sınıflandırma doğruluğuna ulaşmıştır. Bu küçük ve kontrollü veri setlerinde, derin öğrenmenin güçlü öznitelik çıkarma

yeteneđi ile klasik makine öğreniminin basit sınıflandırma yeteneklerinin birleşiminin olađanüstü sonuçlar verebileceđini göstermektedir.

Tüm bu çalışmalar, derin öğrenme modellerinin PV modül arızalarının hem tespiti hem de analizi üzerinde yüksek potansiyele sahip olduğunu kanıtlamaktadır. Geliştirilen yöntemler arasında veri artırma, transfer öğrenmesi, model sıkıştırma, özelleştirilmiş mimariler, nesne tespiti, segmentasyon ve hatta UAV görüntülerinin işlenmesine kadar geniş yelpaze gözlenmektedir. Böylece, üretim hatlarında gerçek zamanlı kalite kontrol uygulamalarından geniş ölçekli PV santrallerin periyodik denetimine kadar farklı senaryolarda daha hızlı, doğru ve hesaplama açısından verimli çözümler sunulabilmektedir. Dolayısıyla literatür, PV modül verimliliđini artırmak ve sistem arıza risklerini en aza indirmektedir. Bu durum derin öğrenme tabanlı otomatik tespit ve değerlendirme sistemlerinin giderek daha yaygın ve etkili hale geleceđini göstermektedir.

3. TEORİK ÇERÇEVE VE MODELLEME

Bu bölümde, çalışmanın metodolojik altyapısını oluşturan temel teorik kavramlar, kullanılan derin öğrenme mimarileri ve veri hazırlık süreçleri detaylandırılmaktadır. İlk olarak, fotovoltaik hücrelerdeki kusurların tespiti ve segmentasyonu için tercih edilen görüntü işleme teknikleri ile YOLOv11 ve Segment Anything Model (SAM2) mimarilerinin yapısal özellikleri açıklanmaktadır. Bununla birlikte karşılaştırma için kullanılan Yolov11-seg yapısından bahsedilmiştir. Ardından, araştırmada kullanılan veri setinin kaynakları, istatistiksel dağılımı ve kapsamı sunulmaktadır. Son olarak, modellerin öğrenme performansını doğrudan etkileyen veri ön işleme adımları ve özellik mühendisliği teknikleri ele alınarak, ham verinin analize hazır hale getirilme süreci ortaya konulmaktadır.

3.1 Görüntü İşleme

Görüntü işleme, dijital görsellerin analiz edilmesi ve iyileştirilmesi için uygulanan yöntemlerin genel adıdır. PV hücrelerin kalite kontrolünde görüntü işleme kritik öneme sahiptir. EL görüntülerinin analizinde, ham görüntü verisi üzerinde doğrudan çalışmak yerine çeşitli ön işleme teknikleri uygulamak gerekmektedir. Bu teknikler, görüntü kalitesini artırarak veya gürültü ve istenmeyen etkileri azaltarak daha başarılı kusur tespiti için zemin hazırlamaktadır.

3.1.1 Görüntü ön işleme teknikleri

Yaygın olarak kullanılan ön işlem adımlarından biri gürültü giderme (denoising) amaçlı filtrelemedir. Örneğin, Gaussian (Gauss) filtreleme sıklıkla tercih edilen yöntem olup, görüntüdeki rastgele parazitleri yumuşatarak ortadan kaldırmaktadır (Song et al., 2021). Gauss filtresi, komşu piksellerin ağırlıklı ortalamasını alarak küçük ölçekli parlaklık dalgalanmalarını bastırmaktadır. Böylece görüntüdeki kusurların daha net ortaya çıkması sağlamaktadır. Benzer şekilde, medyan filtresi de PV hücre EL görüntülerinde tuz-biber gürültüsü olarak adlandırılan noktasal parazitleri temizlemek için kullanılmaktadır. Bu filtre, her pikseli komşu parlaklık değerlerinin medyanı ile değiştirerek uç değerli gürültüleri gidermektedir. Ayrıca bilateral (çift-terafli) filtreleme gibi daha gelişmiş yöntemler de literatürde yer almaktadır. Bilateral filtre hem uzaysal yakınlığı hem de piksel değeri benzerliğini hesaba katarak bulanıklaştırma yapmaktadır. Bu sayede gürültüyü azaltırken kenar bölgelerindeki detayları korumaktadır (Kölblin et al., 2021). Böylece, örneğin çatlak kenarı ya da hücre sınırı gibi ince detaylar filtreleme sonrasında

silikleşmeden kalmaktadır. Diğer önemli ön işleme kontrast iyileştirme (kontrast artırma) adımındır. EL görüntülerinde kusurların tespiti bazen zordur çünkü kusurlu bölgelerin parlaklık farkları düşük olabilir. Bu durumda, görüntünün kontrastını yükselterek kusurlu bölgenin arka plana göre daha belirgin hale gelmesi sağlanmaktadır. Kontrast iyileştirme için yaygın teknik histogram eşitlemedir. Histogram eşitleme, görüntüde en sık rastlanan parlaklık değerlerinin dağılımını genişleterek, az temsil edilen parlaklık seviyelerinin daha görünür olmasını sağlamaktadır (Kim et al., 2021). Özellikle Uyarlamalı Histogram Eşitleme (CLAHE), EL görüntülerindeki lokal kontrastı artırmak için kullanışlıdır. Bu yöntem görüntüyü küçük bölgelere ayırıp her birinin kontrastını ayrı ayrı düzenleyerek hem genel hem de lokal düzeyde iyileştirme yapmaktadır. Böylelikle düşük kontrastlı ince çatlaklar veya hücre içi zayıf bölgeler bile daha belirgin hale gelmektedir.


Tüm bunlara ek olarak, ışıklandırma düzeltmesi ve geometrik düzeltmeler de ön işleme kapsamında değerlidir. Örneğin, EL görüntüsü alınırken sensör veya optik sistem kaynaklı ortaya çıkan kararma/vinyet etkisi varsa düzeltilebilir. Benzer şekilde, kamera kalibrasyonu ile görüntüdeki bozulmalar giderilebilir. Eşikleme (thresholding) ve morfolojik işlemler de bazen ön işleme adımı olarak kullanılmaktadır. Eşikleme ile görüntü ikili (binary) formata dönüştürülerek hücre ile arka plan ayrıştırılabilir, ardından morfolojik açma-kapama işlemleriyle küçük gürültü adacıkları temizlenip kusur bölgelerinin bütünlüğü korunmaktadır. Örneğin yapılmış bir çalışmada EL görüntüsünde PV modülün kenarlarını belirlemek için Otsu eşikleme kullanmış, ardından panel dışı arka planı maskeleyerek sadece hücrelerin analize dahil olmasını sağlamıştır (Tomasi and Manduchi, 1998). Tüm bu ön işleme teknikleri, EL görüntülerindeki kusurların daha ayırt edilebilir hale gelmesini ve sonraki analiz adımlarının (nesne tespiti, sınıflandırma veya segmentasyon) daha yüksek başarıyla gerçekleşmesini mümkün kılmaktadır. Doğru uygulanan ön işleme aşaması sayesinde, derin öğrenme modellerinin eğitimi daha kararlı olmakta ve yanlış pozitif/negatif tespit oranları azaltılmaktadır.

Bu çalışmada, literatürde yaygın olarak kullanılan klasik gürültü giderme ve kontrast iyileştirme temelli ön işleme yöntemleri yerine, derin öğrenme modelinin farklı koşullara karşı genelleme yeteneğini artırmaya odaklanılmıştır. Bu kapsamda, ham elektrolüminesans (EL) görüntüleri öncelikle modelin giriş boyutuna uygun olacak şekilde 640×640 piksel çözünürlüğüne yeniden ölçeklendirilmiş ve piksel değerleri [0–1] aralığında normalize edilmiştir. Bunun dışında, görüntü içeriğini yapay olarak

değiştirebilecek ek filtreleme adımları uygulanmamıştır. Bunun yerine modelin değişen aydınlatma, konum ve ölçek koşullarına karşı daha dayanıklı hale gelmesi amacıyla veri artırma tekniklerinden yararlanılmıştır. Uygulanan veri artırma yöntemleri arasında mozaikleme, rastgele kırpma ve parlaklık değişimleri yer almakta olup, bu yaklaşımlar sayesinde modelin farklı senaryolara uyum sağlama kabiliyeti artırılmıştır.

3.2 Fotovoltaik Hücre Yapısı ve Kusur Mekanizmaları

Kristal silisyum tabanlı fotovoltaik hücreler, güneş enerjisi dönüşümünün temel birimidir. Yapısal olarak ön yüzde ışığı toplayan şeffaf iletken tabaka ve ince metal parmaklar (fingers) bulunmaktadır. Arka yüzey ise akım toplayıcı metal kontakların bulunduğu p-n eklemlili yarıiletken diyotlardır. Hücre yüzeyine uygulanan antirefle kaplama ve optimize edilmiş metalizasyon ağı, foto-üretilen taşıyıcıların minimum kayıpla toplanmasını hedeflemektedir. Ancak bu hücreler mekanik olarak kırılgandır. Bu nedenle dış ortam koşullarına karşı korunmaları elzemdir. Bundan dolayı hücreler şekil 3.1’de katmanlı mimarisi gösterildiği üzere, dış darbelerden koruyan bir alüminyum çerçeve, ışık geçirgenliği yüksek temperli bir ön cam, yalıtımı sağlayan polimer tabakalar (genellikle EVA) ve koruyucu bir arka tabaka (backsheet) arasına lamine edilerek modül haline getirilmektedir.



Şekil 3.1: Fotovoltaik modül yapısı

Buna karşın gerek modül üretim süreci gerekse saha koşullarındaki mekanik ve termal gerilmeler, bu kompozit yapıda veya hücre seviyesinde çeşitli deformasyonlara neden olmaktadır. Ortaya çıkan bu yapısal ve elektriksel kusurlar, hücrelerin akım–gerilim karakteristiğini bozarak ciddi verim kayıplarına yol açmaktadır (Bakır ve Çiftçi, 2023; Saborido-Barba et al., 2024).


Bu çalışmada ele alınan kusur sınıfları, EL görüntülerinde gözlenebilen bozulma mekanizmalarını temsil etmektedir. Çalışma kapsamında altı farklı kusur ele alınmaktadır. Bunlardan ilki çatlak, silisyum kristalinde termomekanik gerilmeler sonucu oluşan kırık ve mikro çatlaklar, aktif alanın kısmını devre dışı bırakarak seri ve şönt dirençte değişimlere ve güç kaybına neden olmaktadır. EL görüntülerinde, bu bölgeler genellikle hücreyi kesen karanlık çizgiler veya parçalı koyu alanlar olarak görülmektedir (Bakır ve Çiftçi, 2023; Parikh et al., 2020; Saborido-Barba et al., 2024). İkincisi parmak, ön yüz metalizasyon parmaklarının kopması, incilmesi veya süresiz hale gelmesi akım toplama yolunu bozarak efektif seri direnci artırmaktadır. Bu durum da modül verimini düşürmektedir. (Köntges et al., 2011; Zhang et al., 2018; Parikh et al., 2020). Üçüncüsü siyah kusurları, hücre içerisinde ciddi iç arızayı, yoğun yeniden birleşme merkezlerini veya güçlü lokal şönt yollarını göstermektedir. EL görüntülerinde hücrenin merkezine yakın, tamamen kararmış kompakt bölgeler şeklinde ortaya çıkmaktadır. Güç çıkışında anlamlı düşümlere yol açtığı bildirilmektedir (Ozturk vd., 2024; Jia et al., 2024; Qu et al., 2024). Dördüncü olarak kısa devre, metalizasyon kusurları veya lokal şönt yolları nedeniyle ortaya çıkan kısa devre bölgeleridir. Taşıyıcıların ohmik kayıplarla hızlıca taşınmasına ve lokal ısınmaya neden olmaktadır. EL görüntülerinde bu tip kritik kusurlar çoğunlukla çok parlak noktalar veya lekeler olarak görmektedir. Ayrıca potansiyel sıcak nokta (hot-spot) riski ile ilişkilendirilmektedir (Jia et al., 2024; Qu et al., 2024). Diğer bir hata yatay kaymadır. Katmanlar arası hizalama hataları, tane sınırı kaynaklı yer değiştirmeler veya montaj toleranslarını aşan geometrik bozulmalar sonucu oluşan bu kusurdur. EL görüntülerinde hücre boyunca uzanan yatay koyu bantlar veya kaymış yapılar olarak gözlenmektedir. Derin öğrenme tabanlı çalışmalarda yatay kayma ayrı kusur sınıfı olarak modellenmiş ve yüksek doğrulukla tespit edilmiştir (Wang et al., 2022; Qu et al., 2024). Son olarak kalın çizgi kusuru ön yüz metalizasyonunun aşırı kalın basılması veya baskı hataları sonucu oluşan kalın çizgi kusurlarıdır. Yerel akım yoğunluğunu ve akım dağılımını bozarak performans kaybına neden olmaktadır. EL görüntülerinde standart parmaklara kıyasla daha geniş ve düzensiz parlak/koyu çizgiler şeklinde görülmektedir. Son yıllarda kalın çizgi hata sınıfı altında otomatik tespit modellerine dâhil edilmiştir (Wang et al., 2022; Qu et al., 2024).

Bu kusur mekanizmalarının her biri, açık devre gerilimi (V_{oc}), kısa devre akımı (I_{sc}) ve doluluk faktörü (FF) gibi elektriksel parametreler üzerinde farklı etkiler oluşturmaktadır.

Bu nedenle kusur tiplerinin doğru sınıflandırılması, güvenilir güç tahmini ve ömür analizi açısından kritik önem taşımaktadır (IEA-PVPS, 2019; Tang et al., 2020).

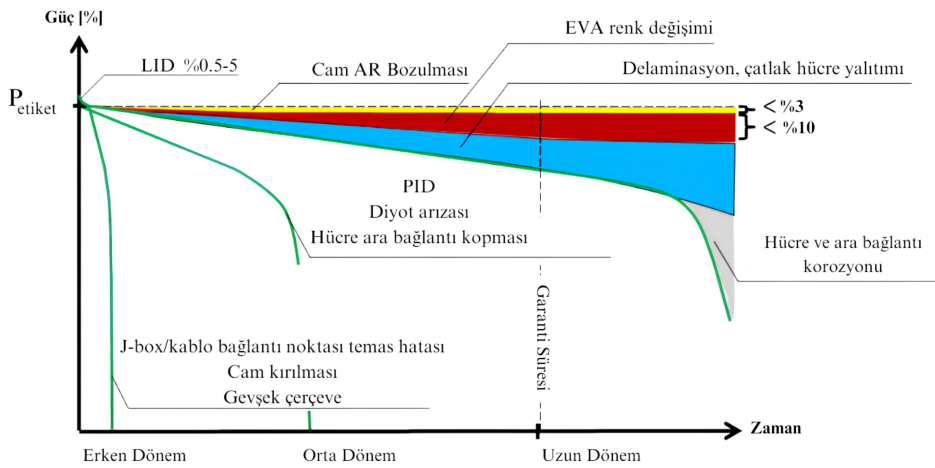
3.3 Elektrolüminesans Görüntüleme Tekniğinin Teorik Temelleri

Bölüm 3.2’de bahsedilen kusurların tespitinde kullanılan görüntüleme teknolojisinin temelini elektrolüminesans (EL) etki oluşturmaktadır. EL, bir malzemenin güçlü bir elektrik alanı veya elektrik akımı etkisiyle ışık yayması etkisidir. Güçlü elektrik alanda veya elektrik akımı geçişi sebebiyle yarı-iletken malzemelerin ışık yayması prensibine dayanmaktadır (Fuyuki et al., 2005). Temel çalışma prensibi Işık Yayan Diyot (LED) teknolojisi ile büyük benzerlik gösteren bu yöntem, fotovoltaik modüllerin adeta bir "röntgenini" çekerek hem mevcut direnç kayıplarını hem de çıplak gözle görülemeyen ve gelecekte arızaya dönüşebilecek potansiyel kusurları erken evrede görünür kılmaktadır. Bu süreçte uyarılan elektronlar, enerjilerini foton halinde boşaltarak "soğuk radyasyon" olarak da bilinen spontan sürecini gerçekleştirirler (Breitenstein et al., 2011). Işığın yayılması, bir elektronun ve bir deliğin ısınımsal rekombinasyonu ile olur ve ortaya çıkan enerji eksiton emisyonu ile serbest bırakılır. Genel itibarıyla EL yapısı, biri elektron diğeri ise boşluk yayabilen iki katmandan oluşmaktadır. Elektrotlardan en az birinin transparan olması gerekmektedir. Genellikle cam veya plastik üzerine sabitlenen Indium Tin Oxide (ITO), yüksek iletkenlik kapasitesi ve şeffaflığı nedeniyle tercih edilmektedir (Köntges et al., 2011). EL olayında ortaya çıkan aydınlığın şiddeti, doyuma ulaşınca dek uygulanan gerilim ile artış göstermektedir. Elektrolüminesans bir cihaz için uygulanan gerilimin değeri genellikle 100 ila 1000V dolaylarındadır. Yani ışık emisyonu geniş bir açıdan gözlemlenebilecek karakterdedir (Fuyuki et al., 2005; Breitenstein et al., 2011).



Şekil 3.2: Elektrolüminesans (EL) görüntüleme tekniğinin şematik çalışma prensibi

Şekil 3.2'de görüldüğü üzere, üretim tesislerinde uygulanan EL görüntüleme yöntemi, fabrika çıkışı öncesinde PV modüllerine tek tek ileri yönde akım verilmesi esasına dayanmaktadır (Özel, 2023). Bu sırada p-n eklem bölgesinde gerçekleşen rekombinasyon sürecinde yayılan IR fotonlar, uygun spektral hassasiyete sahip (genellikle silikon tabanlı CCD/CMOS veya InGaAs) kameralar ile kaydedilir. Taşıyıcı yoğunluğunun ve difüzyon uzunluğunun yüksek olduğu sağlıklı bölgeler daha fazla foton yaydığı için EL görüntüsünde parlak; kristal yapının bozulduğu veya akım yollarının koptuğu bölgeler ise karanlık görülmektedir (IEA-PVPS, 2019; Tang et al., 2020). EL görüntüleme ile tespit edilen bu kusurlar, sadece anlık bir görüntü bozukluğu değil, modülün kullanım ömrü boyunca yaşayacağı performans kayıplarının habercisidir.



Şekil 3.3: Fotovoltaik modüllerde zamana bağlı güç kaybı (degradation) mekanizmaları ve kusurların performans üzerindeki uzun vadeli etkileri

Şekil 3.3 incelendiğinde, modülün "Erken Dönem"de Işık Kaynaklı Bozulma (LID) gibi etkilerle karşılaştığı, ancak asıl riskin "Orta ve Uzun Dönem"de ortaya çıktığı görülmektedir. Özellikle hücre çatlakları, delaminasyon ve korozyon gibi EL ile tespit edilebilen kusurlar, güç çıkışını etiket değerinin altına, hatta garanti süresi sınırlarının dışına (örneğin %10'dan fazla kayıp) düşürebilmektedir. Grafikteki ani düşüş eğrileri, hücre yalıtımı ve ara bağlantı kopmalarının modül ömrünü nasıl kısalttığını somutlaştırmaktadır. Bu bağlamda EL tekniği ile mikro çatlaklar, parmak kopuklukları, şönt yolları, siyah çekirdek alanları ve kısa devre bölgeleri gibi kusurların uzamsal dağılımını doğrudan gözlemleyerek güç kayıplarının yönetilmesinde kritik rol oynamaktadır (Parikh et al., 2020; Wang et al., 2022; Bakır ve Çiftçi, 2023).

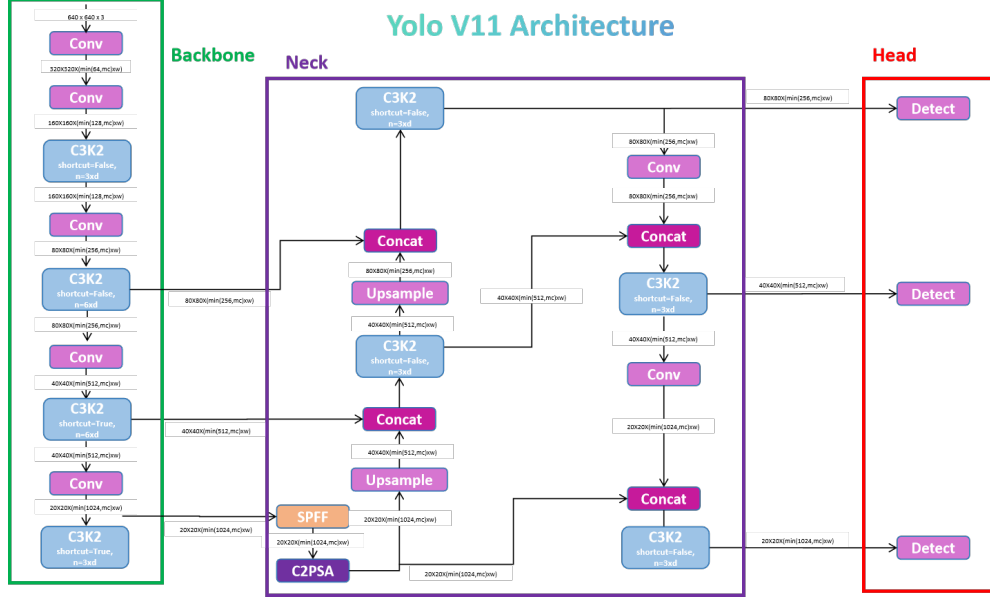
Son yıllarda, EL görüntüleri üzerinden yapılan manuel incelemelerin getirdiği zaman maliyetini ve uzman bağımlılığını azaltmak amacıyla derin öğrenme tabanlı yaklaşımlar geliştirilmiştir. Çatlak, siyah çekirdek, kalın çizgi ve yatay kayma gibi kusur sınıflarının tek model altında tespit edildiği bu sistemler, büyük ölçekli PV santrallerinde otomatik durum izleme için güçlü bir altyapı sunmaktadır.

3.4 Derin Öğrenme Tabanlı Nesne Tespiti

2015 yılında Joseph Redmon ve ekibi (Santosh Divvala, Ross Girshick ve Ali Farhadi) tarafından tanıtılan YOLO (You Only Look Once) algoritması, nesne algılama teknolojilerinde devrim niteliğinde dönüm noktası olmuştur. Önceki yöntemlerin görüntü üzerinde defalarca tarama yapıp farklı bölgeleri parça parça analiz etme stratejisinin aksine, YOLO adının da işaret ettiği gibi ("Sadece Bir Kez Bak") görüntüyü bütünsel olarak ve tek seferde işler.

Bu algoritmanın temelindeki yaklaşım, nesne algılama sürecini karmaşık ve çok adımlı sınıflandırma görevi olmaktan çıkarıp, doğrudan regresyon problemi olarak ele almasıdır. YOLO, tek güçlü CNN mimarisi kullanarak görüntünün tamamını analiz etmektedir. Bu süreçte, eş zamanlı olarak hem nesnelerin konumunu belirleyen sınırlayıcı kutuların koordinatlarını tahmin etmektedir. Hem de bu kutuların içerdiği nesnelerin sınıf olasılıklarını hesaplamaktadır. Algılamayı ve sınıflandırmayı tek ağ üzerinde birleştiren bütünlük yapı, YOLO'yu günümüzde otonom araçlardan gelişmiş güvenlik sistemlerine kadar pek çok alanda "gerçek zamanlı" hızın ve verimliliğin standart belirleyicisi haline getirmiştir (Keita, 2024). Yıllar içinde YOLOv2, YOLOv3, ..., YOLOv5 gibi versiyonlar

ile önemli mimari gelişmeler kaydetmiştir (Ding et al., 2024). YOLOv11, nesne tespiti alanındaki en yeni tek-adımlı derin öğrenme modellerinden biridir. En son iterasyon olan YOLOv11 modeli, önceki sürümlere kıyasla çeşitli mimari yenilikler içermektedir.



Şekil 3.4: Yolo11 akış diyagramı

Bu tez çalışmasında kullanılan YOLOv11 modelinin temel mimarisi ve veri akış diyagramı Şekil 3.4'te sunulmuştur (Ultralytics, 2024b). Model, derin öğrenme tabanlı nesne tespiti süreçlerinde rol oynayan Omurga (Backbone), Boyun (Neck) ve Kafa (Head) üç ana bileşenden oluşmaktadır. Omurga katmanının (yeşil çerçeve), giriş görüntüsünden (640x640x3) temel özellikleri çıkaran bir dizi konvolüsyonel katman (Conv) ve C3K2 bloklarından oluştuğu görülmektedir. Bu katman, görüntüyü farklı çözünürlük seviyelerine indirgeyerek hem düşük seviyeli (kenar, köşe) hem de yüksek seviyeli (nesne bütünlüğü) öznitelikleri yakalamaktadır. Özellikle C3K2 blokları ve SPFF (Spatial Pyramid Pooling-Fast) modülü, farklı ölçeklerdeki nesnelerin tanınmasını kolaylaştıran zengin öznitelik haritaları üretir. Modelin Boyun kısmı (mor çerçeve), omurgadan gelen farklı ölçekteki özellikleri birleştirerek (Concat) ve yukarı örnekleyerek (Upsample) nesne tespiti için gerekli olan mekansal bilgiyi zenginleştirir. C2PSA (Channel-wise Pyramid Squeeze-and-Excitation Attention) modülü ise önemli özellik kanallarına odaklanarak modelin dikkat mekanizmasını güçlendirmektedir. Son olarak, Kafa kısmı (kırmızı çerçeve), zenginleştirilmiş öznitelik haritalarını kullanarak nesnelerin sınıfını ve konumunu (bounding box) tahmin eden üç farklı ölçekteki tespit (Detect) katmanından oluşmaktadır. Bu çok ölçekli yapı, hem küçük (örn: kılcal çatlaklar) hem de büyük (örn: siyah çekirdek)

hataların aynı anda yüksek doğrulukla tespit edilmesini sağlamaktadır (Khanam and Hussain, 2024; Mukherjee, 2024).

Gerçek zamanlı nesne tespitindeki en büyük avantaj, YOLOv11 mimarisinin endüstriyel saha denetimlerinde ihtiyaç duyulan yüksek tespit başarımı ile hesaplama verimliliği arasındaki optimum dengeyi kurabilmesidir. Farklı boyutlardaki model varyantları (nano, orta, büyük gibi) sayesinde hem gömülü cihazlarda hem de yüksek performanslı sunucularda dengeli şekilde çalışmaktadır (Khanam and Hussain, 2024). Bu yönüyle, endüstriyel uygulamalarda gerçek zamanlı kusur tespiti için ideal adaydır. Nitekim fotovoltaik hücrelerdeki kusurların otomatik tespitinde YOLO tabanlı algoritmalar başarılı sonuçlar vermiştir. Örneğin, geliştirilen YOLOv5 tabanlı model, PV modüllerin EL görüntülerinde 12 farklı kusur tipini ortalama %85–87 civarında bir doğrulukla saptayabilmiştir (Ding et al., 2024). Benzer şekilde, hücre seviyesinde YOLOv4 kullanılan çalışma da %98'e varan yüksek tespit doğruluğu elde etmiştir (Song et al., 2021). YOLOv11 ile, mimari iyileştirmelerin de katkısıyla PV hücre kusur tespitinde hem doğruluğun hem de hızın daha da artması beklenmektedir. Özetle, YOLOv11 modeli, gerçek zamanlı nesne tespitindeki hız ve verimlilik geleneğini sürdürürken daha karmaşık görevleri de yerine getirebilmesi ve yüksek doğruluk sunması nedeniyle, fotovoltaik modüllerin EL görüntülerinde kusur tespitine son derece uygun ve uygulanabilir çözüm sunmaktadır.

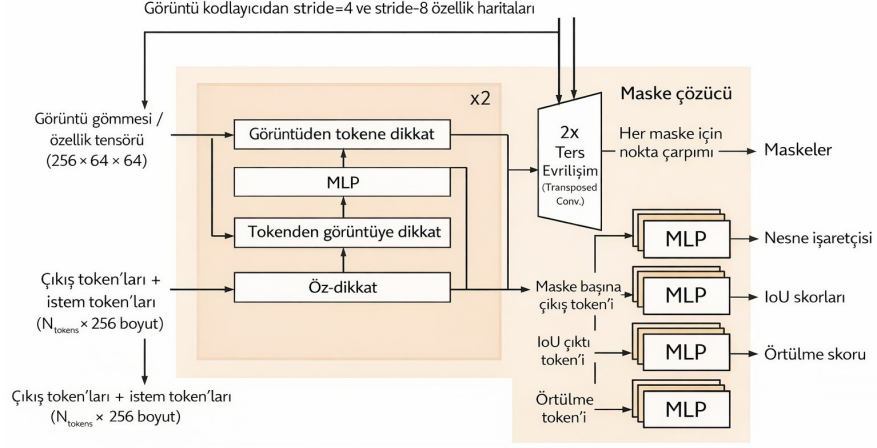
3.5 Her Seyi Bölütleyen Model (Segment Anything Model - SAM ve SAM2)

Derin öğrenme tabanlı görüntü işleme literatüründe, "temel modeller" (foundation models) olarak adlandırılan ve büyük ölçekli veri setleri üzerinde eğitilerek genelleme yeteneği kazanmış mimariler, segmentasyon görevlerinde devrim oluşturmuştur. Bu çalışmada kullanılan hibrit yapının segmentasyon katmanını anlamak için öncelikle bu mimarinin temelini oluşturan orijinal SAM yapısı ve ardından çalışmada kullanılan gelişmiş SAM 2 versiyonu ele alınacaktır.

3.5.1 Temel SAM mimarisi ve çalışma prensibi

Meta AI tarafından geliştirilen Segment Anything Model (SAM), görüntü segmentasyonunu "istemi tabanlı"(promptable) göreve dönüştüren öncü bir yaklaşımdır. Modelin temel amacı, kendisine verilen herhangi bir görüntü ve bu görüntü üzerindeki bir

ipucu (nokta, kutu veya metin) doğrultusunda geçerli bir segmentasyon maskesi üretmektir (Kirillov et al., 2023).



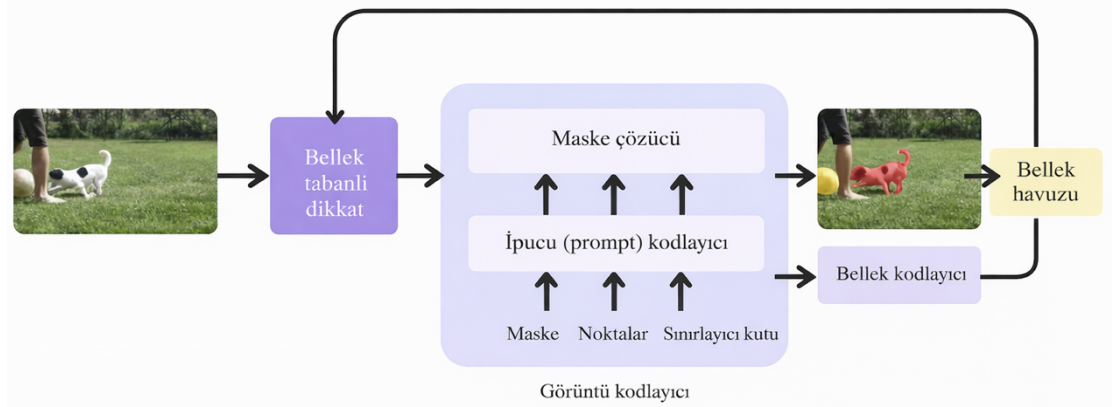
Şekil 3.5: SAM algoritma mimarisi

Görselde (Şekil 3.5) temel mimari yapısı görülen model, üç ana bileşenden oluşmaktadır. Görüntü Kodlayıcı (Image Encoder), görüntüden yüksek seviyeli öznitelikleri çıkarmak için genellikle Vision Transformer (ViT) tabanlı, ağır ve güçlü ağ kullanılmaktadır. Bu kodlayıcı, görüntü başına sadece bir kez çalışmaktadır. Bu da görüntü gömülerini (image embeddings) oluşturmaktadır. İkinci bölüm İstemi Kodlayıcı (Prompt Encoder), kullanıcıdan veya başka bir algoritmadan gelen nokta koordinatları, sınırlayıcı kutular ve metin istemlerini vektörel temsillere dönüştürmektedir. Nokta ve kutular, konumsal kodlamalar (positional encodings) ile toplanarak sisteme dahil edilmektedir. Üçüncü ve son bölüm Hafif Maske Kod Çözücü (Mask Decoder), görüntü gömüleri ile istemi gömülerini birleştiren hafif yapıdır. Transformer dekoder bloklarından esinlenen bu katman, görüntü ve istemi arasındaki ilişkiyi kurarak (cross-attention) maske olasılıklarını hesaplar ve piksel hassasiyetinde çıktı üretmektedir (Kirillov et al., 2023). Aynı zamanda SAM, 11 milyon görüntü ve 1 milyar maskeden oluşan SA-1B veri seti üzerinde eğitilmiştir. Bu geniş veri havuzu sayesinde model, eğitim sırasında hiç görmediği nesnelere dahi "sıfır atış" (zero-shot) yeteneği ile segmentlere ayırabilmektedir (Kirillov et al., 2023).

3.5.2. SAM 2

Adından da anlaşılacağı üzere, "her şeyi segmentleme" mottosuyla geliştirilen ilk SAM modelinin halefi olan SAM2, herhangi görüntü veya video karesindeki nesnelere hızlı ve esnek şekilde segmentleyebilen yapay zekâ modelidir. SAM2'nin temel prensibi, kullanıcı

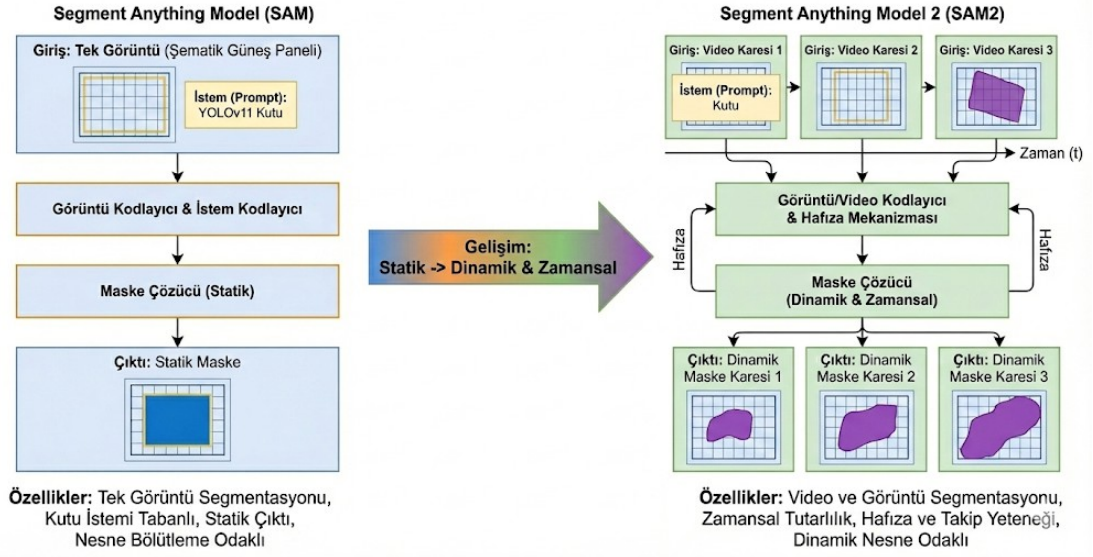
tarafından verilen basit ipuçlarıyla (örneğin bir noktaya tıklama, bir sınır çizme veya kaba bir maske verme) istenen nesnenin piksellerinin otomatik olarak ayrılmasıdır. Model, görüntü ve video segmentasyonunu tek birleşik mimaride birleştirerek, farklı ortamlarda tutarlı performans göstermeyi hedeflemektedir (Ravi et al., 2024). Bu birleşik yapı sayesinde, ayrı ayrı görüntü ve video segmentasyon modellerine ihtiyaç duymadan tek modelle her iki işi de gerçekleştirebilir. SAM2 model mimarisi şekil 3.6’da gösterilmiştir.



Şekil 3.6: SAM2 model mimarisi

SAM2'nin önemli avantajlarından biri gerçek zamanlı çalışabilmesidir. Yapılan testler, modelin yaklaşık 44 kare/saniye hızında segmentasyon yapabildiğini göstermiştir. Bu da artırılmış gerçeklik veya canlı video analizi gibi anlık geri besleme gerektiren uygulamalar için yeterince hızlı olduğunu ortaya koyar. Ayrıca SAM2, çok geniş ve çeşitlendirilmiş veri kümesiyle eğitildiği için hiç görmediği nesnelere bile sıfır-atış yeteneğiyle segmentleyebilir yani önceden tanımlı kategorilere uymayan nesnelere dahi genel öğrenmesiyle ayrıştırabilir. Bu yönü, segmentasyon kalitesini ve genellenebilirliğini önemli ölçüde artırmaktadır. Model aynı zamanda etkileşimli iyileştirme olanağı sunmaktadır. Kullanıcı, modelin çıktı maskesini beğenmezse ek ipuçları vererek sonucun adım adım düzeltilmesini sağlayabilmektedir. Bu özellikle hassas segmentasyon gereken durumlarda sonuçların mükemmelleştirilmesine imkân tanımaktadır (Ravi et al., 2024).

Fotovoltaik hücrelerde kusur tespiti bağlamında, SAM2'nin sunduğu bu güçlü segmentasyon kabiliyetleri oldukça değerlidir. EL görüntülerinde tespit edilen kusurlar sadece dikdörtgen kutu içinde saptanmaktansa piksel düzeyinde maskelenerek kusurun konumu ve şekli çok daha kesin olarak belirlenmektedir. (Ravi et al., 2024).



Şekil 3.7: SAM ve SAM2 Uygulamalarında şematik karşılaştırmalı analizi


Görüntü segmentasyonu alanındaki güncel yaklaşımlar incelendiğinde, Meta AI tarafından geliştirilen temellerin şekil 3.7 üzerinde karşılaştırmalı olarak sunulduğu görülmektedir. Şeklin sol panelinde yer alan orijinal Segment Anything Model (SAM), temel olarak statik ve tekil görüntülerin analizi üzerine kurgulanmıştır. Bu mimari görüntü kodlayıcı, kullanıcı etkileşimlerini (nokta, kutu vb.) işleyen istem kodlayıcı ve bu iki akışı birleştirerek segmentasyon maskesini üreten hafif bir maske çözücünden oluşmaktadır. SAM, tek karelik analizlerde yüksek bir genelleştirme başarısı gösterse de kareler arası zamansal ilişkiyi kuracak bir mekanizmaya sahip değildir.

Buna karşın, tez çalışmasında hibrit mimariye entegre edilen SAM 2 sağ panelde şematize edildiği üzere, selefının statik yapısını aşarak dinamik video verilerini işleyebilecek 'Hafıza (Memory)' ve 'Zamansal Tutarlılık' modülleri ile güçlendirilmiştir. Şekildeki akış diyagramından da izlenebileceği gibi, SAM 2 sadece o anki kareyi işlemekle kalmaz, aynı zamanda geçmiş karelerden elde edilen öznitelikleri ve maske bilgilerini bir 'Bellek Bankası'nda depolamaktadır. Maske çözücü, o anki karenin segmentasyonunu gerçekleştirirken bu bellek modülünden gelen bağlamsal veriyi de sürece dahil etmektedir. Bu yapısal evrim, modelin sadece anlık görüntüdeki hatayı tespit etmesini değil, aynı zamanda hatanın video akışı boyunca takibini ve olası kapanma durumlarında dahi kararlı bir şekilde segmentasyonun sürdürülmesini mümkün kılmaktadır. Dolayısıyla SAM 2, fotovoltaik panellerin ister manuel veyahut ister drone ile taranması gibi video tabanlı

dinamik süreçlerde, statik SAM mimarisine kıyasla çok daha üstün ve tutarlı bir performans sunmaktadır.

3.6 YOLOv11 + SAM2 Tabanlı Modelleme Yaklaşımı

Fotovoltaik hücrelerdeki mikro kusurların tespitinde hem gerçek zamanlı hız hem de piksel düzeyinde hassasiyet elde etmek amacıyla hibrit model kullanılmıştır. Bu model içeriğinde nesne tespitinde uzmanlaşmış YOLOv11 mimarisi ile segmentasyon alanında temel model kabul edilen SAM2'nin ardışık olarak entegre edildiği hibrit yapı geliştirilmiştir.



Şekil 3.8: YOLOv11 + SAM2 hibrit yaklaşım modeli

Şekil 3.8'de detaylandırılan bu mimari akışta süreç, ham elektrolüminesans görüntüsünün YOLOv11 tespit katmanına iletilmesiyle başlamaktadır. Burada model, eğitildiği kusur sınıfları için olasılık haritaları çıkararak kusurlu bölgelerin koordinatlarını belirlemektedir. Elde edilen bu sınırlayıcı kutu koordinatları, sistem tarafından SAM2 modelinin anlayabileceği tensör formatına dönüştürülür. Ardından birer "kutu istemi" olarak segmentasyon modülüne aktarılır. SAM2, kendisine sunulan uzamsal kılavuzları referans olarak, herhangi ek ince ayar eğitimine ihtiyaç duymadan kutu içerisindeki kusurun morfolojik sınırlarını analiz eder. Arka plandan ayrıştırılmış hassas piksel maskesini üretir.

Bu tez çalışmasında kullanılan SAM 2 mimarisi, doğası gereği geniş ölçekli veri setlerinde ön eğitimden geçmiş bir 'temel model' olduğu için fotovoltaik kusur veri seti üzerinde sıfırdan bir eğitime veya ince ayara tabi tutulmamıştır. Bunun yerine, modelin sahip olduğu güçlü 'sıfır-atış' genelleme yeteneğinden faydalanılarak doğrudan çıkarım aşamasında sisteme entegre edilmiştir. Geliştirilen hibrit boru hattında, YOLOv11 modelinin %80-10-10 dağılımında elde ettiği yüksek doğruluklu sınırlayıcı kutular, SAM 2 algoritmasına yönlendirici bir 'kutu istemi' olarak beslenmiştir. Bu implementasyon stratejisi, modeli spesifik kusurlar için yeniden eğitiminin getireceği yüksek donanım ve zaman maliyetini

ortadan kaldırmıştır. Aynı zamanda çokgen etiketleme ihtiyacını sıfıra indirerek endüstriyel uygulanabilirliği yüksek bir otonom sistem ortaya koymuştur.

3.7 YOLOv11-seg Yaklaşımı

Ultralytics ekibi tarafından 27 Eylül 2024 tarihinde YOLOVision etkinliğinde tanıtılan YOLOv11, YOLO serisinin en güncel sürümü olup, gelişmiş özellik çıkarma yetenekleri, optimize edilmiş mimari tasarımı ve iyileştirilmiş eğitim prosedürleri ile öne çıkmaktadır (Ultralytics 2024c, 2024d). Serinin örnek bölümlenme görevleri için özelleştirilmiş versiyonu olan YOLOv11-seg, nesne tespiti ile piksel düzeyinde sınıflandırma yaparak bütüncül olarak anlamsal analiz imkânı sunmaktadır. Model, yalnızca nesne sınır kutularını değil, aynı zamanda nesne maskelerini, sınıf etiketlerini ve güven skorlarını da eş zamanlı olarak üretmektedir.

YOLOv11-seg mimarisi temel olarak omurga, boyun ve baş olmak üzere üç ana bileşenden oluşmaktadır. Modelin özellik çıkarma performansını artırmak amacıyla, önceki sürüm olan YOLOv8'deki C2f modülü yerine C3k2 modülü entegre edilmiştir. C3k2 modülü, 2x2 konvolüsyonel çekirdekler kullanan modifiye edilmiş Kısmi Çapraz Aşama (Cross-Stage Partial) yapısıdır. Bu yapı, gereksiz hesaplama yükünü azaltırken sınır belirsizliklerini netleştirmektedir. Özellikle küçük nesnelerin tespitinde detayların hassas yakalanmasını sağlamaktadır (Khanam and Hussain, 2024). Buna ek olarak, mimarinin omurga kısmında Uzamsal Piramit Havuzlama (SPPF) modülünden sonra C2PSA (Stage Partial with Spatial Attention - Cross) modülü eklenmiştir. C2PSA, uzamsal ve kanal etkileşimlerini ayrıştırarak modelin karmaşık arka planlarda veya kısmi tıkanıklık (occlusion) durumlarında önemli bölgelere odaklanma yeteneğini artırmaktadır (Ultralytics, 2026). Boyun bileşeni, Özellik Piramit Ağı (FPN) yapısını kullanarak farklı ölçeklerdeki özellikleri birleştirir ve bu sayede modelin değişken boyutlardaki hedeflere karşı duyarlılığı artırılır.

YOLOv11-seg, hesaplama kaynaklarına ve performans gereksinimlerine göre ölçeklenebilen beş farklı varyasyona (n: nano, s: small, m: medium, l: large, x: extra-large) sahiptir. Model boyutu büyüdükçe (n'den x'e doğru), parametre sayısı ve kayan nokta işlem (FLOPs) miktarı artmaktadır. Bu durum çıkarım süresini uzatmakla birlikte ortalama hassasiyet (mAP) değerlerinde artış sağlamaktadır (Ultralytics 2024c, 2024d).

Bu çalışmada, doğruluk ve gerçek zamanlı işlem performansı arasındaki denge gözetilerek ve literatürdeki benzer segmentasyon görevlerinde gösterdiği yüksek uyarlanabilirlik nedeniyle YOLOv11-seg mimarisi karşılaştırmalı analizler için temel alınmıştır.

Tablo 3.1: YOLOv11, YOLOv11-seg, SAM ve SAM 2 modellerinin karşılaştırmalı analizi

Özellik / Kriter	YOLOv11	YOLOv11-seg	SAM	SAM 2
Temel Görev	Nesne tespiti	Örnek bölümlenme	İstem tabanlı görüntü bölümlenme	İstem tabanlı video ve görüntü bölümlenme
Mimari Tabanı	CNN (C3k2, C2PSA)	CNN (C3k2, C2PSA + Proto Mask Branch)	Ağır Kodlayıcı (Vision Transformer -ViT)	Hierarchical Masked Autoencoder (Hiera) + Bellek Bankası
Çıktı Formatı	Sınırlayıcı Kutu + Sınıf	Sınırlayıcı Kutu + Piksel Maskesi	Piksel Maskesi	Piksel Maskesi + Zamansal Tutarlılık
Girdi Gereksinimi	Sadece Görüntü	Sadece Görüntü	Görüntü + İstem (Nokta, Kutu, Metin)	Görüntü/Video + İstem (Nokta, Kutu)
Sıfır-Atış (Zero-Shot) Yeteneği	Düşük (Özel veri seti ile eğitim şart)	Düşük (Poligon etiketli veri seti ile eğitim şart)	Çok Yüksek (Eğitilmediği nesnelere ayırabilir)	Çok Yüksek (Video kareleri arasında da genelleme yapar)
Eğitim Verisi İhtiyacı	Etiketli kutular	Etiketli çokgenler	Genellikle ön eğitilmiş kullanılır	Genellikle ön eğitilmiş kullanılır
Gerçek Zamanlı Hız	Çok hızlı (High FPS)	Hızlı (Tespiti göre marjinal yavaşlama)	Yavaş (Görüntü kodlama süresi yüksek)	Optimize edilmiş hız (~44 FPS, SAM v1'den çok daha hızlı)
Video/Bellek Yeteneği	Kareler arası ilişki kurmaz (Statik)	Kareler arası ilişki kurmaz (Statik)	Kareler arası ilişki kurmaz (Statik)	Var (Bellek Bankası ile nesneyi video boyunca takip eder)
Bu Tezdeki Rolü	Hibrit modelde kusurun yerini (Kutu) bulmak için kullanılır.	Karşılaştırma modeli (Benchmark) olarak kullanılır.	Kullanılmadı	Hibrit modelde kutu içindeki kusurun hassas maskesini çıkarmak için kullanılır.

4. METODOLOJİ

Bu bölümde, PV modüllerin EL görüntüleri üzerinden kusur tespiti ve segmentasyonu gerçekleştirmek amacıyla izlenen deneysel yol haritası ve uygulama süreçleri detaylandırılmaktadır. Bölüm içeriği, veri setinin yapılandırılmasından başlayarak modelin eğitim, optimizasyon ve nihai doğrulama aşamalarına kadar olan teknik adımları kapsayacak şekilde kurgulanmıştır. İlk olarak, çalışmanın temelini oluşturan EL2021 veri seti ve saha çalışmalarından elde edilen manuel görüntülerin kaynakları, istatistiksel dağılımı ve modelin genelleme yeteneğini artırmak için uygulanan eğitim-doğrulama-test bölümleri açıklanmaktadır (Bölüm 4.1). Ardından, görüntü işleme tabanlı klasik özellik çıkarma teknikleri ile derin öğrenme tabanlı otomatik özellik çıkarımı arasındaki ilişki ve bu çalışmadaki yaklaşım ele alınmaktadır (Bölüm 4.2). Geliştirilen hibrit sistemin veri hazırlamadan sonuç analizine kadar olan tüm çalışma mantığını görselleştiren genel akış diyagramı ve evreleri tanımlanmaktadır (Bölüm 4.3). Modelin başarısını objektif ölçütlerle değerlendirmek için kullanılan Karmaşıklık Matrisi, IoU, mAP ve F1-Skoru gibi performans metrikleri ile modelin öğrenme sürecini iyileştiren hiperparametre optimizasyonu (Grid, Random ve Bayesyan arama) ve veri artırma stratejileri detaylandırılmaktadır (Bölüm 4.4). Son olarak, çalışmanın bilimsel tekrarlanabilirliğini sağlamak adına deneylerin gerçekleştirildiği deney ortamı donanım ve yazılım altyapısı ayrılarak detaylandırılmıştır (Bölüm 4.5).

4.1 Veri Seti

Araştırma kapsamında kullanılan veri seti, Roboflow Universe platformu üzerinden ve güneş paneli tarlası olan küçük çiftçilerden manuel çekilen görüntüler ile temin edilmiştir. Roboflow Universe platformu üzerinden kullanılan veri setinin EL2021 v13 (08.08.2024) sürümü tercih edilmiştir. Bu sürüm, derin öğrenme tabanlı nesne tespit modelleriyle doğrudan entegre olabilen ve YOLO ailesi algoritmalarıyla tam uyumlu olan formatta yapılandırılmıştır. Veri seti, farklı aydınlatma koşulları ve üretim hatalarını barındıran geniş ölçekli elektrolüminesans görüntü havuzu sunarken veri seti ile uyumlu manuel görüntülerde bu havuza katkı sağlanmıştır.

4.1.1 Veri setinin istatistiksel özellikleri ve bölünmesi

EL2021 v10 veri seti, toplam 12.040 adet anotasyonlu görüntüden oluşmaktadır. Çalışma kapsamında manuel olarak toplanan ek EL görüntülerinin de havuza dahil edilmesiyle veri seti genişletilmiş ve nihai toplam örnek sayısı 13.631'e ulaşmıştır. Modelin öğrenme sürecinde sınıf dengesizliğinin etkisini azaltmak ve genelleme performansını artırmak amacıyla veri setindeki kusur sınıf yapısı sadeleştirilerek 7 ana hata sınıfı altında yeniden düzenlenmiştir. Tüm görüntüler, eğitim sürecinde giriş boyutunun tutarlı olması ve ölçek kaynaklı hataların azaltılması amacıyla 640×640 piksel çözünürlüğünde standartlaştırılmıştır. YOLOv11-seg mimarisi, nesne tespiti ile piksel düzeyinde maske üretimi gerçekleştirmesinden dolayı veri seti anotasyonları iki bileşeni kapsayacak şekilde hazırlanmıştır. İlki her kusur için sınıf etiketi ve normalize edilmiş sınır kutusu bilgileri (merkez koordinatları ile genişlik–yükseklik). İkincisi kusur bölgesini temsil eden segmentasyon poligon/mask bilgisidir. Bu sayede model, kusurun konumunu sınır kutusu düzeyinde tespit ederken, aynı anda kusur alanını maske olarak öğrenebilmiştir.

Etiketleme işlemleri YOLO formatına uygun şekilde gerçekleştirilmiştir. Sınıf kimliği ile normalize merkez (x,y) ve genişlik–yükseklik (w,h) değerleri kullanılmıştır. Ayrıca YOLOv11-seg için segmentasyon etiketleri her nesneye ait sınırları tanımlayan poligon noktaları üzerinden sağlanmıştır. Böylece hem tespit (detection) hem de örnek bölütleme (instance segmentation) görevleri aynı veri yapısı üzerinden uçtan uca öğrenilebilir olmuştur. Bu süreçte özellikle düşük kontrastlı ve ince yapılı kusurların (ör. çatlak) daha hassas biçimde ayrıştırılabilmesi için YOLOv11-seg modelinin maske tabanlı temsil gücünden yararlanmayı hedeflemektedir.

Model eğitimi, hiperparametre optimizasyonu ve nihai performans değerlendirme süreçlerinin sağlıklı şekilde yürütülebilmesi amaçlanmıştır. Bu bağlamda veri seti, eğitim (train), doğrulama (validation) ve test olmak üzere üç ana alt kümeyle ayrılmıştır. Aşırı öğrenme (overfitting) riskini kontrol altında tutmayı hedefleyen bu veri bölme işlemi için iki farklı strateji uygulanmıştır. İlk stratejide veri seti %70-15-15 oranında bölünmüştür. Bölünün veri seti görsel içerik sayılarına incelendiğinde modelin ağırlıklarını öğrenmesi için kullanılan 9.543, eğitim sırasındaki başarımın izlendiği doğrulama seti 2.044 ve modelin ilk kez karşılaşacağı verilerle nihai başarısının ölçüldüğü test setine ise yine 2.044 görüntü atanmıştır. İkinci stratejide ise veri havuzu %80-10-10 oranında paylaştırılmıştır.

Bu dağılımda veri miktarının ağırlığı eğitime verilerek eğitim setine 10.905, doğrulama setine 1.363 ve test setine 1.363 görüntü ayrılmıştır.

4.2 Özellik Çıkarma ve Seçim Teknikleri

Görüntü tabanlı kusur tespitinde, ham görüntü piksellerinden anlamlı özellikler çıkarılması ve bu özellikler arasından en ayırt edici olanların seçilmesi, özellikle derin öğrenme öncesi klasik yaklaşımlarda önemli adımlardır. Özellik çıkarma, görüntünün belirli yönlerini nicelleştirerek ifade etme sürecidir. PV hücrelerinin EL görüntülerinde tespit edilmek istenen kusurlar için pek çok özellik tanımlanabilir. Örneğin, çatlak kusuru için kenar tabanlı özellikler (çatlaktaki kenar uzunluğu, doğrusal yapısı), şekil özellikleri (kusurun alanı, çevresi, dikdörtgensellik oranı), doku (tekstür) özellikleri (Haralick özellikleri vb.) ve parlaklık özellikleri (ortalama gri değer, kontrast farkı) kullanılabilir.

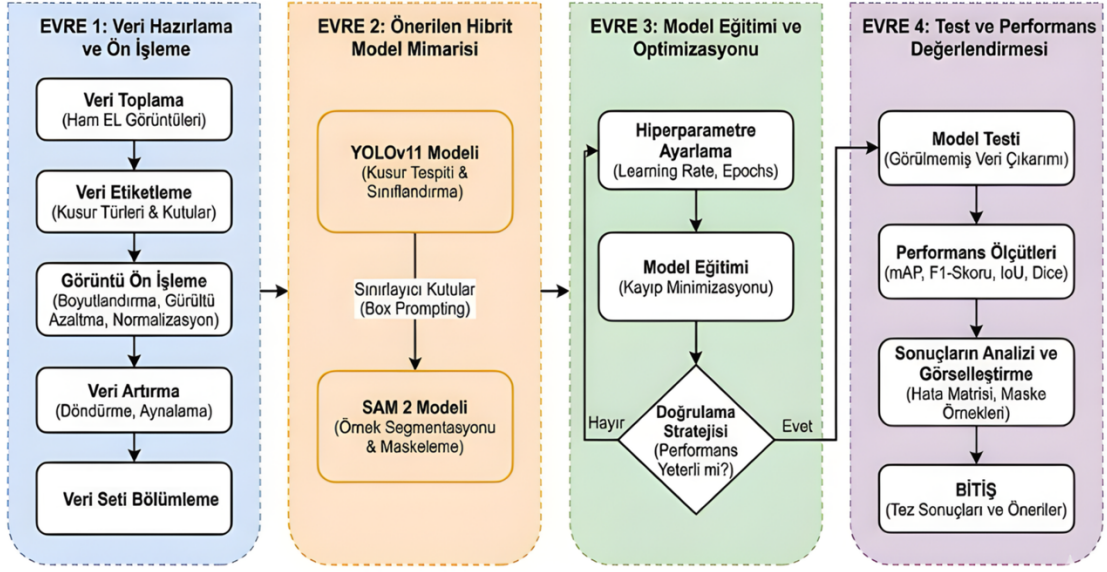
EL görüntülerindeki kusurlar çoğu zaman doku ve şekil farklılıklarıyla ayırt edilir. Mikro çatlaklar ince koyu çizgiler şeklinde görünürken, lehim bağlantı kusurları belirli doku paterni olarak ortaya çıkmaktadır. Literatürde dalgacık dönüşümü tabanlı özellik çıkarma gibi gelişmiş yöntemler de yer almaktadır. Yapılmış bir çalışmada, EL görüntülerinin farklı frekans bantlarındaki alt görüntülerinin dalgacık enerji seviyeleri hesaplanarak, bu enerji değerleri kusur tespitinde ayırıcı özellikler olarak kullanılmıştır (Scharcanski, 2005; Yang, Pang ve Yung, 2005; Joo, Han ve Park, 2010). Bu tür çok ölçekli yaklaşımlar, özellikle hem makro düzeydeki hem de mikro düzeydeki kusurları aynı anda tespit edebilmek için faydalıdır.

Çok sayıda özellik çıkarıldıktan sonra, özellik seçimi aşamasıyla en anlamlı ve modelin başarısına en çok katkı sağlayan özellik alt kümesi belirlenir. Tüm özelliklerin kullanılması, yüksek boyutluluk (hesaplama zorluğu) ve bazı özelliklerin yarardan çok gürültü getirmesi gibi sorunlara yol açabilmektedir. Bu nedenle, en uygun özellikleri seçmek için filtre yöntemleri, sarmalayıcı yöntemler ve gömülü yöntemler gibi teknikler uygulanmaktadır. Bu yöntemler sayesinde hem modelin performansını yükselten hem de yorumlanabilirliği artıran özellikler belirlenmektedir. Derin öğrenme modellerinin yükselişiyle birlikte, görüntülerden elle özellik çıkarma ve seçme ihtiyacı büyük ölçüde azalmıştır. CNN gibi mimariler, katmanlarındaki filtreler aracılığıyla görüntülerden otomatik olarak özellik öğrenebilir. Bu öğrenilen özellikler, insan tarafından tanımlanan kenar, doku vb. özelliklere çoğu zaman üstünlük sağlamaktadır. Zira CNN'ler çok daha karmaşık ve veriyle uyumlu

temsil biçimlerini kendiliğinden keşfeder (Hussain et al., 2023). Derin öğrenme, geri yayılım algoritması sayesinde hangi piksellerin kusur açısından önemli olduğunu kendi başına öğrenir ve ağırlık filtre ağırlıklarını buna göre uyarlar. Yine de derin öğrenme modelleriyle entegrasyon bağlamında elle çıkarılan özelliklerin tamamen terk edildiği söylenemez. Bazı hibrit yaklaşımlar, derin ağların son katmanından elde edilen derin özellikleri alarak bunları ayrı sınıflandırıcıda kullanmakta veya birden fazla derin modelden çıkan özellikleri birleştirmektedir. Farklı bir çalışmada, Inception-v3 ve ResNet50 gibi iki farklı CNN modelinin ürettiği derin özellikler birleştirilmiş ve elde edilen vektör ile EL görüntülerindeki kusurlar başarılı şekilde ayrıştırılmıştır (Al-Waisy et al., 2022). Sonuç olarak, geçmişte PV hücre kusur tespitinin temelini oluşturan özellik çıkarma teknikleri, günümüzde derin öğrenmenin otomatik özellik çıkarma gücüyle entegre edilerek daha yüksek doğrulukta kusur tespisi sağlamaktadır.

Geleneksel görüntü işleme tabanlı yaklaşımlarda, kenar bulma, doku analizi ve şekil tanımlayıcıları gibi özellikler uzman bilgisine dayalı olarak manuel biçimde tasarlanmakta ve ardından özellik seçimi aşamasıyla en ayırt edici alt küme belirlenmektedir. Ancak bu tez çalışmasında kullanılan YOLOv11 mimarisi, özellik çıkarma ve seçme süreçlerini Evrişimli Sinir Ağları (CNN) katmanları aracılığıyla uçtan uca ve otonom olarak gerçekleştirmektedir. Şekil 3.4'te sunulan omurga yapısı, görüntüyü farklı uzamsal ölçeklerde analiz ederek ham piksel verilerinden kenar, köşe ve karmaşık doku bilgilerini otomatik olarak öğrenmektedir. Bu yaklaşım sayesinde manuel özellik tasarımının getirdiği öznellik ve ek hesaplama maliyeti ortadan kaldırılmış, modelin veriyle uyumlu ve daha ayırt edici temsiller öğrenmesi sağlanmıştır.

4.3 Akış Diyagramı



Şekil 4.1: Akış diyagramı

Önerilen hibrit derin öğrenme yaklaşımının genel çalışma prensibi ve işlem adımları şekil 4.1'de şematize edilmiştir. Akış diyagramında görüldüğü üzere, metodoloji birbirini tamamlayan dört temel evre üzerine kurgulanmıştır. İlk evre veri hazırlama ve ön işleme, ham EL görüntülerinin toplanmasıyla başlamaktadır. Etiketleme, gürültü azaltma, normalizasyon ve veri artırma adımlarıyla veri seti model eğitime hazır hale getirilmektedir. İkinci olarak çalışmanın temelini oluşturan bu aşamada, YOLOv11 modeli tespit ettiği kusurların sınırlayıcı kutu koordinatlarını çıkarmaktadır. Ardından bu koordinatlar SAM2 modeline "kutu istemi" olarak iletilerek hassas segmentasyon sağlanmaktadır. Ardından eğitim ve optimizasyon evresi olarak 3. evrede model, belirlenen hiperparametreler ve kayıp fonksiyonları doğrultusunda eğitilmekte, doğrulama stratejileri ile performansı sürekli izlenerek optimize edilmektedir. Son olarak 4. evrede test ve değerlendirmede eğitilen model görülmemiş test verileri üzerinde çalıştırılmaktadır. F1-Skoru, mAP ve IoU gibi metrikler kullanılarak elde edilen sonuçlar analiz edilmektedir.

4.4 Model Doğrulama ve Optimizasyon

Bu bölümde, geliştirilen hibrit derin öğrenme modelinde elde edilen sonuçların güvenilirliğini doğrulamak amacıyla başvurulan yöntemler ele alınmaktadır. İlk olarak, model çıktı sonuçlarını en iyi yorumlamak ve için model performans ölçütleri göz önüne alınmıştır. Ardından modelin başarısını doğrudan etkileyen öğrenme parametrelerinin en

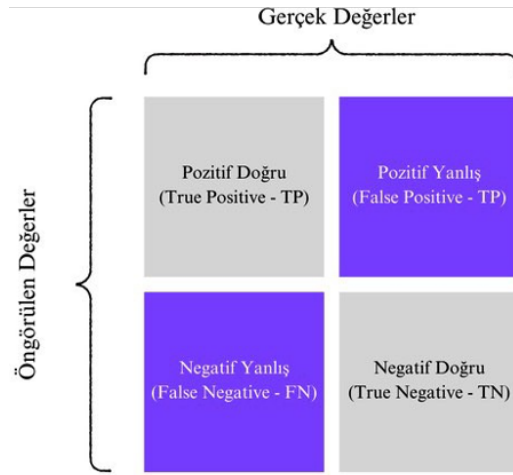
uygun deęerlerini belirlemek iin kullanılan hiperparametre optimizasyonu teknikleri tercih edilen yaklařımlar aıklanmaktadır. Ardından, modelin genelleme yeteneęini lmek ve ařırı ęrenme riskini dřrmek iin uygulanan doęrulama yntemleri ile veri artırma, transfer ęrenimi ve erken durdurma gibi performans artırma stratejileri detaylandırılmaktadır.

4.4.1 Model performans ltleri

Makine ęrenimi ve zellikle derin ęrenme modellerinin bařarımını objektif olarak deęerlendirmek iin eřitli performans metrikleri kullanılmaktadır. Bu metrikler, modelin tahminlerinin gereęe ne kadar yakın olduęunu farklı aılardan lmeyi saęlamaktadır. Ařaęıda bu alıřmada kullanılan temel performans ltleri tanıtılmakta ve matematiksel olarak ifade edilmektedir.

4.4.1.1 Karmařıklık matrisi (confusion matrix)

Karmařıklık matrisi, yapılan tahminlerin sınıflandırma modelinde yer alan daęılımını gsteren tablodur. Modelin doęru ve yanlış tahminlerini Őekil 4.2’de drt farklı blme ayırarak analiz etmektedir (Salmi et al., 2023):



Őekil 4.2: Karmařıklık matrisi deęer gsterim tablosu

Bu matris, yanlış pozitif (FP) ve yanlış negatif (FN) modelin yaptıęı hata trlerini belirlenmektedir. (Stehman, 1997). Ayrıca hata matrisi dengesiz veri kmelerinde modelin bařarılarını deęerlendirmeye olumlu ynde katkı saęlamaktadır. Son olarak belirtmek gerekirse kesinlik-duyarlılık ve ROC eęrilerinin temelini oluřturmaktadır (Hand and Till, 2001).

4.4.1.2 Kesişim - birleşim oranı (intersection over union - IoU)

Nesne tespiti ve görüntü segmentasyonu gibi görevlerde sıkça kullanılan IoU, model tarafından öngörülen bölge ile gerçek bölgenin ne kadar örtüştüğünü ölçmektedir. Matematiksel olarak IoU, öngörülen bölge ile gerçek bölgenin kesişim alanının, bu bölgelerin birleşim alanına oranı olarak tanımlanmaktadır. Bu tanım denklem 4.1’de gösterilmektedir (Gad and Skelton, 2024). IoU değeri 1.0 ise tam örtüşme, 0.0 ise örtüşme olmadığını belirtmektedir. Genellikle eşik değer (ör. 0.5) üzerinde IoU elde eden tespitler doğru pozitif kabul edilmektedir. IoU, modelin konumlama doğruluğunu anlamada temel rol oynamaktadır.

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} \quad (4.1)$$

4.4.1.3 Kesinlik (precision)

Modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Yani modelin yanlış pozitif (false positive) alarm verme eğilimini ölçmektedir. Matematiksel olarak;

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4.2)$$

Denklem 4.2 şeklinde tanımlanmaktadır (Apache Spark). Burada TP (True Positive) modelin doğru pozitif tahmin sayısı, FP (False Positive) ise modelin pozitif olarak işaretlediği ancak gerçekte pozitif olmayan (yanlış alarmlar) sayısıdır. Kesinlik değeri 1’e yaklaştıkça, modelin ürettiği pozitif tahminlerin büyük çoğunluğunun doğru olduğu anlaşılmaktadır.

4.4.1.4 Duyarlılık (recall)

Modelin gerçek pozitif örnekleri ne kadarını yakalayabildiğini göstermektedir. Başka deyişle, modelin kaç yanlış negatif (false negative) bıraktığını ölçmektedir. Matematiksel olarak;

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4.3)$$

Denklem 4.3 ile ifade edilmektedir (Apache Spark). FN (False Negative), modelin pozitif olması gereken durumu atlaması, yani yanlış şekilde negatif olarak sınıflandırması

durumudur. Duyarlılık değeri 1'e (veya %100'e) yaklaştıkça, modelin pozitif örnekleri eksiksiz yakaladığı anlaşılır. Duyarlılık ve türevlilik genellikle kesinlik/duyarlılık dengesi şeklinde değerlendirilmektedir. Birini artırmak diğerini düşürebilir, bu nedenle her ikisini birden dikkate alan ölçütler kullanmak yaygındır.

4.4.1.5 F1 skor

Kesinlik ve duyarlılık arasında denge kuran ve ikisini tek değerde harmanlayan ölçüttür. F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır (Ultralytics, 2024a).

$$F1 = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4.4)$$

Denklem 4.4 şeklinde de ifade edilmektedir (Powers, 2020). Özellikle dengesiz veri setlerinde veya sınıf dağılımı bozuk problemlerinde, F1 skoru modelin genel başarısını özetleyen faydalı metriktir.

4.4.1.6 Ortalama kesinlik (average precision - AP) ve ortalama hassasiyetin ortalaması (Mean Average Precision - mAP)

Nesne tespiti problemlerinde AP, modelin belirli sınıf için farklı eşikdeğerleri boyunca gösterdiği performansı tek skorda özetleyen ölçüttür. AP, kesinlik-duyarlılık eğrisi altında kalan alan olarak tanımlanmaktadır. Kesinlik ile duyarlılık değerlerinin, duyarlılık 0'dan 1'e artarken gösterdiği değişime göre hesaplanmaktadır. AP, her sınıf için ayrı ayrı hesaplanmaktadır. Eğri altındaki alan 1'e (veya %100'e) yaklaştıkça, modelin o sınıfa ait nesnelere yüksek doğrulukla tespit ettiği kabul edilir (Ultralytics, 2024a). mAP ise, birden fazla sınıfın bulunduğu durumlarda tüm sınıflar için hesaplanan AP değerlerinin aritmetik ortalamasını ifade etmektedir. Örneğin, N adet nesne sınıfı varsa, her sınıf için elde edilen AP_1, AP_2, \dots, AP_N değerlerinin ortalaması alınarak mAP elde edilmektedir. Böylece mAP, modelin yalnızca tek sınıftaki başarısını değil, tüm sınıflar üzerindeki genel tespit performansını özetleyen tek metrik sunmaktadır. Nesne tespiti yarışmalarında ve literatürde sıkça kullanılan mAP, farklı IoU eşiklerinde değerlendirilebilir. Bu çalışmada hem $mAP@0.50$ (IoU = 0.50 eşik değerinde AP ortalaması) hem de $mAP@0.50:0.95$ (IoU'nun 0.50 ile 0,95 arasında değiştiği çoklu eşiklerde ortalama AP) raporlanmıştır.

4.4.1.7 Doğruluk (accuracy)

Doğruluk gibi temel ölçütler de bulunmaktadır. Başarı oranı, modelin tüm örnekler içinde doğru doğru tespit ettiği örneklerin oranıdır (Powers, 2020);

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.5)$$

Hata oranı 1 ise doğru olarak hesaplanmaktadır. Modelin yaptığı yanlış tahminlerin oranını göstermektedir. Ancak, özellikle bu çalışmada olduğu gibi nesne tespiti ve segmentasyon problemlerinde doğruluk tek başına anlamlı ölçüt değildir. Zira büyük arka plan bölgelerinde nesne olmamasını “doğru” sayarak yapay olarak yüksek doğruluk elde etmek mümkün olabilmektedir. Bu nedenle IoU, kesinlik, duyarlılık, F1 ve mAP gibi daha ayrıntılı metrikler kullanmak, modelin başarısını ve hatalarını daha iyi analiz etmemize imkân tanımaktadır. Örneğin, modelin genel doğruluğu yüksek olsa bile düşük duyarlılık değeri, modelin birçok pozitif örneği kaçırdığını göstermektedir. Benzer şekilde yüksek hassasiyet fakat düşük doğruluk, modelin çoğu zaman hiçbir tahminde bulunmayarak hatadan kaçındığını ancak pozitifleri de atladığını gösterebilmektedir. Dolayısıyla başarı ve hata oranları, yukarıdaki metriklerle birlikte değerlendirilmelidir. Bu çalışmada, tüm bu ölçütler kullanılarak model performansı kapsamlı şekilde incelenmiştir.

4.4.1.8 Kayıp fonksiyonları (Loss functions)

Derin öğrenme modellerinin eğitim sürecindeki temel amacı, tahmin edilen değerler ile gerçek etiketler arasındaki farkı en düşük olarak çıkarmaktır. Literatürde, özellikle odaklanmış IoU tabanlı kayıp fonksiyonlarının, PV modül kusur tespitinde model başarısını artırdığı rapor edilmiştir. YOLOv11 mimarisinin optimizasyonunda, Bölüm 3.4’te ayrıntılı olarak açıklanan üç temel kayıp bileşeni esas alınmaktadır. Bu bileşenlerden ilki, nesne tespiti görevlerinde IoU metriği temel alınarak hesaplanan konumlandırma kaybı olup, modelin kusurun geometrik sınırlarını ne ölçüde doğru öğrendiğini göstermektedir. İkinci bileşen olan sınıflandırma kaybı (class loss), tespit edilen nesnenin (örneğin çatlak veya lehim hatası) doğru sınıfa atanıp atanmadığını değerlendirmektedir. Doğru sınıflandırma, farklı arıza türlerinin bakım ve müdahale süreçlerinde farklı aksiyonlar gerektirmesi nedeniyle kritik bir öneme sahiptir. Son olarak, dağılım odaklı kayıp DFL, kusur sınırlarının belirsiz olduğu durumlarda kutu kenarlarının daha hassas biçimde modellenmesini sağlayarak, modelin konumlandırma doğruluğunu artırmaktadır.

4.4.2 Hiperparametre optimizasyonu

Makine öğrenimi modelinin hiperparametreleri (öğrenme oranı, katman sayısı, ağaç derinliği vb.), modelin öğrenme sürecini ve dolayısıyla sonuç performansını büyük ölçüde etkilemektedir. Bu parametrelerin en iyi değerlerini bulmak için çeşitli arama stratejileri mevcuttur. Bu bölümün alt başlıklarında bu stratejiler detaylı şekilde anlatılmaktadır.

4.4.2.1 Izgara arama (grid search)

Hiperparametre uzayında önceden belirlenmiş tüm kombinasyonları kapsamlı tarama ile deneyerek en iyi sonucu arayan yöntemdir. Belirlenen her hiperparametre için değer listesi (ızgara) tanımlanmaktadır. Bu listelerin kartezyen çarpımı alınarak tüm kombinasyonlar denenmektedir (Hsu, Chang and Lin, 2003). Örneğin iki hiperparametre için 5'er olası değer belirlenmişse, toplam 25 model eğitilip doğrulama başarımına göre değerlendirilmektedir. Izgara arama, basit uygulanabilirliği ile geleneksel yöntem olmakla birlikte, parametre sayısı ve değer aralıkları arttıkça boyut patlaması yaşanabilmektedir. Yani deneme sayısı üstel olarak artmaktadır. Bu durum ise hesaplama maliyeti çok yükseltmektedir (Bergstra and Bengio, 2012). Bu nedenle ızgara arama genellikle küçük boyutlu hiperparametre uzaylarında veya sınırlı kombinasyonlar için kullanılmaktadır. Yine de tüm kombinasyonları değerlendirdiği için kümedeki global optimumu kaçırmama avantajı vardır.

4.4.2.2 Rastgele arama (random search)

Izgara aramanın aksine, hiperparametre değerlerini önceden tanımlanmış ızgaradan tümünü denemek yerine rastgele örnekleyen yöntemdir. Bu yöntemde her hiperparametre için olasılık dağılımı veya aralık tanımlanmaktadır. Ardından belirlenen iterasyon sayısı kadar rastgele kombinasyonlar seçilip denenmektedir. Random search'ün önemli avantajı, yüksek boyutlu parametre uzaylarında ızgara arama kıyasla daha etkin keşif yapabilmesidir. Araştırmalar, model performansına etki eden hiperparametrelerin genellikle sadece küçük altküme olduğunu, rastgele aramanın bu etkili altkümeye hızlı şekilde denk gelme şansının daha yüksek olduğunu göstermiştir (Bergstra and Bengio, 2012; Wang et al., 2016). Bergstra ve Bengio (2012) tarafından yapılan çalışmada, rastgele aramanın aynı deneme sayısında ızgara aramadan daha iyi sonuçlar verdiği hem teorik hem deneysel olarak ortaya konmuştur. Ayrıca rastgele arama doğası gereği paralel yapılara uygundur (her deneme birbiriyle bağımsızdır). Ek olarak ön bilgi dahilinde belirli değer aralıklarına odaklanmayı

da mümkün kılmaktadır. Bu nedenlerle, hiperparametre optimizasyonunda rastgele arama sıkça tercih edilen güçlü baz yöntemdir.

4.4.2.3 Bayesian (bayesian) optimizasyonu

Hiperparametre arama problemini ayar- kara- kutu (black-box) optimizasyon olarak ele alan ve önceki denemelerin sonuçlarına dayanarak akıllı seçimler yapan yöntemdir. Bayesian optimizasyonunda, olasılıksal model (genellikle Gauss prosesleri) yardımıyla, hiperparametre değerlerinden doğrulama başarımına (hedef fonksiyon) kestirim modeli oluşmaktadır. Ardından edinim fonksiyonu (acquisition function) tanımlanarak, bu fonksiyonun en yüksek değerini veren hiperparametre değeri sonraki deneme için seçilmektedir. Bu edinim fonksiyonu, mevcut modele göre en çok bilgi kazandıracak ya da en yüksek iyileşmeyi sağlamaktadır. Ayrıca noktayı dengeleyerek keşif (exploration) ve sömürü (exploitation) arasında denge kurmaktadır. Örneğin, Beklenen İyileşme (Expected Improvement) veya Üst Güven Sınırı (Upper Confidence Bound) gibi edinim fonksiyonları yaygındır. Bayesian optimizasyon, yeterli sayıda iterasyonla hiperparametre uzayının yapısını öğrenerek ızgara ve rastgele aramaya kıyasla çok daha az deneme ile optimuma yakın sonuçlar bulabilmektedir. Nitekim literatürde Bayesian yaklaşımın, özellikle hesaplama maliyeti yüksek modellerde, daha az model eğitimi ile benzer veya daha iyi performans sağladığı gösterilmektedir (Bergstra et al., 2011; Hutter, Hoos ve Leyton-Brown, 2011; Snoek et al., 2012; Thornton et al., 2013; Kernc, 2024). Bu çalışmada, hiperparametre optimizasyonu için uygun görülen durumlarda Bayesian yöntemleri de değerlendirilmiştir. Örneğin öğrenme oranı ve veri artırma boyutu gibi sürekli parametrelerin optimizasyonunda, Gaussian Process tabanlı arama uygulanmıştır. Hiperparametre optimizasyonu yapılırken modelin değerlendirilmesi için eğitim verisi dışındaki ölçüt gereklidir. Bu amaçla yaygın olarak çapraz doğrulama yöntemlerine başvurulur.

4.4.3 Çapraz doğrulama ve performans artırma stratejileri

Çapraz doğrulama, modelin farklı veri altkümelerinde defalarca eğitilip doğrulanması prensibine dayanmaktadır. Modelin genelleme performansı hakkında daha güvenilir tahmin elde etmeyi amaçlamaktadır. En yaygın kullanılan yöntemlerden K-katlı çapraz doğrulama (K-fold cross-validation) tekniğidir. Bu yöntemde veri seti eşit büyüklükte K adet kata bölünmektedir. Ardından K kez model eğitilmektedir. Her seferinde farklı kat doğrulama (veya test) için ayrılmaktadır. Kalan K-1 kat ise modelin eğitimi için kullanılmaktadır.

Böylece her veri noktası, sürecin parçasında doğrulama verisinde yer almış olmaktadır. Elde edilen K adet doğrulama sonucu (ör. doğruluk veya hata oranı) ortalanarak modelin performansı tahmin edilmektedir. K-kat yöntemi, verinin kıyasla az olduğu durumlarda modelin tüm veriyi hem eğitim hem de doğrulama için kullanabilmesini sağlamaktadır. Bu durum tek seferlik ayırmanın getirebileceği yanlılığı azalttığı için değerlidir. Örneğin 5-fold çapraz doğrulamada, her örnek 4 kez eğitim, 1 kez doğrulama için kullanılmaktadır. Bu da sonuçlar ortalaması modelin beklenen genelleme başarısını vermektedir (McLachlan, Do and Ambroise, 2005).

Bu çalışmada veri seti yeterince büyük olduğundan ve ayrı doğrulama seti (%10) ayrıldığından, temel yaklaşım olarak tek seferlik ayırma (hold-out) yöntemi kullanılmıştır. Model, eğitim sırasında eğitim verisiyle öğrenilmiş ve ayrı tutulan doğrulama seti ile izlenmiştir. Ancak, özellikle hiperparametre optimizasyonunda doğrulama sonuçlarının rasgele bölünmeden etkilenebileceği göz önüne alınarak, gerektiğinde k-katlı çapraz doğrulama da uygulanmıştır. Örneğin, daha küçük veri altkümüsi üzerinde algoritma seçimi yaparken 5-katlı çapraz doğrulama ile ortalama F1 skoru hesaplanmıştır. Böylelikle hangi model/ hiperparametre kombinasyonunun daha iyi genelleme sağladığına karar verilmiştir. Çapraz doğrulama, model seçimi ve hiperparametre aramasında aşırı uyma riskini azaltarak daha sağlam değerlendirme sunmuştur.

Modelin test ve doğrulama performansını üst düzeye çıkarmak için literatürde çeşitli yöntem ve stratejiler önerilmektedir. Bu tez çalışması kapsamında da modelin başarısını artırmak amacıyla aşağıdaki başlıca stratejiler uygulanmıştır.

4.4.3.1 Veri artırma (data augmentation)

Eğitim verisinin etkin boyutunu ve çeşitliliğini artırmak, derin öğrenme modellerinin genelleme yeteneğini yükseltmede kilit rol oynamaktadır. Veri artırma teknikleri ile mevcut görüntüler çeşitli dönüşümlere uğratarak yeni örnekler türetilir. Örneğin, elektrolüminesans görüntülerine rastgele döndürme, parlaklık/kontrast değişikliği, kırpma veya yansıma gibi işlemler uygulanmıştır. Bu sayede model, farklı koşullarda da nesneyi tanıyabilir hale gelmektedir. Veri artırmanın temel prensibi, mevcut veri setini yapay olarak genişleterek modelin gördüğü örnek sayısını ve çeşitliliğini artırmaktır (ACL Digital, 2024). Bu çalışmada geliştirilen “Segment Augmentation Model (SAM2)” ismi de

özel veri artırma yaklaşımının modele entegre edilmesinden gelmektedir. Özellikle kusurların konum ve şekil çeşitliliğini artırmak için segmentasyon tabanlı kesip yapıştırma, gürültü ekleme gibi ileri seviye veri artırma teknikleri kullanılmıştır. Sonuç olarak, veri artırma uygulanan modellerin, aşırı öğrenme eğiliminin azaldığı ve test verisinde daha yüksek başarı sergilediği gözlenmiştir.

4.4.3.2 Düzenleştirme (regularization) teknikleri

Modelin aşırı öğrenmesini önlemek ve daha iyi genelleştirme sağlaması için düzenleştirme büyük önem taşımaktadır. Bu çalışmada, L2 ağırlık çürüklüğü (weight decay) ve bırakma (dropout) gibi yaygın düzenleştirme teknikleri uygulanmıştır. L2 düzenleştirme, kayıp fonksiyonuna ağırlık değerlerinin kareleriyle orantılı ceza terimi ekleyerek, ağırlık çok büyük ağırlık değerleri almasını engellemektedir. Bu sayede modelin karmaşıklığı biraz azaltılarak basit ve genelleştirilebilir hipoteze yönelmesi sağlanmaktadır. Bırakma tekniğinde ise eğitim sırasında her iterasyonda sinir ağırlığının rastgele seçilen bazı nöronları geçici olarak devre dışı bırakmaktadır. Örneğin bırakma oranı %25 ise, her ileri yayılımda nöronların dörtte biri yokmuş gibi hesaplama yapılmaktadır. Bu yaklaşım, ağırlık belirli nöronlara veya özelliklere aşırı bağımlı hale gelmesini engellemektedir. Bu da daha doğru temsil öğrenmesini teşvik etmektedir. Bırakma etkisi, fiilen birden çok farklı alt-ağırlık topluluğu gibi davranarak aşırı öğrenmeyi azaltmasıdır. Düzenleştirme tekniklerinin net etkisi, eğitim hata oranını miktar artırabilse de doğrulama hatasını azaltarak toplamda daha iyi genelleme sağlamaktır (Simplilearn, 2024). Nitekim bu çalışmada da düzenleştirme kullanılan modellerin, kullanılmayanlara kıyasla doğrulama setinde daha düşük hata oranlarına ulaştığı saptanmıştır.

4.4.3.3 Erken durdurma (early stopping)

Aşırı uyumu önlemenin diğer yolu, modelin doğrulama kaybını izleyerek performans düşmeye başladığında eğitimi sonlandırmaktır. Eğitim esnasında her devir (epoch) sonunda doğrulama setindeki kayıp hesaplanmıştır. Belirli değer boyunca iyileşme görülmezse eğitim durdurulmuştur. Erken durdurma, gereksiz devir (epoch)'ların önüne geçerek hem zamanı verimli kullanmayı hem de modelin gereğinden fazla eğitilip öğrenme kapasitesini aşırı doldurmasını engellemektedir. Bu yöntem, bu çalışmada da uygulanmış ve en iyi doğrulama sonucunun alındığı noktada model ağırlıkları saptanarak, sonraki devir (epoch)'larda ortaya çıkabilecek olası aşırı öğrenmeyi engellenmiştir.

4.4.3.4 Topluluk (ensemble) modeller

Birden fazla modelin birlikte kullanılması, tek modelin tek başına yapabildiğinden daha iyi genelleme sağlayabilmektedir. Bu çalışmada esas olarak tek model mimarisi üzerinden gidilmiş olsa da literatürde toparlama (bagging), artırma (boosting), yığma (stacking) gibi topluluk tekniklerinin hatayı azalttığı bilinmektedir (Alam, 2024). Örneğin, YOLOv11 modelinin yanına farklı mimariler eklenerek topluluk oluşturulsaydı, her modelin güçlü olduğu kısımlardan yararlanılıp zayıf yönleri telafi edilebilmektedir. Bu fikir deneysel olarak da küçük çapta test edilmiştir. YOLOv11 ve SAM2 modellerinin tahminleri basitçe birleştirilerek (örneğin herhangi bir modelin tespitini kabullenmek gibi) daha yüksek topluluk performansı elde edilip edilmediğine bakılmıştır. Topluluk kombinasyonunun, özellikle belirsiz örneklerde daha iyi sonuç verebildiği görülmüştür. Ancak topluluk yöntemleri, gerçek zamanlı uygulamalarda ek hesap yükü getirdiğinden burada ağırlıklı olarak değerlendirme amaçlı kullanılmıştır.

4.4.3.5 Transfer öğrenimi

Mevcut çalışmada kullanılan modeller, mümkün seviyede sıfırdan eğitilmiş olsa da (özgün veri seti kullanıldığı için), yaygın uygulamalarda önceden eğitilmiş modellerin kullanımı performansı ve eğitim hızını artıran stratejidir. Özellikle derin evrimsel sinir ağlarında, geniş veri setleri üzerinde eğitilmiş ağırlıklar başlangıç noktası alınarak hedef görev için ince ayar yapılmaktadır. Bu çalışmada YOLOv11 modelinin başlangıç ağırlıkları, büyük genel nesne veri setinde önceden eğitilmiş olarak alınmış ve elektrolüminesans görüntülerine bu ön bilgi ile uyarlanmıştır. Bu sayede model, eğitimin başında rastgele ağırlıklara kıyasla temel görsel özellikleri zaten biliyor durumdadır ve daha hızlı konsantre olarak hedef nesne de kusur tespitine odaklanmaktadır. Transfer öğrenimi, özellikle veri setinin görece küçük veya orta boyutta olduğu durumlarda aşırı öğrenmeyi ciddi oranda azaltırken doğruluk oranlarını yükseltmektedir (Alam, 2024). Nitekim, ön eğitilmiş başlangıç kullanımı YOLOv11 modelinin birkaç devir (epoch) içinde yüksek başarıya ulaşmasına yardımcı olmuştur.

Bu çalışmada eğitim süreci boyunca düzenli olarak hata analizi yapılmıştır. Modelin en çok yanlış olduğu örnekler incelenerek gerek veri setinde gerekse model çıktılarında problemler kısımlara özel çözümler geliştirilmeye çalışılmıştır. Örneğin, modelin sıklıkla düşük parlaklıklı bazı kusurları atladığı görülünce, veri artırma aşamasında yapay karartma işlemleriyle modeli bu durumlara karşı daha dayanıklı hale getirme yoluna gidilmiştir.

Benzer şekilde, yalancı pozitif çıktılar belirli doku desenlerinden kaynaklanıyorsa, bu desenlerin olduğu arka plan görselleri modele olumsuz örnek olarak sunulmuştur. Tüm bu çabalar sonucunda, modelin doğruluk, IoU ve mAP gibi temel göstergelerinde başlangıç sürümlerine kıyasla anlamlı iyileşmeler kaydedilmiştir.


4.5 Deney Ortamı

Bu çalışmada gerçekleştirilen model eğitimi, doğrulaması ve test süreçleri, yüksek hesaplama kapasitesi gerektiren derin öğrenme görevleri için özel olarak yapılandırılmış donanım ve yazılım altyapısı üzerinde yürütülmüştür. Deneylerin bilimsel titizliğini ve tekrarlanabilirliğini sağlamak amacıyla kullanılan sistem konfigürasyonu aşağıda detaylandırılmıştır.

4.5.1 Donanım ve yazılım altyapısı

DeneySEL çalışmalar, büyük ölçekli veri setlerinin işlenmesi ve karmaşık model mimarilerinin eğitimi sırasında gereken yüksek hesaplama gücünü karşılamak üzere optimize edilmiş bir iş istasyonunda gerçekleştirilmiştir. Paralel hesaplama yeteneklerinden tam olarak faydalanmak amacıyla sistemde, NVIDIA Tesla A100 40GB grafik işlem birimi (GPU) kullanılmıştır. Sistemin merkezi işlem birimi (CPU) olarak çok çekirdekli Intel Core i9-13900K tercih edilmiş ve bu işlemci 64 GB DDR5 sistem belleği (RAM) ile desteklenmiştir. Bu donanım konfigürasyonu, eğitim sürelerini minimize ederek verimli bir deney ortamı sağlamıştır.

Yazılım tarafında, sistem kararlılığı ve açık kaynak topluluğunun geniş desteği nedeniyle işletim sistemi olarak Ubuntu 22.04 LTS tercih edilmiştir. Derin öğrenme modelleri, araştırma dünyasında yaygın kabul gören PyTorch 2.1 kütüphanesi temel alınarak geliştirilmiştir. GPU hızlandırması için NVIDIA CUDA 12.1 ve cuDNN 8.9 sürümleri entegre edilmiştir. Ayrıca görüntü işleme, veri manipülasyonu ve sonuçların görselleştirilmesi gibi temel görevler için Python programlama dili ile OpenCV, NumPy ve Matplotlib kütüphanelerinden yararlanılmıştır.



Şekil 4.3: Elektrolüminesans görüntüleme ve test düzeneğinin şematik diyagramı

Veri toplama aşamasında kurulan ve fotovoltaik modüllerin EL görüntülerini elde etmek için kullanılan deney düzeneğinin şematik gösterimi ve bileşenleri Şekil 4.3'te, gerçek saha kurulumu sunulmuştur.

4.5.2 Model eğitim parametreleri

YOLO modellerinin eğitim aşaması, modelin genelleme yeteneğini artırmak ve aşırı öğrenmeyi azaltmak amacıyla yapılandırılmıştır. Optimizasyon algoritması olarak, momentum desteği sayesinde kararlı yakınsama sağlaması ve yerel minimumlardan kaçınmaya yardımcı olması nedeniyle Stokastik Gradyan İnişi (SGDM) tercih edilmiştir. Çok sınıflı problem yapısına uygun olacak şekilde kayıp fonksiyonu Categorical Cross-Entropy olarak belirlenmiştir. Eğitim süreci 0,001 başlangıç öğrenme oranı ve 64 yığın (batch) size ile yürütülmüş, toplam 200 devir (epoch) boyunca sürdürülmüştür.

Tablo 4.1: YOLO modellerinin eğitim ve derleme ayarları

Parametre	Değer	Açıklama
Optimizasyon Algoritması	SGDM	Momentum tabanlı stokastik gradyan inişi
Kayıp Fonksiyonu	Categorical Cross-Entropy	Çoklu sınıflandırma hatası hesaplama

Tablo 4.1 (devam)

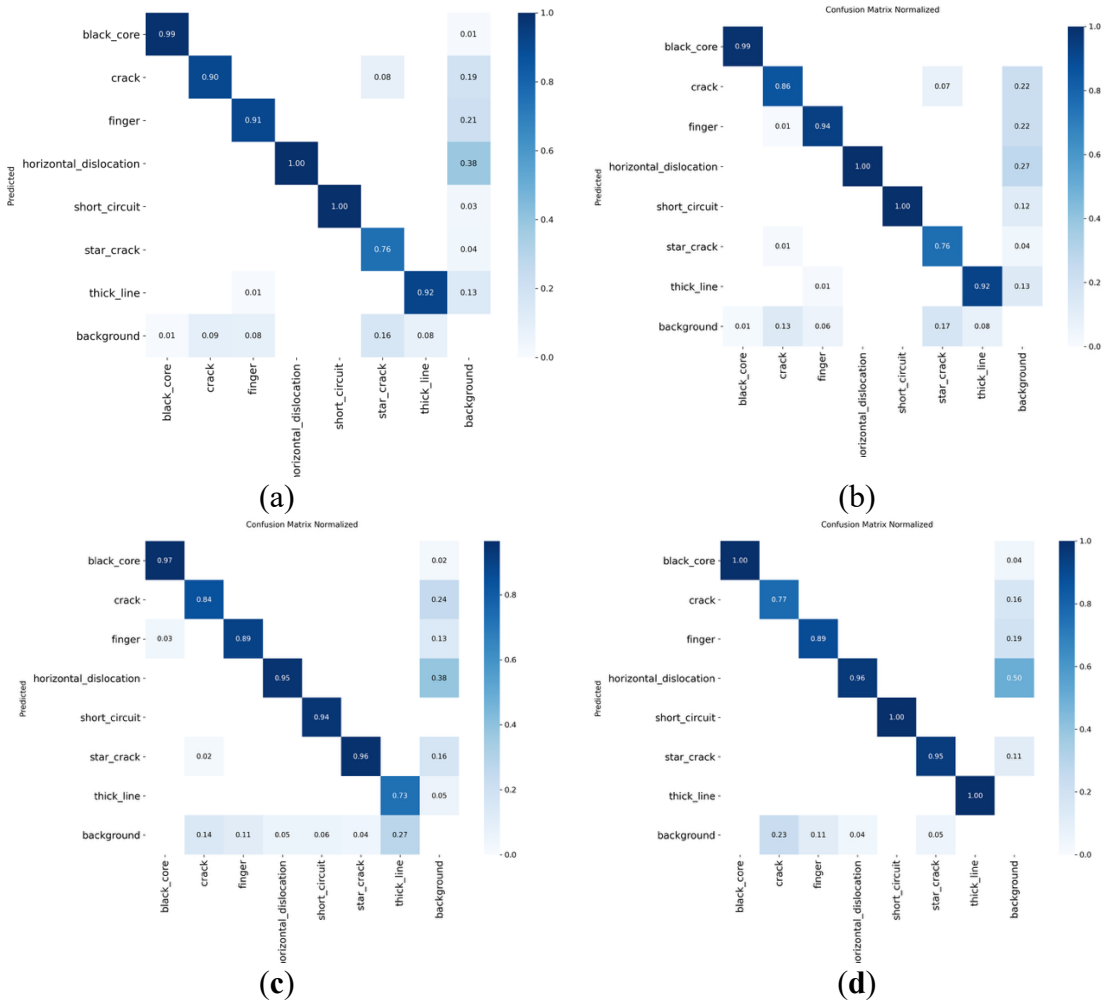
Öğrenme Oranı	0.001	Ağırlık güncelleme katsayısı
Yığın Boyutu (Batch Size)	64	Her işlem adımındaki veri sayısı
Devir (Epoch) Sayısı	200	Toplam eğitim döngüsü
Veri seti bölünmesi (Senaryo A)	%70-15-15	Eğitim / Doğrulama / Test
Veri seti bölünmesi (Senaryo B)	%80-10-10	Eğitim / Doğrulama / Test

Model performansını eğitim sürecinde tarafsız biçimde izlemek ve hiperparametre seçimlerini değerlendirmek amacıyla doğrulama kümesi kullanılmıştır. Bu çalışma kapsamında veri seti, iki farklı deneysel senaryo ile eğitim/doğrulama/test alt kümelerine ayrılarak eğitilmiştir. Bölünme oranları, eğitim ve derleme sürecinde kullanılan hiperparametreler Tablo 4.1’de sunulmuştur.

5. BULGULAR

Bu bölümde, önerilen hibrit derin öğrenme modelinin (YOLOv11 + SAM 2) fotovoltaik hücrelerdeki kusur tespiti ve segmentasyonu üzerindeki performansı deneysel verilerle ortaya konulmuştur. Aynı veriler kıyaslama yapılabilmesi adına YOLOv11-seg modeline de uygulanmıştır. Eğitim sürecinin kararlılığı, sınıf bazlı ayrıştırma yeteneği ve görsel segmentasyon başarısı; karmaşıklık matrisi, kayıp grafikleri, hassasiyet-duyarlılık eğrileri ve niteliksel görsel çıktılar üzerinden karşılaştırmalı olarak detaylandırılmıştır.

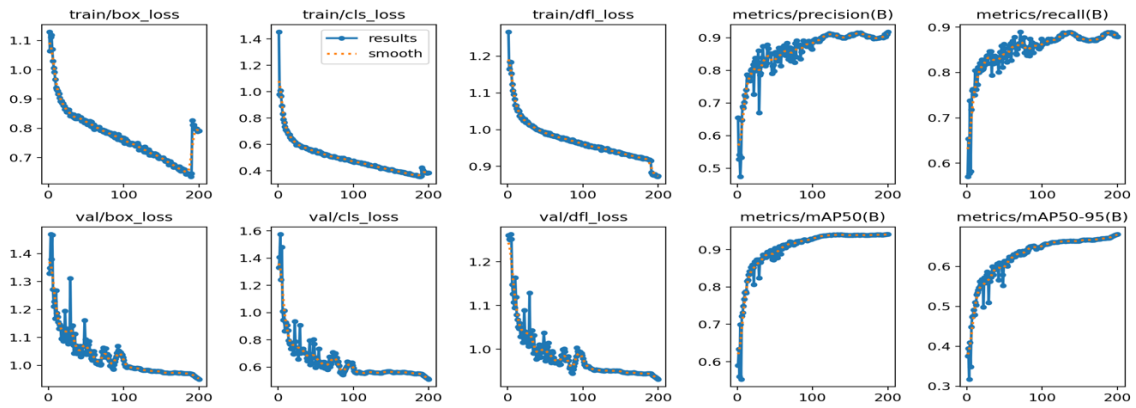
5.1 Çıktı Sonuçları



Şekil 5.1: Farklı veri seti dağılımlarına göre modellerin sınıflandırma performansını gösteren normalleştirilmiş karmaşıklık matrisleri: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).


Şekil 5.1'de, çalışmada kullanılan standart YOLOv11 (hibrit yapının ön aşaması) ve YOLOv11-seg (referans) modellerinin farklı veri seti dağılımları (%70-15-15 ve %80-10-10) altındaki sınıflandırma performanslarını yansıtan normalleştirilmiş karmaşıklık

matrisleri (confusion matrix) sunulmuştur. Matrislerdeki koyu mavi renkli köşegen hattı, modelin ilgili kusur sınıfını (örn. siyah çekirdek, çatlak, iletken parmak vb.) doğru tahmin etme oranını (True Positive) temsil ederken köşegen dışındaki açık renkli hücreler, modelin sınıfları birbirleriyle veya arka planla (background) karıştırma oranlarını göstermektedir. Grafikler incelendiğinde veri dağılımının etkisi hem YOLOv11 (Şekil 5.1-a ve b) hem de YOLOv11-seg (Şekil 5.1-c ve d) modelleri için veri setinin %80 Eğitim, %10 Doğrulama ve %10 Test olarak ayrıldığı (b ve d) senaryolarda köşegen üzerindeki doğru bilme oranlarının genel olarak daha yüksek olduğu ve renk yoğunluğunun arttığı gözlemlenmiştir. Bu durum, veri miktarındaki artışın her iki mimarinin de sınıflandırma yeteneğini olumlu yönde etkilediğini doğrulamaktadır. Ayrıca arka plan karmaşası, tüm matrislerde en sık karşılaşılan hata tipinin, belirli kusurların (özellikle kılcal yapılar olan çatlak ve kalın çizgi gibi) "arka plan" (background) olarak tahmin edilmesi olduğu görülmektedir. Ancak YOLOv11 (%80-10-10) modeli (Şekil 5.1-b), kusurları arka plandan ayırt etme konusunda referans segmentasyon modeline (Şekil 5.1-d) kıyasla daha kararlı bir yapı sergilemiştir.

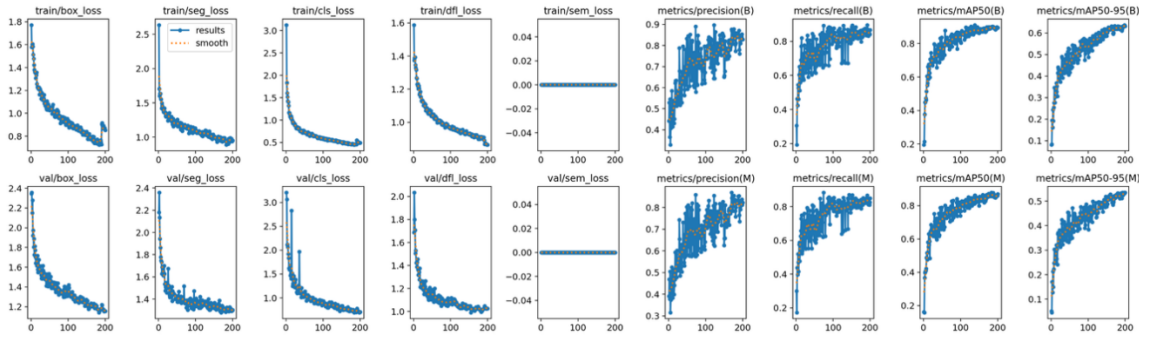


(a)

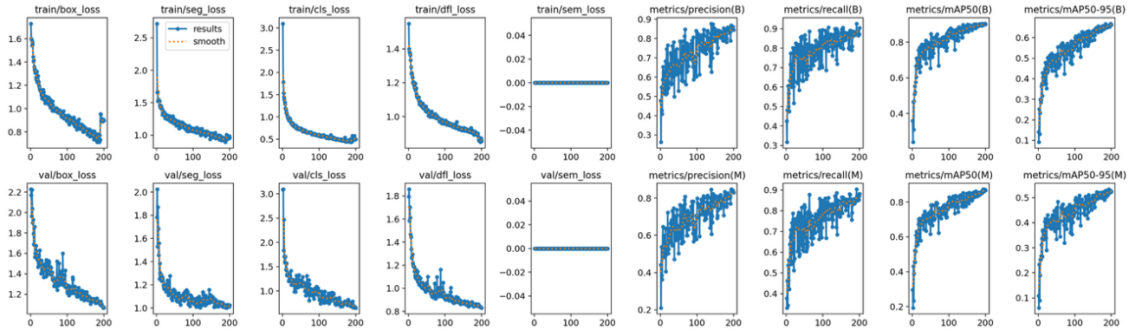
Şekil 5.2: Farklı modellerin 200 devir (epoch) boyunca eğitim ve doğrulama kayıpları ile performans metriklerinin değişimi: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).



(b)



(c)



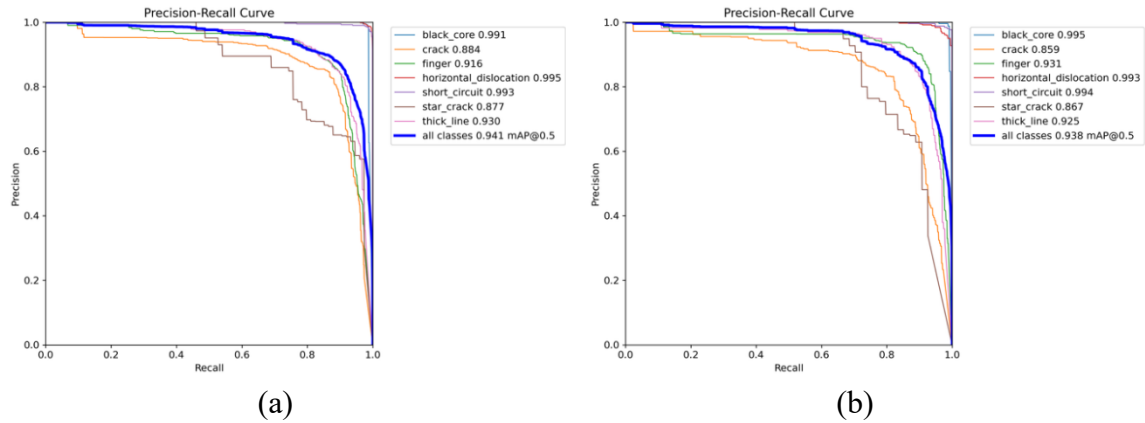
(d)

Şekil 5.2 (devam)


Şekil 5.2'de, tez çalışması kapsamında önerilen hibrit mimarinin ön aşamasını oluşturan YOLOv11 modelinin, optimum olarak belirlenen %80 Eğitim, %10 Doğrulama ve %10 Test veri dağılımı altındaki 200 epokluk eğitim sürecine ait performans dinamikleri sunulmaktadır. İlgili grafik seti, eğitim ve doğrulama veri setleri üzerinden hesaplanan kayıp fonksiyonlarının (kutu, sınıflandırma ve yönlendirici odak kaybı - DFL) epoklar bazındaki azalma eğilimlerini ve modelin temel performans artış ivmesini eş zamanlı olarak göstermektedir.

Eđitim sürecine ait kayıp grafikleri incelendiđinde, hem eđitim hem de dođrulama ařamalarındaki kutu ve sınıflandırma kayıp deđerlerinin ilk epoklardan itibaren hızlı ve istikrarlı bir düşüş ivmesi yakaladıđı gözlemlenmiřtir. İlerleyen epoklarda bu düşüş eğiliminin yerini stabil bir yatay seyre (yakınsama) bıraktıđı tespit edilmiřtir. Eđitim ve dođrulama kayıp eğrilerinin süreç boyunca birbirine paralel bir seyir izlemesi ve aralarında modelin ezberlemeye bařladıđına iřaret eden belirgin bir sapma (makas açılması) olmaması, ađın aşırı öğrenme problemine maruz kalmadıđını kanıtlamaktadır. Bu durum, eđitilen YOLOv11 modelinin yeni ve daha önce hiç görmediđi veriler üzerindeki genelleme yeteneđinin oldukça yüksek olduđunu ortaya koymaktadır.

Modelin dođrulama seti üzerinden elde ettiđi performans metriklerinin gelişimi deđerlendirilmiřtir. Bu deđerlendirme sonucunda hassasiyet, duyarlılık ve ortalama hassasiyet deđerlerinin, beklendiđi üzere ilk 50 epok içerisinde dik bir artış sergilediđi görölmektedir. Yaklařık 100. epoktan itibaren bu metriklerin doygunluk noktasına ulařarak %95 bandında sabitlendiđi ve eđitim sonuna kadar bu istikrarını koruduđu belirlenmiřtir. Eğrilerde gözlemlenen bu kararlı yapı, modelin 200 epokluk süreç zarfında fotovoltaik hücrelerdeki kusur özelliklerini öğrenme ve sınıflandırma kapasitesine sađlıklı bir řekilde ulařtıđını göstermektedir.



řekil 5.3: Farklı modellerin hassasiyet-duyarlılık eğrisi ve mAP@0.5 deđerleri: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).

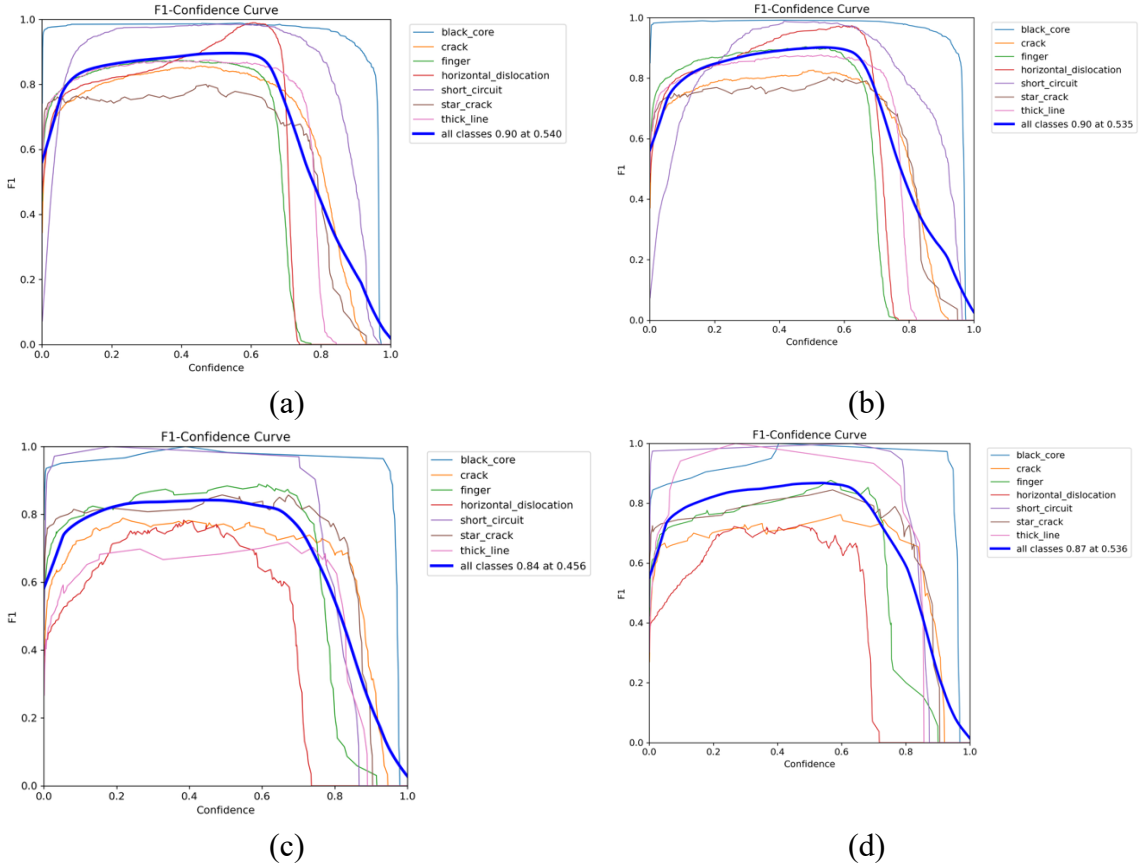


Şekil 5.3 (devam)

Şekil 5.3'te, çalışmada değerlendirilen YOLOv11 ve YOLOv11-seg modellerinin farklı veri seti dağılımları altındaki hassasiyet- duyarlılık (PR) eğrileri sunulmuştur. PR eğrilerinde, x eksenini modelin gerçek kusurları ne oranda bulabildiğini (duyarlılık), y eksenini ise bulunduğu kusurların ne kadarının gerçekten doğru olduğunu (hassasiyet) ifade etmektedir. Eğrilerin sağ üst köşeye (1.0, 1.0 koordinatlarına) ne kadar yakın olduğu ve eğrinin altında kalan alan (Area Under Curve - AUC), modelin genel başarısını (mAP) doğrudan yansıtmaktadır. Grafikler üzerindeki kalın mavi çizgiler, tüm kusur sınıflarının ortalama performansını (all classes mAP@0.5) temsil etmektedir.

Grafikler detaylı olarak incelendiğinde mimari performans kıyaslaması sadece nesne tespiti yapan standart YOLOv11 modeline ait PR eğrilerinin (Şekil 5.3-a ve b), tek aşamalı bölümlenme yapan YOLOv11-seg modeline ait eğrilere (Şekil 5.3-c ve d) kıyasla sağ üst köşeye çok daha yakın ve dolgun (dışbükey) bir yapı sergilediği açıkça görülmektedir. YOLOv11 modellerinde tüm sınıfların ortalamasını gösteren kalın mavi çizgi %94 bandında seyrederken, YOLOv11-seg modellerinde bu değer %90 seviyelerinde kaldığı ve eğrilerde erken düşüşler (sagging) yaşandığı tespit edilmiştir. Bu durum, YOLOv11'in kutu tahminindeki kararlılığının daha yüksek olduğunu kanıtlamaktadır. Kusur türleri özelinde bakıldığında, her iki model tipinde de siyah çekirdek ve kısa devre gibi belirgin ve yapısal sınırları net olan kusurların %99'un üzerinde (0.991 - 0.995) bir başarıyla neredeyse kusursuz tespit edildiği görülmektedir. Buna karşın, özellikle hücre üzerindeki kılcal formları nedeniyle arka planla karışmaya müsait olan çatlak, yıldız çatlak ve kalın çizgi gibi kusur sınıflarında modelin zorlandığı ve bu sınıflara ait eğrilerin genel ortalamayı aşağı çektiği gözlemlenmiştir. Özellikle YOLOv11-seg modelinde (c ve d) bu zorlu sınıfların eğrilerindeki dalgalanmalar çok daha belirgindir. Ayrıca YOLOv11-seg modeli

için veri setinin %80-10-10 oranında ayrılması (Şekil 5.3-d), %70-15-15 dağılımına (Şekil 5.3-c) göre ortalama başarıyı (0.898'den 0.903'e) artırmış ve kalın mavi çizginin genel formunu iyileştirmiştir. Eğitim verisindeki bu artış, segmentasyon modelinin zorlu sınıflardaki genel karakteristiğini olumlu yönde desteklemiştir.



Şekil 5.4: Farklı modellerin F1 Skoru- Güven eşiği değişim eğrileri: (a) YOLOv11 (%70-15-15), (b) YOLOv11 (%80-10-10), (c) YOLOv11-seg (%70-15-15) ve (d) YOLOv11-seg (%80-10-10).

Şekil 5.4'te, tez çalışması kapsamında değerlendirilen YOLOv11 ve YOLOv11-seg modellerinin farklı veri seti dağılımları altındaki F1 Skoru - Güven Eşiği (F1-Confidence) değişim eğrileri sunulmuştur. F1 skoru, modelin hassasiyet ve duyarlılık değerlerinin harmonik ortalamasını ifade eden ve özellikle sınıflar arası dengesizliklerin olduğu durumlarda modelin gerçek performansını yansıtan kritik bir metriktir. Eğrilerdeki x eksen, modelin bir tahmini kabul etmek için kullandığı güven eşiğini (0.0 ile 1.0 arası), y eksen ise bu eşikte elde edilen F1 skorunu göstermektedir. Grafikler üzerindeki kalın mavi çizgiler tüm sınıfların ortalama F1 performansını temsil ederken, eğrinin tepe noktası modelin en yüksek doğruluğa ulaştığı optimum güven eşiğini (optimal confidence threshold) belirtmektedir.

Mimari bazlı performanslar incelendiğinde, sadece nesne tespiti görevini üstlenen standart YOLOv11 modelinin (Şekil 5.4-a ve b), tek aşamalı segmentasyon yapan YOLOv11-seg modeline (Şekil 5.4-c ve d) kıyasla çok daha yüksek ve kararlı bir F1 skoru profili çizdiği görülmektedir. YOLOv11 modellerinde tüm sınıfların ortalama F1 skoru sırasıyla 0.540 ve 0.535 güven eşiklerinde maksimum 0.90 değerine ulaşırken, bu tepe noktasının geniş bir güven aralığında (yaklaşık 0.2 ile 0.6 arası) istikrarını koruduğu saptanmıştır. Buna karşın, YOLOv11-seg modelinde maksimum F1 skoru %70-15-15 dağılımında 0.84, %80-10-10 dağılımında ise 0.87 seviyesinde kalmış ve eğrilerdeki düşüş eğilimi daha erken başlamıştır. Bu bulgu, YOLOv11'in hata yapma riskini minimize eden optimum dengeyi çok daha başarılı bir şekilde kurduğunu göstermektedir.

Sınıf bazlı eğriler detaylı olarak analiz edilmiştir. Analiz sonucunda PR eğrilerindeki bulgulara paralel olarak, siyah çekirdek ve kısa devre gibi belirgin morfolojik özelliklere sahip kusurların neredeyse 1.0 güven eşiğine kadar maksimum F1 skorunu (1.0'a yakın) koruduğu gözlemlenmiştir. Öte yandan, çatlak ve kalın çizgi gibi yapısal olarak tespiti zor olan ve arka plan gürültüsünden kolay etkilenen kusur sınıfları, genel F1 ortalamasını aşağı çekmiştir. Özellikle YOLOv11-seg modelinde (Şekil 5.4-c ve d) bu zorlu sınıflara ait eğrilerin düşük güven eşiklerinde bile dalgalanmalar yaşadığı ve modelin bu kusurları tespit ederken güven kaybı (confidence drop) yaşadığı tespit edilmiştir. Eğitim verisinin artırılması (%80-10-10 dağılımı), her iki mimaride de modelin zorlu sınıflardaki özgüvenini kısmen artırarak eğrilerin tepe noktalarını yukarı taşımıştır.

5.2 Model Performans Analizi

Tablo 5.1'de, çalışmada karşılaştırmalı analizleri yapılan tek aşamalı YOLOv11-seg modeli ile önerilen YOLOv11+SAM2 hibrit mimarisinin iki farklı veri bölünmesi (%70-15-15 ve %80-10-10) altındaki sınıf bazlı performans (mAP@0.5) metrikleri sunulmuştur. Hibrit modelin başarımı, SAM 2 algoritmasına hatasız bir şekilde iletilen ön-tespit aşamasının (YOLOv11) doğruluğu üzerinden değerlendirilmiştir.

Tablo 5.1: YOLOv11-seg ve YOLOv11+SAM2 modellerinin iki farklı veri bölünmesinde sınıf bazlı kutu mAP@50–95 karşılaştırması

Sınıf	YOLOv11-seg		YOLOv11+SAM2	
	%70-15-15	%80-10-10	%70-15-15	%80-10-10
Siyah Çekirdek (black core)	0.995	0.989	0.995	0.995
Çatlak (crack)	0.877	0.797	0.867	0.893
İletken Parmak (finger)	0.957	0.933	0.979	0.942
Yatay Kayma (horizontal dislocation)	0.810	0.994	0.848	0.992
Kısa Devre (short circuit)	0.995	0.992	0.995	0.990
Yıldız Çatlak (star crack)	0.955	0.887	0.967	0.959
Kalın Çizgi (thick line)	0.724	0.932	0.821	0.929
Genel Ortalama	0.9019	0.9246	0.9320	0.9571

Tablodaki veriler genel olarak her iki mimarinin de %80 Eğitim, %10 Doğrulama ve %10 Test olarak ayrılan veri seti dağılımında daha iyi öğrendiği ve genel başarısını artırdığı görülmektedir. Optimizasyonun en yüksek olduğu bu dağılımda, önerilen hibrit yapı (YOLOv11+SAM2) 0.9571 genel ortalama ile, tek aşamalı referans model olan YOLOv11-seg'i (0.9246) geride bırakmıştır.

Kusur sınıfları özelinde yapılan detaylı analizler, mimariler arasındaki performans farkının kaynağını net bir şekilde ortaya koymaktadır. Sınırları belirgin ve kontrastı yüksek olan siyah çekirdek ve kısa devre gibi sınıflarda her iki model de %99.5 gibi mükemmel yakın başarılar sergilemiştir. Ancak, kusurun hücre morfolojisi ile karıştığı ve tespiti yapısal olarak zorlaştığı durumlarda hibrit yapının ciddi bir üstünlüğü bulunmaktadır. Örneğin hibrit model yatay kayma sınıfında %99.2 (0.992) gibi kusursuz bir başarı gösterirken, YOLOv11-seg modeli bu sınıfı ancak 0.848 doğrulukla tespit edebilmiştir. Benzer şekilde kalın çizgi kusurunda hibrit model rakibine 0.929'a karşı 0.821'lik bir fark atmıştır. Tespiti

en zor sınıflardan biri olan çatlak sınıfında ise 0.893'lük skoruyla referans modeli (0.867) geride bırakmıştır. Elde edilen bu sonuçlar, PV hücrelerindeki özellikle kompleks ve asimetrik kusurların yakalanmasında hibrit yapının ön aşamasının (YOLOv11) çok daha kararlı ve yüksek doğruluklu bir referans sunduğunu göstermektedir. Bu sayede hibrit sistem, kusurun tespiti ve sonrasındaki sıfır-atış maskeleye işlemleri için tek aşamalı modellere kıyasla daha güvenilir bir otomasyon çözümü sağlamaktadır.


Tablo 5.2: YOLOv11 ve YOLOv11-seg modellerinin hız ve çıkarım süresi karşılaştırması

Model	Veri Seti Dağılımı	Çıkarım Süresi (ms/görüntü)	İşlem Hızı (FPS)
YOLOv11 (Hibrit Ön-Aşama)	%70-15-15	1.28	780.51
	%80-10-10	1.38	720.39
YOLOv11-seg (Referans)	%70-15-15	2.80	356.57
	%80-10-10	3.61	276.72

Tablo 5.2'te, çalışmada kullanılan standart YOLOv11 ve tek aşamalı YOLOv11-seg modellerinin test veri seti üzerindeki çıkarım süreleri (inference time) ve saniye başına işlenen kare sayıları (Frames Per Second - FPS) karşılaştırmalı olarak sunulmuştur. Elde edilen hız metrikleri incelendiğinde, hibrit yapının ön aşamasını oluşturan ve yalnızca nesne tespiti (kutu regresyonu) görevini üstlenen YOLOv11 modelinin, %80-10-10 veri dağılımında saniyede 720.39 kare (FPS) işleme hızına ve görüntü başına yalnızca 1.38 milisaniye çıkarım süresine sahip olduğu görülmektedir. Buna karşın, aynı veri dağılımında eş zamanlı maske üretimi de yapan YOLOv11-seg modeli, artan hesaplama karmaşıklığı (FLOPs) nedeniyle 3.61 milisaniye çıkarım süresine ve 276.72 FPS işlem hızına gerilemiştir.

Bu bulgular, YOLOv11 mimarisinin YOLOv11-seg modeline kıyasla yaklaşık 2.6 kat daha hızlı çalıştığını ve çok daha düşük bir hesaplama maliyeti gerektirdiğini kanıtlamaktadır. Tez kapsamında önerilen hibrit (YOLOv11 + SAM2) mimarinin ilk aşaması için standart YOLOv11'in tercih edilmesi, sistemin donanım kaynaklarını tüketmeden kusur bölgelerini (Region of Interest - ROI) milisaniyeler içinde tespit etmesini sağlamaktadır. Böylece SAM2 modelinin yalnızca bu hedeflenmiş alanlar üzerinde maskeleye yapmasına olanak

tanılarak uçtan uca daha efektif bir gerçek zamanlı kalite kontrol boru hattı (pipeline) oluşturmaktadır.



Şekil 5.5: Hibrit modelin test veri seti üzerindeki örnek tahminleri: (a) yatay yer değiştirme kusuru (b) uzun ve kavisli çatlak segmentasyonu (c) çoklu yıldız çatlak kusurları

Elde edilen görsel sonuçlar (Şekil 5.5) incelendiğinde, YOLOv11 ve SAM 2 entegrasyonunun farklı morfolojik yapıya sahip kusurları tespit etmedeki başarısı şu üç temel senaryo üzerinden değerlendirilmiştir. Öncelikle doğrusal yapılar panel boyunca uzanan yatay yer değiştirme kusuru, ince ve uzun yapısına rağmen model tarafından kesintisiz bir şekilde tespit edilmiştir. SAM 2'nin ürettiği segmentasyon maskesi (turkuaz alan), kusurun tüm hattını başarıyla kaplamış ve sınır dışına taşma yapmamıştır. İkinci olarak karmaşık geometrilere uyum, çatlak sınıfına ait kusurların genellikle düzensiz, kavisli ve parçalı bir yapı sergilediği bilinmektedir. Orta paneldeki örnekte, modelin bu karmaşık geometriyi sadece bir kutu içine almakla kalmayıp, SAM 2 sayesinde çatlağın kıvrımlarını piksel hassasiyetinde takip edebildiği görülmüştür. Bu klasik nesne tespiti yöntemlerinin sağlayamadığı bir morfolojik analiz yeteneğidir. Son olarak çoklu ve hibrit kusur tespiti aynı panel üzerinde birden fazla ve farklı türde kusurun bulunduğu karmaşık senaryolarda, modelin her bir nesneyi bağımsız olarak algılayabildiği kanıtlanmıştır. Yıldız çatlağın kendine özgü çok kollu yapısı ile ince çatlağın çizgisel yapısı, model tarafından karıştırılmadan ve yüksek doğrulukla ayırt edilmiştir. Bu niteliksel bulgular, sayısal olarak raporlanan yüksek mAP ve F1 skorlarını görsel olarak desteklemekte ve yapılmış olan yöntemin endüstriyel kalite kontrol süreçlerinde uygulanabilirliğini somutlaştırmaktadır.


6. SONUÇ VE ÖNERİLER

Tablo 6.1'de, çalışmada önerilen hibrit mimarinin ön-aşamasını oluşturan standart YOLOv11 modeli ile referans model olarak seçilen tek aşamalı YOLOv11-seg modelinin farklı veri seti dağılımları (%70-15-15 ve %80-10-10) altındaki test performansları sunulmuştur.

Tablo 6.1: Farklı Veri Seti Dağılımlarına Göre YOLOv11 ve YOLOv11-seg Modellerinin Test Başarımı (mAP@50) Karşılaştırması

Model	Veri Seti Dağılımı	Kutu Tespit Başarısı (Box mAP@50)	Bölütleme Başarısı (Mask mAP@50)
YOLOv11 (Hibrit Ön-Aşama)	%70-15-15	0.9321	-
	%80-10-10	0.9571	-
YOLOv11-seg	%70-15-15	0.9018	0.8641
	%80-10-10	0.9245	0.9089

Elde edilen bulgular incelendiğinde, her iki model için de veri setinin %80 Eğitim, %10 Doğrulama ve %10 Test olarak bölündüğü (%80-10-10) senaryonun en yüksek başarı oranlarını (mAP@50) sağladığı görülmektedir. Bu dağılımda, hibrit yapının ilk aşaması olan standart YOLOv11 modeli nesne konumunu belirlemede 0.9571 gibi oldukça yüksek bir kutu tespit başarısına ulaşmıştır. Referans model olan YOLOv11-seg ise aynı veri dağılımında 0.9245 kutu tespit ve 0.9089 bölütleme (maske) başarısı göstermiştir. Tablodaki veriler, yalnızca nesne tespitine (kutu regresyonu) odaklanan standart YOLOv11 modelinin, aynı anda hem tespit hem de maskeleme yapmaya çalışan YOLOv11-seg modeline kıyasla konum belirlemede daha yüksek bir performans (%95.71'e karşı %92.45) sergilediğini ortaya koymaktadır. Bu sonuç, tez çalışmasında önerilen YOLOv11 + SAM2 hibrit mimarisinin haklılığını destekler niteliktedir. Zira standart YOLOv11 kusurun konumunu çok yüksek bir doğrulukla izole etmekte, segmentasyon görevi ise bu konuda özelleşmiş temel model olan SAM2'ye bırakılarak uçtan uca daha güvenilir bir kalite kontrol mekanizması hedeflenmektedir. Ayrıca YOLOv11 modelinin maske mAP değerleri, mimarisi gereği yalnızca kutu tespiti yapıp maske üretmediği için tabloda '-' olarak belirtilmiştir.



Şekil 6.1: Yoğun hata içeren saha görüntüsü üzerinde standart YOLOv11 + SAM 2 tespiti ile hibrit yöntemin karşılaştırmalı analizi.

Geliştirilen hibrit mimarinin endüstriyel saha koşullarındaki etkinliğini doğrulamak amacıyla, eğitim veri setinde bulunmayan ve 40 adet gibi yüksek yoğunlukta hata içeren bir test görüntüsü üzerinde karşılaştırmalı analiz yapılmıştır (Şekil 6.1). Görselin sol panelinde ham elektrolüminesans (EL) görüntüsü yer almaktadır. Orta panelde görüldüğü üzere, standart YOLOv11 modeli hataların konumunu başarıyla tespit etmiş olsa da sınırlayıcı kutuların üst üste binmesi nedeniyle hataların birbirinden ayrıştırılması ve gerçek boyutlarının algılanması zorlaşmaktadır. Sınırlayıcı kutular, hatanın yanı sıra hasarsız alanları da içine alarak analiz hassasiyetini düşürmektedir. Buna karşın, sağ panelde sunulan önerilen hibrit yöntem tespit edilen her bir hatayı piksel seviyesinde izole etmiştir. SAM 2 modülü, YOLO'dan aldığı koordinatları referans alarak hatanın morfolojik yapısını birebir çıkarmış ve arka plandaki sağlam hücre yapısından ayırmıştır. Bu sonuç, önerilen sistemin karmaşık ve yoğun hatalı panellerde dahi sadece hatanın yerini değil, tam şeklini ve kapladığı alanı yüksek doğrulukla belirleyebildiğini göstermektedir.

6.1 Sonuçlar

Güneş enerjisi santrallerinde fotovoltaik (PV) modüllerin işletme ömrünü ve verimliliğini doğrudan etkileyen mikro kusurların tespiti, enerji sektörünün en kritik mühendislik problemlerinden biridir. Bu tez çalışması kapsamında, insan faktörüne dayalı ve zaman maliyeti yüksek olan manuel EL görüntüsü analizlerine alternatif olarak, otonom ve yüksek doğruluklu hibrit bir derin öğrenme mimarisi (YOLOv11 + SAM 2) geliştirilmiştir. Toplam 13.631 görselden oluşan geniş çaplı bir veri seti kullanılarak "siyah çekirdek, çatlak, iletken parmak, yatay kayma, kısa devre, yıldız çatlak ve kalın çizgi" olmak üzere yedi farklı kusur sınıfı derinlemesine analiz edilmiştir.

Çalışmada önerilen hibrit mimarinin ön-aşamasını oluşturan standart YOLOv11 modeli ile referans model olarak seçilen tek aşamalı YOLOv11-seg modelinin test performansları karşılaştırmalı olarak değerlendirilmiştir. Elde edilen nicel bulgular incelendiğinde, her iki

mimari için de veri setinin %80 Eğitim, %10 Doğrulama ve %10 Test olarak bölündüğü (%80-10-10) senaryonun en yüksek genel başarı oranlarını sağladığı görülmüştür. Bu optimum dağılımda, hibrit yapının ilk aşaması olan standart YOLOv11 modeli nesne konumunu belirlemede %95.71 (0.9571) gibi oldukça yüksek bir kutu tespit (mAP@0.50) başarısına ulaşmıştır. Referans model olan YOLOv11-seg ise aynı veri dağılımında 0.9245 kutu tespit ve 0.9089 bölütleme (maske) başarısı göstermiştir. Bu sonuçlar, yalnızca nesne tespitine odaklanan YOLOv11 modelinin kusurların konumunu izole etmede daha kararlı olduğunu ve segmentasyon görevinin bu konuda özelleşmiş temel model olan SAM 2'ye bırakılmasının uçtan uca daha güvenilir bir kalite kontrol mekanizması oluşturduğunu sayısal olarak kanıtlamaktadır.

Elde edilen görsel sonuçlar incelendiğinde, YOLOv11 ve SAM 2 entegrasyonunun farklı morfolojik yapılara sahip kusurları tespit etmedeki başarısı üç temel senaryo üzerinden doğrulanmıştır. Öncelikle, doğrusal yapılar halinde panel boyunca uzanan yatay yer değiştirme kusuru, ince ve uzun yapısına rağmen model tarafından kesintisiz bir şekilde tespit edilmiş ve SAM 2 maskesi kusurun tüm hattını başarıyla kaplamıştır. İkinci olarak çatlak sınıfına ait düzensiz, kavisli ve parçalı yapıya sahip kusurlar sadece sınırlayıcı bir kutu içine alınmakla kalmamıştır. Aynı zamanda SAM 2'nin piksel hassasiyeti sayesinde çatlağın kıvrımları tam olarak maskelenmiştir. Son olarak, aynı panel üzerinde birden fazla kusurun bulunduğu (çoklu ve hibrit kusur tespiti) karmaşık senaryolarda, yıldız çatlağın kendine özgü çok kollu yapısı ile ince çatlağın çizgisel yapısı model tarafından karıştırılmadan birbirinden bağımsız olarak tespit edilmiştir. Bu niteliksel bulgular, sayısal olarak raporlanan yüksek doğruluk oranlarını görsel olarak da desteklemektedir.

Doğruluk oranlarındaki bu üstünlüğün yanı sıra, çalışmanın bir diğer kritik çıktısı modelin gerçek zamanlı (real-time) çalışma performansıdır. Yapılan dinamik tarama süreçleri göz önüne alındığında hibrit modelin ön aşamasını oluşturan YOLOv11 saniyede ortalama 720 kare (FPS) işleme hızı ve görüntü başına 1.38 milisaniye çıkarım süresine ulaşmıştır. Bu hız, eş zamanlı maske üretimi yaparak donanım kaynaklarını tüketen referans modele (YOLOv11-seg, ~276 FPS) kıyasla yaklaşık 2.6 kat daha yüksektir.

Geliştirilen bu otonom yapı literatürdeki benzer çalışmalarla karşılaştırıldığında rekabetçi ve üstün sonuçlar ortaya koymaktadır. Klasik makine öğrenmesi ve CNN yaklaşımları göz önüne alındığında Deitsch vd. (2019) CNN tabanlı çalışmasında %88.42, SVM tabanlı

yaklaşımında ise %82.44 doğruluk elde etmiştir. Demirci vd. (2021) ikili sınıflandırmada %94.52 başarıya ulaşmış olsa da, bu tez çalışması çok sınıflı (7 sınıf) ve daha karmaşık bir problemi çözerek daha ileri bir tespiti başarmıştır. YOLO tabanlı önceki çalışmalardan Mazen vd. (2023) YOLOv5 ile %77.7 mAP@0.5 değerinde kalırken, güncel hibrit modellerden Wang vd. (2025) tarafından önerilen MRA-YOLOv8 modeli %91.7 mAP50 değerine ulaşmıştır. Bu tez çalışması %95.71'lik mAP skoru ile güncel literatürü geride bırakmakla kalmamıştır. SAM 2 modelinin sıfır-atış yeteneği sayesinde ek bir poligon etiketleme veya segmentasyon eğitime gerek bırakmayarak model maliyetlerini sıfıra indirmiş ve endüstriyel kalite kontrol süreçleri için yenilikçi bir standart belirlemiştir.

6.2 Gelecek Çalışmalar için Öneriler

Elde edilen başarılı bulgular ışığında, geliştirilen modelin daha da ileri taşınması ve farklı endüstriyel ihtiyaçlara cevap verebilmesi adına dört çalışma önerilmektedir. Bunlardan ilki sınır cihazlara entegrasyon işlemidir. Geliştirilen hibrit modelin Jetson Nano veya Raspberry Pi gibi düşük güçlü ve taşınabilir sınır cihazlara (edge computing) optimize edilerek entegre edilmesi, drone (İHA) tabanlı anlık denetimlerin bulut bağlantısına ihtiyaç duymadan cihaz üzerinde gerçekleştirilmesini sağlayacaktır. İkinci olarak farklı hava ve aydınlatma koşullarında testtir. EL görüntüleri laboratuvar koşullarında veya gece çekimlerinde elde edilmektedir. Modelin dış ortam etkilerine karşı direncini artırmak için görüntü işleme filtreleriyle sentetik olarak üretilmiş gürültülü (noisy) veya düşük kontrastlı veriler üzerinde ince ayar (fine-tuning) çalışmaları yapılabilir. Ardında görüntüleme tekniklerinin çeşitlendirilmesidir. Sistem sadece EL görüntüleri ile sınırlı kalmayıp, Termal Kızılötesi (IR) ve standart RGB (drone kamerası) görüntüleriyle desteklenerek çok modlu (multimodal) bir tespit mimarisine dönüştürülebilir. Bu sayede hücre ısınmaları (hot spot) ve yüzeydeki fiziksel kirlenmeler/gölgelenmeler aynı anda tespit edilebilir. Son olarak farklı güneş paneli teknolojilerine adaptasyon, çalışmanın eğitim veri seti ağırlıklı olarak polikristal veya monokristal silikon tabanlı hücrelere dayanmaktadır. Gelecekteki çalışmalarda modelin ince film (Thin Film) veya perovskit tabanlı yeni nesil güneş pillerindeki kusurları tespit etme yeteneği araştırılabilir.

7. KAYNAKLAR

- Abdelhamid, M., Singh, R., and Omar, M.** (2014). Review of microcrack detection techniques for silicon solar cells. *IEEE Journal of Photovoltaics*, 4(1), 514–524. <https://doi.org/10.1109/JPHOTOV.2013.2285622>
- ACL Digital.** (2024). Data augmentation and its importance in machine learning. ACL Digital. <https://www.acldigital.com/blogs/data-augmentation-in-ml#:~:text=Data%20Augmentation%20is%20a%20technique,to%20get%20the%20larger%20dataset> (Erişim Tarihi: 02 Mart 2025)
- Akram, M. W., Li, G., Jin, Y., Chen, X., Zhu, C., Zhao, X., ... and Ahmad, A.** (2019). CNN based automatic detection of photovoltaic cell defects in electroluminescence images. *Energy*, 189, 116319.
- Al Mahdi, H., Leahy, P. G., Alghoul, M., and Morrison, A. P.** (2024). A review of photovoltaic module failure and degradation mechanisms: Causes and detection techniques. *Solar*, 4(1), 43–82. <https://doi.org/10.3390/solar4010003>
- Al-Waisy, A. S., Ibrahim, D. A., Zebari, D. A., Hammadi, S., Mohammed, H., Mohammed, M. A., and Damaševičius, R.** (2022). Identifying defective solar cells in electroluminescence images using deep feature representations. *PeerJ Computer Science*, 8, e992. <https://doi.org/10.7717/peerj-cs.992>
- Alam, M.** (2024). Ensemble methods in machine learning: A comprehensive guide. *Data Science Dojo*. <https://datasciencedojo.com/blog/ensemble-methods-in-machine-learning/> (Erişim Tarihi: 02 Mart 2025)
- Allied Vision.** (2022). Defect detection in photovoltaic modules. *AltEnergyMag*. Retrieved from <https://www.altenergymag.com/article/2022/04/defect-detection-in-photovoltaic-modules/37111> (Erişim Tarihi: 02 Mart 2025)
- Ameerdin, M. I. M., Jamaluddin, M. H., Shukor, A. Z., and Mohamad, S.** (2024). A review of deep learning-based defect detection and panel localization for photovoltaic panel surveillance system. *International Journal of Robotics and Control Systems*, 4(4), Article 1579. <https://doi.org/10.31763/ijrcs.v4i4.1579>
- Apache Spark.** Evaluation metrics – RDD-based API. In *Spark 3.5.3 documentation*. Retrieved from <https://spark.apache.org/docs/3.5.3/mllib-evaluation-metrics.html#evaluation-metrics-rdd-based-api> (Erişim Tarihi: 02 Mart 2025)

KAYNAKLAR DİZİNİ (devam)

- Bakır, H.** (2024). Detection of micro-cracks in PV system using electroluminescence (EL) testing. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(2), 1-1.
- Bergstra, J., and Bengio, Y.** (2012). Random search for hyper-parameter optimization. *The journal of machine learning research*, 13(1), 281-305.
- Bergstra, J., Bardenet, R., Bengio, Y., and Kégl, B.** (2011). Algorithms for hyper-parameter optimization. *Advances in neural information processing systems*, 24.
- Breitenstein, O., Bauer, J., Bothe, K., Hinken, D., Müller, J., Kwapil, W., Schubert, M.C. and Warta, W.** (2011). Can luminescence imaging replace lock-in thermography on solar cells?. *IEEE Journal of Photovoltaics*, 1(2), 159-167.
- Chen, Z., Li, Y., Wang, J., and Huang, Q.** (2023). Crack Segmentation and Defect Localization of Photovoltaic Cells Using VGG16-UNet Network. *Engineering Applications of Artificial Intelligence*, 120, 105856.
- Deutsch, S., Christlein, V., Berger, S., Buerhop-Lutz, C., Maier, A., Gallwitz, F., and Riess, C.** (2019). Automatic classification of defective photovoltaic module cells in electroluminescence images. *Solar Energy*, 185, 455-468.
- Demirci, M. Y., Beşli, N., ve Gümüşçü, A.** (2021). Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in Electroluminescence images. *Expert Systems with Applications*, 175, 114810.
- Ding, S., Jing, W., Chen, H., and Chen, C.** (2024). YOLO-based defects detection algorithm for EL in PV modules with focal and efficient IoU loss. *Applied Sciences*, 14(17), 7493. <https://doi.org/10.3390/app14177493>
- Du, S., Pan, W., Li, N., Dai, S., Xu, B., Liu, H., Xu, C., and Li, X.** (2024). TSD-YOLO: Small traffic sign detection based on improved YOLO v8. *IET Image Processing*, 18(11), 2884–2898. <https://doi.org/10.1049/ipr2.13141>
- Ebied, M. A., Munshi, A., Alhuzali, S. A., El-Sotouhy, M. M., Shehta, A. I., and Elborlsy, M. S.** (2025). Advanced deep learning modeling to enhance detection of defective photovoltaic cells in electroluminescence images. *Scientific Reports*, 15(1), 31640.
- Fan, T., Sun, T., Xie, X., Liu, H., and Na, Z.** (2022). Automatic micro-crack detection of polycrystalline solar cells in industrial scene. *IEEE Access*, 10, 16269-16282.

KAYNAKLAR DİZİNİ (devam)

- Fernández, A., Usamentiaga, R., de Arquer, P., Fernández, M. Á., Fernández, D., Carús, J. L., and Fernández, M.** (2020). Robust detection, classification and localization of defects in large photovoltaic plants based on unmanned aerial vehicles and infrared thermography. *Applied Sciences*, 10(17), 5948. <https://doi.org/10.3390/app10175948>
- Fuyuki, T., Kondo, H., Yamazaki, T., Takahashi, Y., and Uraoka, Y.** (2005). Photographic surveying of minority carrier diffusion length in polycrystalline silicon solar cells by electroluminescence. *Applied Physics Letters*, 86(26).
- Gad, A. F., and Skelton, J.** (2024). Evaluating object detection models using mean average precision (mAP). *DigitalOcean*. <https://www.digitalocean.com/community/tutorials/mean-average-precision> (Erişim Tarihi: 02 Mart 2025)
- Gallardo-Saavedra, S., Hernández-Callejo, L., Alonso-García, M. C., Muñoz-Cruzado-Alba, J., and Ballestín-Fuertes, J.** (2020). Infrared thermography for the detection and characterization of photovoltaic defects: Comparison between illumination and dark conditions. *Sensors*, 20(16), 4395. <https://doi.org/10.3390/s20164395>
- Hand, D. J., and Till, R. J.** (2001). A simple generalisation of the area under the ROC curve for multiple class classification problems. *Machine Learning*, 45(2), 171–186. <https://doi.org/10.1023/A:1010920819831>
- Høiaas, I., Grujić, K., Imenes, A. G., Burud, I., Olsen, E., and Belbachir, N.** (2022). Inspection and condition monitoring of large-scale photovoltaic power plants: A review of imaging technologies. *Renewable and Sustainable Energy Reviews*, 161, 112353. <https://doi.org/10.1016/j.rser.2022.112353>
- Hsu, C. W., Chang, C. C., and Lin, C. J.** (2003). A practical guide to support vector classification. <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> (Erişim Tarihi: 16 Aralık 2025)
- Huang, C., Zhang, Z., and Wang, L.** (2022). PSOPruner: PSO-based deep convolutional neural network pruning method for PV module defects classification. *IEEE Journal of Photovoltaics*, 12(6), 1550-1558.

KAYNAKLAR DİZİNİ (devam)

- Hussain, T., Hussain, M., Al-Aqrabi, H., Alsboui, T., and Hill, R.** (2023). A review on defect detection of electroluminescence-based photovoltaic cell surface images using computer vision. *Energies*, 16(10), 4012. <https://doi.org/10.3390/en16104012>
- Hutter, F., Hoos, H. H., and Leyton-Brown, K.** (2011). Sequential model-based optimization for general algorithm configuration. In *Learning and intelligent optimization: 5th international conference, LION 5, rome, Italy, January 17-21, 2011. selected papers 5* (pp. 507-523). Springer Berlin Heidelberg.
- IEA-PVPS Task 13.** (2019). Review on IR and EL imaging for PV field applications.
- International Energy Agency Photovoltaic Power Systems Programme (IEA-PVPS).** (2018). Review on IR and EL imaging for PV field applications (IEA PVPS Technical Report T13-10:2018). Retrieved from <https://iea-pvps.org/key-topics/review-on-ir-and-el-imaging-for-pv-field-applications/> (Erişim Tarihi: 02 Mart 2025)
- Jahn, U., Herz, M., Köntges, M., Parlevliet, D., Paggi, M., Tsanakas, I., Stein, J. S., Berger, K. A., Ranta, S., French, R. H., Richter, M., and Tanahashi, T.** (2018). Review on infrared (IR) and electroluminescence (EL) imaging for photovoltaic field applications (IEA PVPS Task 13, Report T13-10:2018). International Energy Agency.
- Jerome Vasanth, J., Naveen Venkatesh, S., Sugumaran, V., and Mahamuni, V. S.** (2023). Enhancing Photovoltaic Module Fault Diagnosis with Unmanned Aerial Vehicles and Deep Learning-Based Image Analysis. *International Journal of Photoenergy*, 2023(1), 8665729.
- Jia, Y., Chen, G., and Zhao, L.** (2024). Defect detection of photovoltaic modules based on improved VarifocalNet. *Scientific Reports*, 14(1), 15170.
- Joo, Y. B., Han, C. H., and Park, K. H.** (2010). Robust Defect Size Measurement Using 3D Modeling for LCD Defect Detection in Automatic Vision Inspection System. *IEICE transactions on electronics*, 93(6), 922-928.
- Keita, Z.** (2024). YOLO Object Detection Explained. DataCamp. <https://www.datacamp.com/blog/yolo-object-detection-explained> (Erişim Tarihi: 07 Aralık 2025)

KAYNAKLAR DİZİNİ (devam)

- Kernc.** (2024). SAMBO: Sequential and model-based optimization: Efficient global optimization in Python (Version v1) [Computer software]. Zenodo. <https://zenodo.org/records/14461363> (Erişim Tarihi: 02 Mart 2025)
- Khanam, R., and Hussain, M.** (2024). Yolov11: An overview of the key architectural enhancements. arXiv preprint arXiv:2410.17725.
- Khanam, R., Asghar, T., and Hussain, M.** (2025). Comparative performance evaluation of YOLOv5, YOLOv8, and YOLOv11 for solar panel defect detection. *Solar*, 5(1), 6. <https://doi.org/10.3390/solar5010006>
- Khosa, I., Rahman, A., Ali, K., Akhtar, J., Armghan, A., Arshad, J., and Amentie, M. D.** (2023). Fault-Level Grading of Photovoltaic Cells Employing Lightweight Deep Learning Models. *Computational Intelligence and Neuroscience*, 2023.
- Kim, B., Serfa Juan, R. O., Lee, D. E., and Chen, Z.** (2021). Importance of image enhancement and CDF for fault assessment of photovoltaic module using IR thermal image. *Applied Sciences*, 11(18), 8388.
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., ... and Girshick, R.** (2023). Segment anything. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 4015-4026).
- Kölblin, P., Bartler, A., and Füller, M.** (2021). Image preprocessing for outdoor luminescence inspection of large photovoltaic parks. *Energies*, 14(9), 2508.
- Köntges, M., Kunze, I., Kajari-Schröder, S., Breitenmoser, X., and Bjørneklett, B.** (2011). The risk of power loss in crystalline silicon based photovoltaic modules due to micro-cracks. *Solar energy materials and solar cells*, 95(4), 1131-1137.
- Mazen, F. M. A., Seoud, R. A. A., and Shaker, Y. O.** (2023). Deep learning for automatic defect detection in PV modules using electroluminescence images. *IEEE Access*, 11, 57783-57795.
- McLachlan, G. J., Do, K. A., and Ambroise, C.** (2005). Analyzing microarray gene expression data.
- Mukherjee, S.** (2024). What's new in YOLOv11 transforming object detection once again part 1. DigitalOcean. <https://www.digitalocean.com/community/tutorials/what-is-new-with-yolo> (Erişim Tarihi: 02 Mart 2025)

KAYNAKLAR DİZİNİ (devam)

- Ozturk, E., Ogliari, E., Sakwa, M., Dolara, A., Blasuttigh, N., and Pavan, A. M.** (2024). Photovoltaic modules fault detection, power output, and parameter estimation: A deep learning approach based on electroluminescence images. *Energy Conversion and Management*, 319, 118866.
- Özel F.**, (2023). Elektrolüminesans testiyle güneş paneli kusurlarını erken teşhis etme ve enerji verimliliğini artırma. Medium. <https://medium.com/@ozelfaruk/%EF%B8%8F-elektrol%C3%BCminesans-testiyle-g%C3%BCne%C5%9F-paneli-kusurlar%C4%B1n%C4%B1-erken-te%C5%9Fhis-etme-ve-enerji-verimlili%C4%9Fini-c777c1104cd1> (Erişim Tarihi: 20 Aralık 2025)
- Parikh, H. R., et al.** (2020). Solar cell cracks and finger failure detection using statistical parameters of EL images and machine learning. *Applied Sciences*, 10(24), 8834.
- Powers, D. M.** (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. arXiv preprint arXiv:2010.16061.
- Qu, Z., Li, L., Zang, J., Xu, Q., Xu, X., Dong, Y., and Fu, K.** (2024). A photovoltaic cell defect detection model capable of topological knowledge extraction. *Scientific Reports*, 14(1), 21904.
- Rahman, M. R. U., and Chen, H.** (2020). Defects inspection in polycrystalline solar cells electroluminescence images using deep learning. *IEEE Access*, 8, 40547-40558.
- Ravi, N., Gabeur, V., Hu, Y. T., Hu, R., Ryali, C., Ma, T., ... and Feichtenhofer, C.** (2024). Sam 2: Segment anything in images and videos. arXiv preprint arXiv:2408.00714.
- Saborido-Barba, N., García-López, C., Clavijo-Blanco, J. A., Jiménez-Castañeda, R., and Álvarez-Tey, G.** (2024). Methodology for calculating the damaged surface and its relationship with power loss in photovoltaic modules by electroluminescence inspection for corrective maintenance. *Sensors*, 24(5), 1479.
- Salmi, M., and Pei, E.** (2023). Additive manufacturing processes and materials for spare parts. *Journal of Mechanical Science and Technology*, 37(11), 5979–5990. <https://doi.org/10.1007/s12206-023-1034-0>
- Scharcanski, J.** (2005). Stochastic texture analysis for monitoring stochastic processes in industry. *Pattern Recognition Letters*, 26(11), 1701-1709.

KAYNAKLAR DİZİNİ (devam)

- Simplilearn.** (2024). The best guide to regularization in machine learning (Lesson 24 of 40). <https://www.simplilearn.com/tutorials/machine-learning-tutorial/regularization-in-machine-learning> (Erişim Tarihi: 02 Mart 2025)
- Snoek, J., Larochelle, H., and Adams, R. P.** (2012). Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 25.
- Song, X., Qi, L., Huang, D., Wang, Z., Li, L., Zhang, J., and Gao, Y.** (2021). A real-time apple grading method with YOLOv4 in the experiments. *Sensors*, 21(14), 4655. <https://doi.org/10.3390/s21144655>
- Stehman, S. V.** (1997). Estimating standard errors of accuracy assessment statistics under cluster sampling. *Remote Sensing of Environment*, 60(3), 258–269. [https://doi.org/10.1016/S0034-4257\(96\)00176-9](https://doi.org/10.1016/S0034-4257(96)00176-9)
- Su, B., Chen, H., and Zhou, Z.** (2021). BAF-Detector: An efficient CNN-based detector for photovoltaic cell defect detection. *IEEE Transactions on Industrial Electronics*, 69(3), 3161–3171. <https://doi.org/10.1109/TIE.2021.3070507>
- Tang, W., et al.** (2020). Deep learning-based automatic defect identification of photovoltaic modules using EL images. *Solar Energy*, 201, 485–498.
- Tang, W., Yang, Q., and Yan, W.** (2022). Deep Learning-Based Algorithm for Multi-Type Defects Detection in Solar Cells with Aerial EL Images for Photovoltaic Plants. *CMES-Computer Modeling in Engineering & Sciences*, 130(3).
- Tella, H., Hussein, A., Rehman, S., Liu, B., Balghonaim, A., Mohandes, M.** (2025). Solar photovoltaic panel cells defects classification using deep learning ensemble methods. *Case Studies in Thermal Engineering*, Vol. 66, Article 105749. DOI: 10.1016/j.csite.2025.105749.
- Thornton, C., Hutter, F., Hoos, H. H., and Leyton-Brown, K.** (2013). Auto-WEKA: Combined selection and hyperparameter optimization of classification algorithms. In *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 847-855)
- Tomasi, C., and Manduchi, R.** (1998). Bilateral filtering for gray and color images. In *Sixth international conference on computer vision (IEEE Cat. No. 98CH36271)* (pp. 839-846). IEEE.

KAYNAKLAR DİZİNİ (devam)

- Ultralytics.** (2024a). YOLO Performance Metrics Guide. Ultralytics Documentation. <https://docs.ultralytics.com/tr/guides/yolo-performance-metrics/> (Erişim Tarihi: 02 Mart 2025)
- Ultralytics.** (2024b). YOLOv11: Next-Generation Object Detection Architecture. <https://docs.ultralytics.com/compare/yolo11-vs-yolo26/> (Erişim Tarihi: 13 Şubat 2026)
- Ultralytics.** (2024c). Ultralytics YOLO11 (Model documentation). Ultralytics Documentation. <https://docs.ultralytics.com/models/yolo11/> (Erişim Tarihi: 13 Şubat 2026)
- Ultralytics..** (2024d). YOLO Vision 2024 (Event page). Ultralytics. <https://www.ultralytics.com/events/yolovision/2024> (Erişim Tarihi: 13 Şubat 2026)
- Ultralytics.** (2026). YOLO11 vs PP-YOLOE+: Detailed architecture and performance comparison. Ultralytics Documentation. <https://docs.ultralytics.com/compare/yolo11-vs-pp-yoloe/>
- Wang, J., and Cheng, Z.** (2025). Photovoltaic panel defect detection algorithm based on infrared imaging and improved YOLOv8. PeerJ Computer Science, 11, e2776.
- Wang, J., et al.** (2022). Deep-learning-based automatic detection of photovoltaic cell defects in electroluminescence images. Sensors, 23(1), 297.
- Wang, Z., Hutter, F., Zoghi, M., Matheson, D., and De Freitas, N.** (2016). Bayesian optimization in a billion dimensions via random embeddings. Journal of Artificial Intelligence Research, 55, 361-387.
- Yang, X., Pang, G., and Yung, N.** (2005). Robust fabric defect detection and classification using multiple adaptive wavelets. IEE Proceedings-Vision, Image and Signal Processing, 152(6), 715-723.
- Zhang, L., et al.** (2018). Detection of finger interruptions in silicon solar cells using photoluminescence imaging. Chinese Physics B, 27(6), 068801.