

**T.C.  
BİNGÖL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTROLÜMİNESANS GÖRÜNTÜLERİNDE FOTOVOLTAİK  
PANEL HÜCRELERİNİN DERİN ÖĞRENME İLE OTOMATİK  
KUSUR TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**FATİH GÜNDOĞDU**

**YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI**

**TEZ DANIŞMANI  
Dr. Öğr. Üyesi Mücahit ÇALIŞAN**

**BİNGÖL-2026**

**T.C.  
BİNGÖL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTROLÜMİNESANS GÖRÜNTÜLERİNDE FOTOVOLTAİK  
PANEL HÜCRELERİNİN DERİN ÖĞRENME İLE OTOMATİK  
KUSUR TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**FATİH GÜNDOĞDU**

**YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI**

**TEZ DANIŞMANI  
Dr. Öğr. Üyesi Mücahit ÇALIŞAN**

**BİNGÖL-2026**

**ELEKTROLÜMİNESANS GÖRÜNTÜLERİNDE FOTOVOLTAİK  
PANEL HÜCRELERİNİN DERİN ÖĞRENME İLE OTOMATİK  
KUSUR TESPİTİ**

..... danışmanlığında, ..... tarafından hazırlanan bu çalışma  
...../...../..... tarihinde aşağıdaki jüri tarafından ..... Anabilim Dalı'nda Yüksek  
Lisans Tezi olarak **oybirliği/oy çokluğu (.../...)** ile kabul edilmiştir.

|          |        |
|----------|--------|
| Başkan : | İmza : |
| Üye :    | İmza : |
| Üye :    | İmza : |

Yukarıdaki sonuç;

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

**Doç. Dr. Murat DENER**  
**Enstitü Müdürü**

Bu çalışma ..... (örn. BAP, DPT, Tübitak 1001, v.s.) projeleri kapsamında  
desteklenmiştir.

Proje No: (Bir projeye desteklenmeyen tezlerde bu bölüm silinecektir)

---

**Not:** Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

## ÖNSÖZ

Güneş enerjisi, günümüzde yenilenebilir enerji kaynakları arasında en hızlı büyüyen ve en umut verici teknolojilerin başında gelmektedir. Fotovoltaik panellerin verimliliği, enerji üretim sürekliliği ve sistemin uzun ömürlü olması, büyük ölçüde panellerde meydana gelen kusurların erken teşhis edilmesine bağlıdır. Bu tez çalışması, elektrolüminesans görüntüleme tekniği ile elde edilen görüntüler üzerinde derin öğrenme yöntemleri kullanarak fotovoltaik hücre kusurlarının otomatik olarak tespit edilmesine yönelik bir yaklaşım sunmaktadır.

Bu çalışmanın gerçekleştirilmesinde büyük emeği ve katkısı olan, tez sürecim boyunca bilgi ve deneyimlerini benimle cömertçe paylaşan, karşılaştığım her zorlukta yol gösterici olan ve akademik gelişimime önemli katkılar sağlayan danışmanım **Dr. Öğr. Üyesi Mücahit ÇALIŞAN**'a en içten saygı ve şükranlarımı sunarım.

Çalışmada kullanılan elektrolüminesans görüntü verilerini sağlayarak tezin uygulama boyutuna önemli katkıda bulunan **GTC Güneş Sanayi ve Ticaret A.Ş.** yönetimine ve çalışanlarına teşekkür ederim. Gerçek bir üretim hattından elde edilen bu veriler, çalışmanın sektörel gerçekliklerle örtüşmesini ve elde edilen sonuçların uygulamaya dönük değerini artırmıştır.

Yüksek lisans eğitimim boyunca maddi ve manevi desteklerini esirgemeyen, her zaman yanımda olan sevgili aileme; eğitim hayatım boyunca gösterdikleri sabır, anlayış ve sonsuz destekleri için minnettarım.

Bu çalışmanın, fotovoltaik enerji sektöründe kalite kontrol süreçlerine ve akademik literatüre katkı sağlaması en büyük dileğimdir.

**Fatih GÜNDOĞDU**  
**BİNGÖL 2026**

# İÇİNDEKİLER

|                                                                                     |     |
|-------------------------------------------------------------------------------------|-----|
| ÖNSÖZ .....                                                                         | i   |
| İÇİNDEKİLER .....                                                                   | ii  |
| SİMGELER VE KISALTMALAR LİSTESİ .....                                               | v   |
| ŞEKİLLER LİSTESİ .....                                                              | vii |
| TABLolar LİSTESİ .....                                                              | x   |
| ÖZET .....                                                                          | xi  |
| ABSTRACT .....                                                                      | xii |
| 1. GİRİŞ .....                                                                      | 1   |
| 1.1. Çalışmanın Amacı ve Kapsamı .....                                              | 2   |
| 2. KAYNAK ÖZETLERİ .....                                                            | 4   |
| 2.1. Güneş Paneli Sınıflandırma Çalışmaları .....                                   | 4   |
| 2.2. Görüntü Tabanlı Kusur Tespiti Çalışmaları .....                                | 7   |
| 2.3. Derin Öğrenme ve Güncel Yaklaşımlar .....                                      | 9   |
| 2.4. Tezin Organizasyonu .....                                                      | 10  |
| 3. GÜNEŞ ENERJİSİ PANEL SİSTEMLERİ .....                                            | 12  |
| 3.1. Dünyada ve Türkiye’de Güneş Enerjisi Kullanımı .....                           | 12  |
| 3.2. Güneş Paneli Teknolojisinin Temelleri .....                                    | 16  |
| 3.3. Güneş Paneli Çeşitleri .....                                                   | 18  |
| 3.3.1. Kristal Silikon Tabanlı Fotovoltaik Teknolojiler .....                       | 19  |
| 3.3.2. Kadmiyum Tellür (CdTe) Tabanlı Fotovoltaik Teknolojiler .....                | 20  |
| 3.3.3. Bakır İndiyum Galyum Diselenit (CIGS) Tabanlı Fotovoltaik Teknolojiler ..... | 22  |
| 3.3.4. Perovskit Tabanlı Fotovoltaik Teknolojiler .....                             | 23  |
| 3.3.5. Çoklu Bağlantılı (III-V) Fotovoltaik Teknolojiler .....                      | 24  |
| 3.3.6. Organik Fotovoltaik Teknolojiler .....                                       | 25  |
| 3.4. Güneş Paneli Tasarımı ve Verimlilik Kriterleri .....                           | 25  |
| 3.5. Güneş Paneli Kusur Türleri .....                                               | 27  |
| 3.6. Elektrolüminesans (EL) Görüntüleme Yöntemi .....                               | 30  |
| 4. DERİN ÖĞRENME YÖNTEMLERİ VE BAŞARIM METRİKLERİ .....                             | 32  |
| 4.1. Yapay Sinir Ağları ve Temel Kavramlar .....                                    | 32  |

|                                                                     |    |
|---------------------------------------------------------------------|----|
| 4.2. Evrişimli Sinir Ağları (CNN) .....                             | 36 |
| 4.2.1. Evrişim Katmanı .....                                        | 37 |
| 4.2.2. Havuzlama Katmanı.....                                       | 38 |
| 4.2.3. Tam Bağlantılı Katman ve Sınıflandırma .....                 | 39 |
| 4.3. Transfer Öğrenme.....                                          | 40 |
| 4.3.1. Transfer Öğrenme Stratejileri .....                          | 41 |
| 4.3.2. Öne Çıkan Mimariler (ResNet, EfficientNet, MobileNet).....   | 42 |
| 4.3.3. Dikkat Mekanizmaları ve Sıkıştırma-Uyarma (SE) Blokları..... | 44 |
| 4.4. İkili Sınıflandırma .....                                      | 45 |
| 4.5. Başarım Metrikleri.....                                        | 48 |
| 4.5.1. Doğruluk, Hassasiyet, Geri Çağırma ve F1-Skoru.....          | 49 |
| 4.5.2. ROC Eğrisi ve AUC.....                                       | 50 |
| 4.5.3. Karmaşıklık Matrisi .....                                    | 51 |
| 5. MATERYAL VE YÖNTEM .....                                         | 53 |
| 5.1. Veri Seti.....                                                 | 53 |
| 5.1.1. Veri Setinin Tanımı ve Kaynağı .....                         | 54 |
| 5.1.2. Sınıf Dağılımı ve Görüntü Özellikleri.....                   | 55 |
| 5.1.3. Doğrulama Veri Seti: ELPV .....                              | 56 |
| 5.2. Ön İşleme ve Veri Hazırlama .....                              | 57 |
| 5.2.1. Hücre Segmentasyonu.....                                     | 58 |
| 5.2.2. Görüntü Ön İşleme .....                                      | 59 |
| 5.2.3. Veri Artırma Teknikleri .....                                | 60 |
| 5.3. Derin Öğrenme Modelinin Mimarisi.....                          | 61 |
| 5.3.1. Baz Modeller ve Seçim Gerekçesi .....                        | 61 |
| 5.3.2. Önerilen Model: SE ile Güçlendirilmiş ResNet50.....          | 63 |
| 5.3.3. Transfer Öğrenme ve İnce Ayar Süreci .....                   | 65 |
| 5.4. Modelin Eğitim Süreci .....                                    | 66 |
| 5.4.1. Eğitim-Doğrulama-Test Bölünmesi .....                        | 67 |

|                                                                 |    |
|-----------------------------------------------------------------|----|
| 5.4.2. Hiperparametre Ayarları .....                            | 68 |
| 5.4.3. Kayıp Fonksiyonu ve Optimizasyon Algoritması.....        | 69 |
| 6. BULGULAR VE TARTIŞMA .....                                   | 70 |
| 6.1. DeneySEL Kurulum.....                                      | 70 |
| 6.2. GTC Veri Seti Üzerindeki Sonuçlar .....                    | 72 |
| 6.2.1. Eğitim ve Doğrulama Eğrileri .....                       | 72 |
| 6.2.2. Aşırı Öğrenme Analizi .....                              | 75 |
| 6.2.3. Karmaşıklık Matrisi ve Test Metrikleri.....              | 76 |
| 6.2.4. ROC Eğrisi ve AUC Değerlendirmesi .....                  | 78 |
| 6.3. ELPV Veri Seti Üzerindeki Sonuçlar .....                   | 80 |
| 6.3.1. Eğitim ve Doğrulama Eğrileri .....                       | 81 |
| 6.3.2. Aşırı Öğrenme Analizi .....                              | 85 |
| 6.3.3. Karmaşıklık Matrisi ve Test Metrikleri.....              | 86 |
| 6.4. Model Karşılaştırması .....                                | 90 |
| 6.4.1. Önerilen Model ve Baz Modellerin Karşılaştırılması ..... | 90 |
| 6.4.2. SE Bloğunun Katkısı.....                                 | 90 |
| 7. SONUÇLAR VE ÖNERİLER .....                                   | 92 |
| 7.1. Genel Değerlendirme.....                                   | 92 |
| 7.2. Çalışmanın Katkıları.....                                  | 93 |
| 7.3. Sınırlılıklar.....                                         | 94 |
| 7.4. Gelecek Çalışmalar için Öneriler .....                     | 94 |
| KAYNAKLAR .....                                                 | 96 |

## SİMGELER VE KISALTMALAR LİSTESİ

|      |                                                                  |
|------|------------------------------------------------------------------|
| Adam | Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation)        |
| AUC  | Eğri Altındaki Alan (Area Under the Curve)                       |
| CIGS | Bakır İndiyum Galyum Diselenit                                   |
| CNN  | Evrişimli Sinir Ağı (Convolutional Neural Network)               |
| CdTe | Kadmiyum Tellür                                                  |
| DCNN | Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network)    |
| DN   | Doğru Negatif (True Negative)                                    |
| DP   | Doğru Pozitif (True Positive)                                    |
| EL   | Elektrolüminesans                                                |
| ELPV | Fotovoltaik Hücrelerin Elektrolüminesansı                        |
| EVA  | Etilen-Vinil Asetat                                              |
| F1   | F1-Skoru (F1-Score)                                              |
| FCN  | Tam Evrişimli Ağ (Fully Convolutional Network)                   |
| GPU  | Grafik İşlem Birimi (Graphics Processing Unit)                   |
| GTC  | GTC Güneş Sanayi ve Ticaret A.Ş.                                 |
| HJT  | Heteroeklem Teknolojisi                                          |
| IEA  | Uluslararası Enerji Ajansı (International Energy Agency)         |
| IR   | Kızılötesi (Infrared)                                            |
| MLP  | Çok Katmanlı Algılayıcı (Multilayer Perceptron)                  |
| OPV  | Organik Fotovoltaik                                              |
| PERC | Pasiflenmiş Yayıcı ve Arka Hücre                                 |
| PID  | Potansiyel Kaynaklı Bozulma (Potential-Induced Degradation)      |
| PV   | Fotovoltaik (Photovoltaic)                                       |
| ReLU | Düzeltilmiş Doğrusal Birim (Rectified Linear Unit)               |
| RGB  | Kırmızı, Yeşil, Mavi (Red, Green, Blue)                          |
| RLSA | Çalışma Uzunluğu Düzgünleştirme Algoritması                      |
| ROC  | Alıcı İşletim Karakteristiği (Receiver Operating Characteristic) |
| SE   | Sıkıştırma-Uyarma (Squeeze-and-Excitation)                       |

|          |                                         |
|----------|-----------------------------------------|
| SHJ      | Silikon Heteroeklem                     |
| Tanh     | Hiperbolik Tanjant (Hyperbolic Tangent) |
| TOPCon   | Tünel Oksitli Pasif Kontak              |
| YN       | Yanlış Negatif (False Negative)         |
| YP       | Yanlış Pozitif (False Positive)         |
| $\eta$   | Öğrenme oranı (learning rate)           |
| $\sigma$ | Sigmoid aktivasyon fonksiyonu           |
| $\tau$   | Karar eşiği (threshold)                 |
| w        | Ağırlık (weight)                        |
| b        | Eşik değeri (bias)                      |
| z        | Net girdi                               |
| L        | Kayıp (loss)                            |

## ŞEKİLLER LİSTESİ

|                                                                                                                                                                                                                                         |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 3.1. Küresel güneş enerjisi kurulum verileri (2024) (IEA PVPS, 2025) .....                                                                                                                                                        | 12 |
| Şekil 3.2. Kişi Başına Düşen PV Kapasitesi (IEA PVPS, 2025) .....                                                                                                                                                                       | 13 |
| Şekil 3.3. En Yüksek PV Nüfuzuna Sahip Ülkeler (IEA PVPS, 2025) .....                                                                                                                                                                   | 13 |
| Şekil 3.4. Yıllık PV Kurulumlarının Gelişimi (IEA PVPS, 2025) .....                                                                                                                                                                     | 14 |
| Şekil 3.5. 2025-2029 yılları arasında güneş enerjisi panellerine yapılacak eklemelerde<br>ilk 10 Pazar (SolarPower Europe, 2025) .....                                                                                                  | 15 |
| Şekil 3.6. Birincil Fotovoltaik etki ile güneş enerjisinin elektrik enerjisine dönüşüm<br>mekanizması. ....                                                                                                                             | 16 |
| Şekil 3.7. PV sistemlerin hücre, modül ve dizi yapısındaki hiyerarşik bileşimi .....                                                                                                                                                    | 17 |
| Şekil 3.8. Kristal silikon Fotovoltaik hücre örnekleri .....                                                                                                                                                                            | 19 |
| Şekil 3.9. Ultra ince cam üzerine yerleştirilmiş esnek CdTe güneş hücreleri<br>(Mahabaduge ve ark.) (URL-3, 2026) .....                                                                                                                 | 20 |
| Şekil 3.10. CdTe güneş pilinin yapısı (URL-3, 2026) .....                                                                                                                                                                               | 21 |
| Şekil 3.11. Bakır İndiyum Galyum Diselenit (CIGS) güneş pilinin yapısı<br>(URL-3, 2026) .....                                                                                                                                           | 22 |
| Şekil 3.12. Perovskit güneş hücresi (Dennis Schroeder / National Renewable Energy<br>Laboratory) (URL-3, 2026) .....                                                                                                                    | 23 |
| Şekil 3.13. Rekor seviyeye yakın iki bağlantılı III-V güneş pili, galyum indiyum<br>fosfit üst hücresinin luminesansı nedeniyle kırmızı renkte parlıyor ve<br>malzemenin iyi kalitesini gösteriyor. Fotoğraf: NREL. (URL-3, 2026) ..... | 24 |
| Şekil 3.14. Organik fotovoltaik güneş hücresi (URL-3, 2026) .....                                                                                                                                                                       | 25 |
| Şekil 3.15. EL testi ile görülebilen mikro çatlaklar (URL-4, 2026) .....                                                                                                                                                                | 28 |
| Şekil 3.16. Busbar kopması (URL-4, 2026) .....                                                                                                                                                                                          | 29 |
| Şekil 4.1. Yapay nöron modelinin temel bileşenleri .....                                                                                                                                                                                | 33 |
| Şekil 4.2. Sigmoid, Tanh ve ReLU aktivasyon fonksiyonlarının davranışı .....                                                                                                                                                            | 34 |
| Şekil 4.3. Evrişimli sinir ağının genel mimarisi ve EL görüntüsü üzerinde<br>Defect/Normal sınıflandırma akışı .....                                                                                                                    | 36 |
| Şekil 4.4. Bir çekirdeğin girdi üzerinde kaydırılmasıyla öznitelik haritasının<br>oluşturulması .....                                                                                                                                   | 37 |

|                                                                                                                                                                                                    |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 4.5. 2×2 boyutlu pencere ile maksimum ve ortalama havuzlama işlemleri.....                                                                                                                   | 39 |
| Şekil 4.6. ImageNet üzerinde önceden eğitilmiş bir ağın EL görüntüleriyle kusur sınıflandırmaya transferi .....                                                                                    | 41 |
| Şekil 4.7. ResNet mimarisindeki artık (residual) blok ve özdeşlik kestirme bağlantısı..                                                                                                            | 42 |
| Şekil 4.8. Sigmoid çıktısı, karar eşiği ( $\tau = 0,5$ ) ve Normal/Defect karar bölgeleri.....                                                                                                     | 45 |
| Şekil 4.9. Sigmoid çıktısı, karar eşiği ( $\tau = 0,5$ ) ve Normal/Defect karar bölgeleri.....                                                                                                     | 47 |
| Şekil 4.10. Örnek bir ROC eğrisi ve eğri altındaki alan (AUC) .....                                                                                                                                | 51 |
| Şekil 4.11. İkili sınıflandırma için karmaşıklık matrisinin yapısı.....                                                                                                                            | 51 |
| Şekil 5.1. EL Görüntüleme Cihazı .....                                                                                                                                                             | 54 |
| Şekil 5.2. Veri kümesinden örnek EL hücre görüntüleri: (a)–(d) kusurlu (Defect) hücreler; (e)–(h) sağlıklı (Normal) hücreler. ....                                                                 | 56 |
| Şekil 5.3. ELPV veri kümesinden dört kusur-olasılığı sınıfına ait örnek monokristal hücre görüntüleri (soldan sağa: kusursuz 0,0; düşük 0,33; orta 0,67; yüksek 1,0).....                          | 57 |
| Şekil 5.4. Hücre segmentasyonu, görüntü ön işleme ve veri artırma adımlarını içeren genel ön işleme ve veri hazırlama iş akışı .....                                                               | 58 |
| Şekil 5.5. 60 Hücreli Panel'in EL görüntüsü ve her hücrenin ayrıştırılmış hali .....                                                                                                               | 59 |
| Şekil 5.6. Bir örnek hücre görüntüsüne uygulanan döndürme ve yansıtma tabanlı veri artırma sonuçları .....                                                                                         | 61 |
| Şekil 5.7. Önerilen modelin genel mimarisi: ImageNet ön-eğitilmiş ResNet50 omurgası, kanal dikkat sağlayan SE bloğu ve sigmoidli sınıflandırıcı. Sağda SE bloğunun içyapısı gösterilmektedir. .... | 65 |
| Şekil 6.1. ResNet50 modeli eğitim ve doğrulama doğruluk eğrileri.....                                                                                                                              | 72 |
| Şekil 6.2. ResNet50 modeli eğitim ve doğrulama kayıp eğrileri .....                                                                                                                                | 73 |
| Şekil 6.3. EfficientNetB0 modeli eğitim ve doğrulama doğruluk eğrileri.....                                                                                                                        | 73 |
| Şekil 6.4. EfficientNetB0 modeli eğitim ve doğrulama kayıp eğrileri .....                                                                                                                          | 74 |
| Şekil 6.5. MobileNetV2 modeli eğitim ve doğrulama doğruluk eğrileri .....                                                                                                                          | 74 |
| Şekil 6.6. MobileNetV2 modeli eğitim ve doğrulama kayıp eğrileri.....                                                                                                                              | 75 |
| Şekil 6.7. ResNet50 modeline ait karmaşıklık matrisi.....                                                                                                                                          | 77 |
| Şekil 6.8. EfficientNetB0 modeline ait karmaşıklık matrisi .....                                                                                                                                   | 77 |
| Şekil 6.9. MobileNetV2 modeline ait karmaşıklık matrisi .....                                                                                                                                      | 78 |
| Şekil 6.10. ResNet50+SE (Önerilen) modeline ait karmaşıklık matrisi .....                                                                                                                          | 78 |
| Şekil 6.11. ResNet50 modeline ait ROC eğrisi.....                                                                                                                                                  | 79 |

|                                                                                 |    |
|---------------------------------------------------------------------------------|----|
| Şekil 6.12. EfficientNetB0 modeline ait ROC eğrisi .....                        | 80 |
| Şekil 6.13. MobileNetV2 modeline ait ROC eğrisi .....                           | 80 |
| Şekil 6.14. ResNet50 modeli ELPV eğitim ve doğrulama doğruluk eğrisi .....      | 81 |
| Şekil 6.15. ResNet50 modeli ELPV eğitim ve doğrulama kayıp eğrisi.....          | 82 |
| Şekil 6.16. ResNet50+SE modeli ELPV eğitim ve doğrulama doğruluk eğrisi .....   | 82 |
| Şekil 6.17. ResNet50+SE modeli ELPV eğitim ve doğrulama kayıp eğrisi.....       | 83 |
| Şekil 6.18. EfficientNetB0 modeli ELPV eğitim ve doğrulama doğruluk eğrisi..... | 83 |
| Şekil 6.19. EfficientNetB0 modeli ELPV eğitim ve doğrulama kayıp eğrisi .....   | 84 |
| Şekil 6.20. MobileNetV2 modeli ELPV eğitim ve doğrulama doğruluk eğrisi.....    | 84 |
| Şekil 6.21. MobileNetV2 modeli ELPV eğitim ve doğrulama kayıp eğrisi .....      | 85 |
| Şekil 6.22. ResNet50 modeline ait ELPV karmaşıklık matrisi .....                | 87 |
| Şekil 6.23. ResNet50+SE modeline ait ELPV karmaşıklık matrisi .....             | 87 |
| Şekil 6.24. EfficientNetB0 modeline ait ELPV karmaşıklık matrisi .....          | 88 |
| Şekil 6.25. MobileNetV2 modeline ait ELPV karmaşıklık matrisi .....             | 88 |
| Şekil 6.26. Modellerin ELPV veri setinde sınıf bazına F1 karşılaştırması .....  | 89 |

## TABLolar LİSTESİ

|                                                                                                                             |    |
|-----------------------------------------------------------------------------------------------------------------------------|----|
| Tablo 4.1. Transfer öğrenmede yaygın kullanılan önceden eğitilmiş mimarilerin karşılaştırılması .....                       | 43 |
| Tablo 5.1. Veri kümesinin sınıf dağılımı. ....                                                                              | 55 |
| Tablo 5.2. Baz mimariler ve önerilen modelin temel özellikleri. ....                                                        | 62 |
| Tablo 5.3. GTC veri kümesinde 5-katlı çapraz doğrulama için kat başına sınıf dağılımı (dört kat eğitim, bir kat test). .... | 67 |
| Tablo 5.4. Model eğitiminde kullanılan hiperparametreler. ....                                                              | 68 |
| Tablo 6.1. Deneylerde kullanılan hiperparametre yapılandırması. ....                                                        | 71 |
| Tablo 6.2. GTC veri seti üzerinde baz modellerin test metrikleri.....                                                       | 76 |
| Tablo 6.3. GTC veri seti üzerinde baz modellerin karmaşıklık matrisi değerleri (5 kat toplamı).....                         | 76 |
| Tablo 6.4. ELPV veri seti üzerinde modellerin ortalama test metrikleri. ....                                                | 86 |
| Tablo 6.5. ELPV veri seti üzerinde modellerin sınıf bazlı F1 değerleri. ....                                                | 89 |
| Tablo 6.6. Önerilen model ile baz modellerin her iki veri seti üzerindeki karşılaştırması. ....                             | 90 |
| Tablo 6.7. SE bloğunun katkısına ilişkin ablasyon karşılaştırması (ResNet50 vs. ResNet50+SE). ....                          | 91 |

# ELEKTROLÜMINESANS GÖRÜNTÜLERİNDE FOTOVOLTAİK PANEL HÜCRELERİNİN DERİN ÖĞRENME İLE OTOMATİK KUSUR TESPİTİ

## ÖZET

Bu tez çalışmasında, fotovoltaik (PV) güneş hücrelerinde meydana gelen kusurların, elektrolüminesans (EL) görüntüleri üzerinden derin öğrenme yöntemleri kullanılarak otomatik olarak tespit edilmesi amaçlanmıştır. Güneş enerjisi sistemlerinin hızla yaygınlaşması, PV panellerde oluşan mikro çatlak, hücre kırığı, busbar kopması ve PID gibi kusurların erken teşhisini zorunlu kılmaktadır.

Çalışmada iki farklı veri seti kullanılmıştır. Birincil veri seti, GTC Güneş Sanayi ve Ticaret A.Ş.'nin üretim hattından elde edilen 540 kusurlu ve 500 sağlıklı olmak üzere toplam 1040 hücre görüntüsünden oluşmaktadır. İkincil olarak, önerilen yaklaşımın genellenebilirliğini test etmek amacıyla dört sınıflı ve belirgin dengesizliğe sahip kamuya açık ELPV veri seti kullanılmıştır. Görüntü ön işleme aşamasında, panel görüntüleri geliştirilmiş RLSA tabanlı segmentasyon yaklaşımıyla hücrelere ayrıştırılmış, 227×227 piksel boyutuna getirilmiş ve normalleştirilmiştir. Veri artırma teknikleri ile eğitim verisi çeşitlendirilerek modelin genelleme yeteneği artırılmıştır.

Önerilen model, ImageNet üzerinde önceden eğitilmiş ResNet50 omurgasının, kanal bazında dikkat sağlayan Squeeze-and-Excitation (SE) bloğu ile güçlendirilmesine dayanmaktadır. SE bloğu, öznelilik haritalarındaki kanalları yeniden ağırlıklandırarak ayırt edici kanalların öne çıkarılmasını sağlamaktadır. Modelin başarımı, ResNet50, EfficientNetB0 ve MobileNetV2 baz modelleri ile 5 katlı tabakalı çapraz doğrulama protokolü kullanılarak karşılaştırmalı olarak değerlendirilmiştir. İkili sınıflandırma görevinde tüm modeller %98-99 aralığında yüksek başarımler sergilerken, dört sınıflı ELPV veri setinde önerilen ResNet50+SE modeli %76,09 doğruluk ve 0,559 F1-skoru ile en yüksek başarımları elde etmiştir. SE bloğu, düz ResNet50'ye kıyasla doğrulukta yaklaşık 9,85 puanlık iyileşme sağlamıştır.

Elde edilen bulgular, SE bloğu ile güçlendirilmiş ResNet50 mimarisinin, özellikle zorlu ve dengesiz veri koşullarında kanal bazında dikkat mekanizması sayesinde ayırt edici öznelilikleri başarıyla öne çıkarabildiğini göstermektedir. Çalışma, gerçek bir üretim hattından elde edilen verilerle desteklenmiş olup, önerilen modelin fotovoltaik üretim süreçlerinde otomatik kalite kontrol sistemi olarak kullanılabileceğini ortaya koymaktadır.

**Anahtar Kelimeler:** Fotovoltaik Hücre, Elektrolüminesans, Kusur Tespiti, Derin Öğrenme, Evrişimli Sinir Ağı, ResNet, Dikkat Mekanizması.

# **AUTOMATIC DEFECT DETECTION OF PHOTOVOLTAIC PANEL CELLS IN ELECTROLUMINESCENCE IMAGES USING DEEP LEARNING**

## **ABSTRACT**

This thesis aims to automatically detect defects occurring in photovoltaic (PV) solar cells using deep learning methods on electroluminescence (EL) images. The rapid expansion of solar energy systems necessitates early diagnosis of defects such as micro-cracks, cell fractures, busbar breaks, and potential-induced degradation (PID) in PV panels.

Two different datasets were used in this study. The primary dataset consists of 1040 cell images obtained from the production line of GTC Güneş Sanayi ve Ticaret A.Ş., comprising 540 defective and 500 healthy cells. Secondly, the publicly available ELPV dataset, which has a four-class structure with significant imbalance, was used to test the generalizability of the proposed approach. During image preprocessing, panel images were segmented into individual cells using an improved RLSA-based segmentation approach, resized to 227×227 pixels, and normalized. Data augmentation techniques were applied to diversify the training data and enhance the model's generalization capability.

The proposed model is based on a pre-trained ResNet50 backbone on ImageNet, enhanced with a Squeeze-and-Excitation (SE) block that provides channel-wise attention. The SE block reweights the channels in the feature maps, highlighting discriminative channels and thus contributing to more effective learning of defect patterns. The model's performance was comparatively evaluated against three baseline models—ResNet50, EfficientNetB0, and MobileNetV2—using a 5-fold stratified cross-validation protocol. While all models achieved high performance in the range of 98-99% on the binary classification task, the proposed ResNet50+SE model achieved the highest performance on the four-class ELPV dataset with 76.09% accuracy and 0.559 F1-score. The SE block provided an improvement of approximately 9.85 percentage points in accuracy compared to plain ResNet50.

The findings demonstrate that the SE-enhanced ResNet50 architecture can successfully highlight discriminative features through its channel-wise attention mechanism, particularly under challenging and imbalanced data conditions. Supported by data obtained from a real production line, this study reveals that the proposed model can serve as an automated quality control system in photovoltaic manufacturing processes.

**Keywords:** Photovoltaic Cell, Electroluminescence, Defect Detection, Deep Learning, Convolutional Neural Network, ResNet, Attention Mechanism.

## 1. GİRİŞ

Dünyada enerji talebi her geçen gün artmakta ve fosil yakıtların ekosisteme verdikleri zararlar belirgin bir hale gelmektedir. Bu sebeple küresel strateji açısından yenilebilir enerji kaynaklarının kullanımı öncelikli hale gelmiştir. Temiz, sürdürülebilir ve anında erişimin mümkün olduğu güneş enerjisi, kullanılan yenilebilir enerji kaynakları içinde merkezi bir konuma sahiptir. Fotovoltaik (PV) sistemler, güneşten dünyamıza ulaşan fotonların enerjilerini doğrudan elektrik enerjisine dönüştüren bir teknoloji olarak, enerji üretimi içerisindeki payını hızla artırmaktadır. Bu olumlu özelliklerin dışında, PV modüllerde meydana gelen yüzeysel ve içsel kusurlar, enerji verimliliği ve çalışma performansını olumsuz etkileyen unsurlardır. Bu kusurların erken tespit edilmesi bakım onarım maliyetlerinin düşürülmesi ve enerji üretiminde sürekliliğin sağlanması açısından kritik bir öneme sahiptir.

Uzmanların, panellerde oluşan kusurları geleneksel tespit yöntemleri ile denetlemeleri iş gücü maliyetini ve zaman kaybını artırmaktadır. İnsan denetimli olan geleneksel yöntemler, insan faktöründen kaynaklı hata paylarını da beraberinde getirmektedir. Bu gibi sorunların çözümü için otomatik ve yüksek doğruluklu yöntemlerin geliştirilmesine yönelik araştırmalar artmaktadır (Masita vd., 2025). Yüksek performans gösteren derin öğrenme tabanlı yaklaşımlar, görüntü işleme ile kusur tespiti ve sınıflandırma işlemlerinde yaygın olarak kullanılmaktadır (Masita vd., 2025).

İnsan gözünün tespit edemediği mikro çatlaklar, kısa devreler ve hücresel bozulmalar gibi kusurlar, elektrolüminesans (EL) görüntüleme gibi ileri tekniklerle tespit edilebilmektedir. EL görüntüleme, PV hücrelere verilen elektriksel uyarılar sayesinde meydana gelen zayıf ışığın gözlemlenmesi ilkesine dayanır ve bu sayede bir çok kusur tespit edilebilir (Masita vd., 2025; Pierdicca vd., 2020). Ancak EL görüntüler, kişi tecrübesine bağlı olarak analiz edildiği için hem iş yükü ve zaman kaybı hem de uzman yorumu gerektirdiği için büyük ölçekli sistemlerde sınırlı kalmaktadır (Pierdicca vd., 2020).

Bu bağlamda, derin öğrenme tabanlı yöntemler EL görüntülerinde kusur tespiti ve sınıflandırma süreçlerini insan müdahalesine gerek kalmadan, yüksek doğruluk ve hız ile gerçekleştirebilen güçlü yaklaşımlar olarak öne çıkmaktadır (Pierdicca vd., 2020). Wang ve arkadaşları tarafından geliştirilen model, EL görüntülerinden otomatik kusur tespiti yaparak literatürde dikkat çekici doğruluk oranları elde etmiştir (Wang vd., 2023). Ayrıca son çalışmalar hem EL hem de görünür ve kızılötesi görüntüleri birlikte kullanarak PV modüllerindeki farklı kusur türlerini tanımlamakta ve derin öğrenme tabanlı modeller aracılığıyla yüksek doğruluk oranları elde etmektedir (Lai vd., 2025). Bu bulgular, derin öğrenme yöntemlerinin PV endüstrisinde ölçeklenebilir ve otomatik kalite kontrol sistemlerinin geliştirilmesinde önemli bir potansiyele sahip olduğunu göstermektedir.

Bu tez çalışmasında, derin öğrenme tabanlı yöntemler kullanılarak elektrolüminesans (EL) görüntülerinde PV hücre kusurlarının otomatik sınıflandırılması amaçlanmaktadır. Çalışmada, EL görüntülerinin işlenmesi, ön işleme ve eğitim süreçleri aracılığıyla derin öğrenme modellerinin öğrenme yetenekleri değerlendirilecek, sınıflandırma performansı ölçülecek ve mevcut literatüre göre karşılaştırmalı analizler yapılacaktır. Bu sayede hem akademik literatüre hem de pratik uygulama alanına katkı sağlanması hedeflenmektedir.

### **1.1. Çalışmanın Amacı ve Kapsamı**

Bu tez çalışmasının temel amacı, fotovoltaik (PV) hücrelerde meydana gelen kusurların elektrolüminesans (EL) görüntüleri üzerinden derin öğrenme tabanlı yöntemler kullanılarak otomatik olarak sınıflandırılmasıdır.

Geleneksel görüntü işleme yöntemleri çoğunlukla manuel özellik çıkarımına dayanmakta olup karmaşık ve düşük kontrastlı EL görüntülerinde sınırlı performans gösterebilmektedir. Bu nedenle çalışmada, evrimsel sinir ağları (CNN) başta olmak üzere derin öğrenme mimarileri kullanılarak otomatik özellik öğrenimi gerçekleştirilmesi planlanmaktadır. Model performansı doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1-skoru ve karmaşıklık matrisi gibi metriklerle değerlendirilecektir.

Çalışma kapsamında;

- EL görüntü veri setinin hazırlanması ve ön işleme adımlarının gerçekleştirilmesi,
- Veri artırma (augmentation) tekniklerinin uygulanması,
- Farklı derin öğrenme mimarilerinin karşılaştırılması,
- Transfer öğrenme ve ince ayar (fine-tuning) stratejilerinin değerlendirilmesi,
- Model performanslarının literatürde raporlanan çalışmalar ile karşılaştırılması amaçlanmaktadır.

Tez çalışmasının kapsamı, PV hücre kusurlarının yalnızca EL görüntüleri üzerinden sınıflandırılması ile sınırlandırılmıştır. Termal görüntüleme, drone tabanlı saha analizi veya gerçek zamanlı gömülü sistem uygulamaları bu çalışmanın kapsamı dışında bırakılmıştır. Çalışma, geliştirilen modelin doğruluk ve genellenebilirlik performansının deneysel olarak değerlendirilmesine odaklanmaktadır.

Bu doğrultuda tez hem akademik literatüre katkı sunmayı hem de büyük ölçekli güneş enerji sistemlerinde otomatik kalite kontrol süreçlerine temel oluşturabilecek bir yaklaşım geliştirmeyi hedeflemektedir.

## 2. KAYNAK ÖZETLERİ

### 2.1. Güneş Paneli Sınıflandırma Çalışmaları

Akademik yazında fotovoltaik modüllerin sınıflandırılması temel olarak iki ana problem etrafında şekillenmektedir. Bunlar sağlam/arızalı panel ayrımı ve kusur türlerine göre çok kategorili sınıflandırmadır (Masita vd., 2025). İncelenen derleme çalışmasında, ilk dönem araştırmalarda geleneksel görüntü işleme tekniklerinden (eşikleme, kenar belirleme, morfolojik işlemler) yararlanıldığı ifade edilmektedir. Bununla birlikte, bu yöntemlerin ışık koşullarındaki değişimlere duyarlı olma, gürültüden etkilenme ve karmaşık arka planlarda başarımların düşüklüğü gibi kısıtları bulunduğu vurgulanmaktadır (Masita vd., 2025). Derin öğrenme tekniklerinin gelişimiyle birlikte, özellikle evrişimli sinir ağı (CNN) mimarilerinin panel sınıflandırma problemlerinde yüksek doğruluk düzeylerine eriştiği rapor edilmiştir. Ele alınan araştırmalarda, ikili sınıflandırma görevlerinde %90'ın üzerinde doğruluk, çok sınıflı kusur tespitinde ise yüksek F1-skor değerleri elde edildiği belirtilmektedir (Masita vd., 2025). Bunlara ek olarak, transfer öğrenme yönteminin sınırlı veri setleriyle çalışıldığı durumlarda model performansını belirgin şekilde artırdığı ifade edilmiştir (Masita vd., 2025).

Lai ve arkadaşları fotovoltaik modüllerin sınıflandırılması üzerine yaptıkları araştırmalarda, çoğunlukla panellerin sağlam (healthy) ve arızalı (defective) biçiminde iki kategoriye ayrılması temeline dayandığını belirtmiştir. Ele alınan çalışmada, kızılötesi (IR), elektrolüminesans (EL) ve RGB görüntüler ayrı ayrı işlenerek her bir görüntü tipi için sınıflandırma başarımları değerlendirilmiştir (Lai vd., 2025). Araştırmada derin öğrenme tabanlı CNN mimarisi kullanılarak paneller, farklı kusur kategorileri doğrultusunda sınıflandırılmıştır. Bu yöntem, elle öznitelik çıkarımı gerektirmeksizin ayırt edici özelliklerin otomatik olarak öğrenilmesine imkân tanımıştır. Elde edilen bulgular, özellikle EL görüntülerinin mikro düzeydeki yapısal bozuklukların sınıflandırılmasında daha yüksek başarı gösterdiğini ortaya koymaktadır (Lai vd., 2025). Bu sonuç, görüntü türünün sınıflandırma performansı üzerinde doğrudan belirleyici olduğunu göstermekte ve birden

fazla görüntüleme tekniğinin bir arada kullanılmasının gerekliliğine dikkat çekmektedir (Lai vd., 2025).

Ele alınan başka bir araştırmada, hücre düzeyinde kaydedilen Elektrolüminesans (EL) görüntüleri kullanılarak panel hücreleri arıza durumuna göre etiketlenmiştir (Pierdicca vd., 2020). Geliştirilen Derin Evrişimli Sinir Ağı (DCNN) modeli, el ile öznetelik çıkarma gerektirmeden doğrudan ham görüntülerden ayırt edici öznetelikleri öğrenmektedir. Bu yaklaşım, klasik kenar belirleme, eşikleme ya da morfolojik işlemler gibi yöntemlere kıyasla daha başarılı bir doğruluk düzeyi elde etmiştir (Pierdicca vd., 2020). Çalışma, özellikle mikro çatlak ve hücre içi bozulmalar gibi insan gözüyle fark edilmesi güç hataların sınıflandırılmasında derin öğrenmenin ne denli etkili olduğunu göstermektedir. Bu bulgu, panel sınıflandırma alanında CNN tabanlı modellerin güçlü bir seçenek hâline geldiğini ortaya koymaktadır (Pierdicca vd., 2020).

Wang ve arkadaşları tarafından yürütülen çalışmada, elektrolüminesans (EL) görüntüler kullanılarak hücreler sınıflandırılmış ve arızalı hücrelerin otomatik tespiti amaçlanmıştır. Araştırmada hücreler, temelde sağlam (normal) ve arızalı (defective) olmak üzere iki kategoriye ayrılmıştır (Wang vd., 2023). Bu sınıflandırma biçimi, üretim bandı kalite denetim süreçlerinde hızlı karar almayı kolaylaştıracak niteliktedir (Wang vd., 2023). Geleneksel sınıflandırma yaklaşımlarında uzman görüşüne dayalı manuel denetim gerekliyken, Wang ve arkadaşlarının geliştirdiği evrişimli sinir ağı (CNN) tabanlı model sayesinde insan faktörü en aza indirilmiştir. Model eğitiminde, EL görüntülerden oluşan veri kümesi eğitim ve test kümelerine bölünmüş, sınıflandırma başarımı doğruluk (accuracy) ölçütüyle değerlendirilmiştir (Wang vd., 2023). Elde edilen yüksek doğruluk değerleri, derin öğrenme tekniklerinin güneş paneli sınıflandırma problemlerinde başarıyla uygulanabileceğini ortaya koymaktadır (Wang vd., 2023).

Fotovoltaik modüllerin sınıflandırılmasına yönelik ilgili başka bir çalışmada, paneller termal davranışları temel alınarak normal ve arızalı biçiminde iki kategoriye ayrılmıştır (Akram vd., 2020). Kızılötesi (IR) görüntülerden elde edilen sıcaklık dağılımı verileri analiz edilerek modüller arasında ayırım yapılmış ve bu yaklaşımda sıcaklık farklılıkları temel ayırt edici özellik olarak kullanılmıştır (Akram vd., 2020). Sınıflandırma sürecinde termal yoğunluk farkları, bölgesel sıcaklık değişimleri ve anormal ısınma bölgeleri gibi

parametreler özellik çıkarımı aşamasında değerlendirilerek panel bazında otomatik karar mekanizması oluşturulmuştur (Akram vd., 2020).

İlgili bir araştırmada, fotovoltaik panellerin görüntü içerisindeki farklı nesnelerden ayrıştırılarak tespiti gerçekleştirilmiştir (Diaz vd., 2020). Bu kapsamda panel yüzeyleri; bina çatıları, asfalt zemin, toprak alanlar ve bitki örtüsü gibi çeşitli arka plan öğelerinden ayırt edilmiştir (Diaz vd., 2020). Model, panel bölgelerini nesne tanıma yöntemiyle sınıflandırmakta ve konum bilgisiyle birlikte belirlemektedir (Diaz vd., 2020). Bu yönüyle çalışma, yalnızca panel varlığı/yokluğu analizine odaklanmayıp aynı zamanda panelin görüntü içerisindeki konumunun tespitine de önem vermektedir (Diaz vd., 2020). Böylece geniş ölçekli alanlarda modüllerin konum haritasının çıkarılması olanaklı hâle gelmektedir (Diaz vd., 2020).

Fotovoltaik modüller, kullanılan hücre teknolojileri temel alınarak farklı kategorilere ayrılmaktadır. Bu kategoriler arasında kristal silikon tabanlı hücreler (monokristal ve polikristal), ince film teknolojileri (CdTe, CIGS, amorf silikon), yeni nesil yüksek verimli yapılar (PERC, TOPCon, HJT) ile perovskit ve tandem hücreler gibi yenilikçi türler bulunmaktadır (Singh vd., 2021). Söz konusu ayırım, panellerin verimlilik, maliyet, dayanıklılık ve üretim süreçleri açısından karşılaştırılmasına olanak sağlamakta; böylece performans farklılıklarının arkasındaki malzeme ve yapısal özellikler daha net biçimde ortaya konulmaktadır (Singh vd., 2021).

Jaffery ve arkadaşlarının yaptığı araştırmada fotovoltaik modüller, çalışma koşullarına bağlı olarak farklı kategorilere ayrılmaktadır. Geliştirilen sistem; normal işleyiş, kısmi gölgelenme, açık devre, kısa devre ve benzeri elektriksel arıza durumlarını birbirinden ayırt edebilecek biçimde tasarlanmıştır (Jaffery vd., 2017). Sınıflandırma işlemi, panelin gerilim, akım ve güç gibi elektriksel büyüklükleri temel alınarak gerçekleştirilmektedir (Jaffery vd., 2017). Bu yöntem, modüllerin yalnızca fiziksel özelliklerine göre değil, aynı zamanda performans davranışlarına göre de gruplandırılmasına imkân tanımaktadır (Jaffery vd., 2017).

Yapılan bir tez çalışması kapsamında fotovoltaik paneller, işletme koşullarına ve arıza tiplerine göre kategorize edilmiştir. Normal işleyiş ile arızalı durumlar karşılaştırılmış;

özellikle gölgeleme etkisi, hücre hasarları ve bağlantı sorunları gibi durumlar farklı başlıklar altında ele alınmıştır. Modüllerin performansı, gerilim, akım ve güç parametreleri üzerinden değerlendirilmiş ve bu büyüklükler yardımıyla paneller arasında ayırım yapılmıştır. Bu şekilde, performans temelli düzenli bir sınıflandırma yöntemi oluşturulmuştur (Dişli, 2018).

Pathak ve arkadaşları tarafından gerçekleştirilen bir çalışmada, güneş panellerinde sıkça rastlanan aşırı ısınma (hotspot) problemlerinin tespiti ve arıza türlerine göre sınıflandırılması ele alınmıştır. Araştırmada, termal kameralar aracılığıyla elde edilen görüntüler üzerinden panel yüzeyindeki sıcaklık farklılıkları incelenmiş ve anormal bölgeler belirlenmiştir. Toplanan termal veriler, derin öğrenme mimarileri ile işlenerek farklı arıza tiplerinin yüksek doğrulukla ayırt edilebildiği gözlemlenmiştir. Bu yaklaşım, geleneksel insan kaynaklı denetim yöntemlerine kıyasla hem hız hem de güvenilirlik açısından önemli avantajlar sunmaktadır (Pathak vd., 2022).

Dokur ve Koç, güneş panellerinin durum izleme ve sınıflandırma konusunda gerçekleştirilen araştırmaların, ağırlıklı olarak panellerin işlevsel ya da arızalı şeklinde kategorize edilmesi veya arıza türlerinin ayırt edilmesi üzerine yoğunlaştığından bahsetmiştir. Bu çalışmalarda sınıflandırma süreci, panel görüntülerinden çıkarılan çeşitli öznitelikler yardımıyla yürütülmektedir. Görüntü işleme yöntemleri aracılığıyla hücre yapılarının incelenmesi ve anormal bölgelerin saptanmasına yönelik birçok yaklaşım geliştirilmiştir. Bu teknikler sayesinde yüzeylerdeki çatlaklar, hücre hasarları veya üretim kaynaklı kusurlar başarıyla sınıflandırılabilir (Dokur ve Koç, 2019).

## 2.2. Görüntü Tabanlı Kusur Tespiti Çalışmaları

Literatürdeki bir derleme, görüntü tabanlı kusur tespiti yöntemlerini kullanılan görüntüleme tekniklerine göre üç ana başlık altında sınıflandırmaktadır (Masita vd., 2025).

**Elektrolüminesans (EL) Görüntüleme:** Bu teknikle mikro çatlaklar, hücre kırıkları, busbar kopmaları ve potansiyel kaynaklı bozulma (PID) etkileri gibi kusurlar incelenmektedir. EL görüntülemenin, hücre düzeyindeki mikro boyutlu arızaları yüksek

duyarlılıkla saptayabildiği ifade edilmekle birlikte, laboratuvar koşullarına ihtiyaç duyması önemli bir kısıt olarak değerlendirilmiştir (Masita vd., 2025).

**Termal (Infrared- IR) Görüntüleme:** Bu kategoride sıcak noktalar (hotspot), bağlantı arızaları ve aşırı ısınma sorunları ele alınmaktadır. IR görüntüleme yönteminin, özellikle saha çalışmalarında ve drone tabanlı sistemlerde yaygın biçimde tercih edildiği belirtilmiştir (Masita vd., 2025).

**RGB (Görünür Işık) Görüntüleme:** Yüzey çatlakları, kirlenme ve cam hasarları gibi problemler bu yöntemle tespit edilmektedir (Masita vd., 2025). Derlemede, derin öğrenme modellerinin özellikle EL ve IR görüntüler üzerinde geleneksel yöntemlere kıyasla daha yüksek hassasiyet sağladığı vurgulanmaktadır. Ayrıca nesne tespiti (object detection) ve anlamsal bölütleme (semantic segmentation) yaklaşımlarının, kusurların konumlandırılmasında kayda değer avantajlar sunduğu ifade edilmiştir (Masita vd., 2025).

Görüntü tabanlı kusur tespit sistemlerinin temel hedefi, fotovoltaik panellerin yüzeyinde ya da hücre yapısında meydana gelen düzensizliklerin otomatik olarak saptanmasıdır. Söz konusu araştırmada üç ayrı görüntüleme yöntemi ele alınmıştır (Lai vd., 2025):

- Elektrolüminesans (EL) görüntüler: Mikro çatlaklar ve hücre içi hasarların incelenmesi,
- Termal (IR) görüntüler: Sıcak noktalar (hotspot) ve ısı anormalliklerin belirlenmesi,
- RGB görüntüler: Yüzey kırıkları ve fiziksel hasarların tespiti.

Elde edilen bulgular, IR görüntülerin özellikle sıcak nokta tespitinde yüksek başarı gösterdiğini, buna karşılık EL görüntülerin hücre içi yapısal bozuklukların saptanmasında daha etkili olduğunu ortaya koymaktadır (Lai vd., 2025). Ayrıca çalışma kapsamında veri çoğaltma (data augmentation) teknikleri uygulanarak modelin genelleme yeteneği geliştirilmiştir. Bu sayede farklı aydınlatma koşulları ve görüntü çeşitliliklerine karşı daha dayanıklı bir sistem oluşturulmuştur (Lai vd., 2025).

### 2.3. Derin Öğrenme ve Güncel Yaklaşımlar

Fotovoltaik modüllerdeki arızaların saptanmasında kullanılan derin öğrenme mimarileri üç temel başlık altında değerlendirilebilir (Masita vd., 2025).

**Sınıflandırma Tabanlı Modeller:** CNN, VGG, ResNet ve Inception gibi mimariler bu grupta yer almaktadır. Bu modeller çoğunlukla panelleri sağlam ya da arızalı olarak etiketleme işlevi görmektedir (Masita vd., 2025).

**Nesne Tespiti Modelleri:** YOLO ve Faster R-CNN gibi algoritmalar bu kategoride incelenmektedir. Bu yaklaşımlar, hatalı bölgelerin konumlarını sınırlayıcı kutular (bounding box) aracılığıyla belirlemektedir (Masita vd., 2025).

**Segmentasyon Modelleri:** U-Net ve Tam Evrişimli Ağlar (FCN) bu grupta ele alınmaktadır. Segmentasyon modelleri, kusurları piksel düzeyinde ayırarak daha incelikli bir analiz olanağı sunmaktadır. Özellikle mikro çatlak gibi küçük ölçekli yapısal bozuklukların tespitinde bu yöntemlerin daha başarılı olduğu ifade edilmektedir (Masita vd., 2025).

Günümüzde fotovoltaik panel kusur tespitinde en sık başvurulan yaklaşım, evrişimli sinir ağı (CNN) temelli derin öğrenme modelleridir. İncelenen araştırmada da uçtan uca (end-to-end) öğrenme stratejisi benimsenmiş, elle öznitelik çıkarma yerine otomatik öznitelik öğrenimi tercih edilmiştir (Lai vd., 2025).

Model mimarisi temel olarak şu bileşenlerden oluşmaktadır (Lai vd., 2025):

- Evrişim katmanları ile öznitelik çıkarımı,
- Aktivasyon ve havuzlama (pooling) katmanları,
- Tam bağlantılı (fully connected) katmanlar,
- Softmax sınıflandırıcı.

Elde edilen bulgular, derin öğrenme tabanlı sistemlerin klasik eşikleme ve morfolojik işlemlerle çalışan yöntemlere oranla daha yüksek doğruluk sağladığını ortaya koymaktadır

(Lai vd., 2025). Çalışma ayrıca, farklı görüntü türlerinin bir arada değerlendirilmesinin ilerleyen dönemlerde hibrit sistemlerin geliştirilmesine olanak tanıdığını belirtmektedir. Bu yaklaşım, özellikle gerçek saha koşullarında daha güvenilir ve anlık kusur tespiti açısından önemli bir potansiyel barındırmaktadır (Lai vd., 2025).

## 2.4. Tezin Organizasyonu

Bu tez çalışması, fotovoltaik (PV) panel hücrelerinde ortaya çıkan kusurların, elektrolüminesans (EL) görüntüleme tekniği ile elde edilen veriler üzerinden derin öğrenme algoritmaları kullanılarak otomatik bir biçimde teşhis edilmesini hedeflemektedir. Güneş enerjisi sistemlerinin dünya çapında hızla yaygınlaşması, PV panellerin yüksek verimlilik ve güvenilirlikte çalışmasını zorunlu kılmaktadır. Bu bağlamda, panel hücrelerinde meydana gelebilecek kusurların erken safhada saptanması, sistem performansının sürdürülebilirliği ve bakım giderlerinin düşürülmesi açısından kritik bir rol oynamaktadır. Bu doğrultuda hazırlanan tez, her biri belirli bir amaca hizmet eden altı ana bölümden oluşmaktadır.

Tezin birinci bölümünde, araştırmanın amacı, kapsamı ve çalışmanın temel motivasyonu ortaya konulmuştur. Bu bölümde ayrıca, konuyla ilgili akademik yazın taranarak güneş paneli sınıflandırma çalışmaları, görüntü tabanlı kusur tespit yöntemleri ve derin öğrenme temelli güncel yaklaşımlar hakkında kapsamlı bir değerlendirme sunulmuştur. Bunun yanı sıra, gerçekleştirilen bu çalışmanın literatüre sağlayacağı katkılar açıklanmış ve tezin genel yapısı hakkında bilgi verilmiştir.

Tezin ikinci bölümünde, güneş enerjisi panel sistemlerine ilişkin temel bilgiler sunulmuştur. Bu kapsamda öncelikle dünyada ve Türkiye'de güneş enerjisinin kullanım durumu ve tarihsel gelişimi ele alınmıştır. Ardından fotovoltaik panel teknolojisinin çalışma prensipleri açıklanmış ve panellerin yapısal özellikleri detaylandırılmıştır. Bu bölümde ayrıca farklı güneş paneli türleri tanıtılmış, panel tasarımında verimliliği etkileyen faktörler irdelenmiştir. Bunun yanında, PV panellerde sıklıkla karşılaşılan kusur türleri olan mikro çatlaklar, hücre kırıkları, busbar kopmaları, potansiyel kaynaklı bozunma (PID) etkileri ve delaminasyon gibi problemler ayrıntılı olarak açıklanmıştır. Son olarak, bu

kusurların tespitinde yaygın olarak kullanılan elektrolüminesans görüntüleme yöntemi hakkında bilgiler verilmiştir.

Tezin üçüncü bölümünde, derin öğrenme yöntemleri ve model performansının değerlendirilmesinde kullanılan başarımlar metrikleri ele alınmıştır. Bu bölümde öncelikle derin öğrenme kavramı ve görüntü işleme alanındaki uygulamaları açıklanmış, özellikle evrimsel sinir ağlarının (Convolutional Neural Networks- CNN) çalışma prensipleri üzerinde durulmuştur. Ayrıca sınıflandırma problemlerinde kullanılan doğruluk, kesinlik, duyarlılık ve F1 skoru gibi performans değerlendirme ölçütleri tanıtılmıştır.

Tezin dördüncü bölümünde, çalışmanın materyal ve metot kısmı ayrıntılı olarak sunulmuştur. Bu bölümde araştırmada kullanılan veri setinin özellikleri ve hazırlanma süreci açıklanmıştır. Ayrıca elektrolüminesans görüntülerinin analizine yönelik veri hazırlama aşamaları, hücre segmentasyonu işlemleri ve görüntü ön işleme yöntemleri ele alınmıştır. Bunun yanı sıra, veri setinin genişletilmesi amacıyla uygulanan veri artırma teknikleri tanıtılmış ve çalışmada kullanılan derin öğrenme modelinin mimarisi detaylandırılmıştır. Son olarak, modelin eğitim süreci, veri setinin eğitim, doğrulama ve test gruplarına ayrılması gibi aşamalar kapsamlı biçimde açıklanmıştır.


Tezin beşinci bölümünde, gerçekleştirilen deneysel çalışmalar neticesinde elde edilen bulgular sunulmuştur. Bu bölümde geliştirilen modelin performansı çeşitli değerlendirme metrikleri kullanılarak analiz edilmiş ve sonuçlar grafikler ile tablolar yardımıyla görselleştirilmiştir. Ayrıca elde edilen sonuçlar, literatürde yer alan benzer çalışmalarla karşılaştırılarak modelin başarımlar düzeyi değerlendirilmiştir.

Tezin altıncı ve son bölümünde ise çalışma kapsamında elde edilen sonuçların genel bir değerlendirmesi yapılmıştır. Bu bölümde araştırmanın bulguları tartışılmış, çalışmanın literatüre sağladığı katkılar ortaya konulmuştur. Ayrıca araştırmanın sınırlılıkları belirtilmiş ve gelecekte bu alanda yapılabilecek çalışmalar için öneriler sunulmuştur.

### 3. GÜNEŞ ENERJİSİ PANEL SİSTEMLERİ

#### 3.1. Dünyada ve Türkiye’de Güneş Enerjisi Kullanımı

Dünya genelinde enerji talebinin hızla artması ve fosil yakıtların çevresel etkilerinin belirginleşmesi, yenilenebilir enerji kaynaklarına yönelimi güçlendirmiştir. Bu kaynaklar arasında güneş enerjisi; çevre dostu, sürdürülebilir ve geniş ölçekte uygulanabilir olması sayesinde en hızlı büyüyen elektrik üretim teknolojilerinden biri konumuna gelmiştir. Maliyetlerdeki düşüş ve yenilenebilir enerjiyi destekleyen politikalar, güneş enerjisinin küresel yayılımını hızlandırmıştır.




Şekil 3.1. Küresel güneş enerjisi kurulum verileri (2024) (IEA PVPS, 2025)

Uluslararası Enerji Ajansı'nın (IEA) fotovoltaiik programı verilerine göre 2024 yılında güneş enerjisi kurulumlarında Çin, 309–357 GW aralığındaki kapasitesiyle açık ara lider konumdadır; bunu 63 GW ile Avrupa Birliği ve 47 GW ile Amerika Birleşik Devletleri izlemektedir (Şekil 3.1) (IEA PVPS, 2025).


Bugüne kadar devreye alınmış toplam kurulu gücün bölgesel dağılımı incelendiğinde, kapasitenin önemli bir bölümünün Çin, Avrupa ve Asya-Pasifik bölgesinde yoğunlaştığı; Afrika, Orta Doğu ve dünyanın geri kalanının ise henüz düşük paya sahip olduğu

görülmektedir. Bu durum, güneş enerjisi yatırımlarının coğrafi olarak belirli merkezlerde toplandığını göstermektedir (IEA PVPS, 2025).




Şekil 3.2. Kişi Başına Düşen PV Kapasitesi (IEA PVPS, 2025)

Kurulu güç nüfusa oranlandığında farklı bir sıralama ortaya çıkmaktadır. 2024 yılı itibarıyla kişi başına düşen PV kapasitesinde 1547 W ile Hollanda ilk sırada yer alırken, onu 1448 W ile Avustralya ve 1198 W ile Almanya izlemektedir (Şekil 3.2). Bu veriler, bir ülkenin güneş enerjisindeki gelişmişliğinin yalnızca toplam kurulu güçle değil, nüfusa oranlı kapasiteyle de değerlendirilmesi gerektiğini ortaya koymaktadır (IEA PVPS, 2025).



Şekil 3.3. En Yüksek PV Nüfuzuna Sahip Ülkeler (IEA PVPS, 2025)


Güneş enerjisinin elektrik sistemine entegrasyon yoğunluğu açısından değerlendirildiğinde, bazı ülkeler dikkat çekici seviyelere ulaşmıştır. "PV nüfuz oranı" olarak adlandırılan bu metrik, genellikle güneş enerjisinin toplam elektrik talebini karşılama oranını veya belirli bir ölçütteki yoğunluğunu ifade etmektedir (Şekil 3.3). Bu kategoride Yunanistan 44.0 GW değeriyle ilk sırada yer alırken, onu 41.5 GW ile Hollanda takip etmektedir. İspanya (21.6 GW), Macaristan (20.6 GW) ve Şili (19.9 GW) da ilk beşte yer alan diğer ülkelerdir. Listede Avustralya, Almanya, İsrail, Malta, Estonya, Litvanya, Güney Kıbrıs ve Polonya gibi farklı coğrafyalardan ülkeler bulunmaktadır. Bu çeşitlilik, yüksek PV entegrasyonunun belirli bir iklim veya coğrafyaya özgü olmadığını, farklı bölgelerdeki ülkelerin uygun politikalarla bu yoğunluğa ulaşabildiğini göstermektedir (IEA PVPS, 2025).



Şekil 3.4. Yıllık PV Kurulumlarının Gelişimi (IEA PVPS, 2025)

Yıllık kurulum rakamları, 2010 sonrasında ivme kazanmış ve son yıllarda belirgin bir sıçrama göstermiştir; bu büyümede en büyük pay Çin'e aittir (Şekil 3.4) (IEA PVPS, 2025). SolarPower Europe verilerine göre 2024 yılında dünya genelinde yaklaşık 597 GW yeni kapasite kurulmuş ve toplam kurulu güç 2 TW sınırını aşmıştır; projeksiyonlar 2030 yılına kadar yıllık kurulumların 1 TW seviyesine ulaşabileceğini öngörmektedir (SolarPower Europe, 2025).

Türkiye, yaklaşık 2700 saatlik yıllık güneşlenme süresi ve 1500 kWh/m<sup>2</sup> düzeyindeki ortalama güneş radyasyonu ile güneş enerjisi potansiyeli yüksek ülkeler arasında yer almaktadır. Son dönemde uygulanan yatırım teşvikleri sayesinde santral sayısı ve kurulu güç hızla artmış, ülke küresel ölçekte güneş enerjisinin en hızlı arttığı pazarlardan biri hâline gelmiştir (SolarPower Europe, 2025).



Şekil 3.5. 2025-2029 yılları arasında güneş enerjisi panellerine yapılacak eklemelerde ilk 10 Pazar (SolarPower Europe, 2025)


2025–2029 dönemine ilişkin beş yıllık değerlendirmede Türkiye'nin kurulum potansiyeli düşük senaryoda 34 GW, orta senaryoda 45 GW ve yüksek senaryoda 49 GW olarak öngörülmektedir (Şekil 3.5). En gerçekçi öngörü olan orta senaryoda Türkiye, 45 GW'lık potansiyeliyle küresel sıralamada altıncı sıraya yükselmesi beklenmektedir (SolarPower Europe, 2025).

Sonuç olarak hem dünya genelinde hem de Türkiye özelinde güneş enerjisi kullanımının hızla yaygınlaştığı görülmektedir. Bu yaygınlaşma, fotovoltaik panellerin performansının

izlenmesini ve olası kusurların erken aşamada teşhis edilmesini amaçlayan bilimsel çalışmaların önemini artırmaktadır.

### 3.2. Güneş Paneli Teknolojisinin Temelleri

Güneş kaynaklı enerji, son yirmi yılda yenilenebilir enerji türleri arasında en yüksek büyüme hızını gösteren alanlardan biri konumuna gelmiştir. Küresel ölçekte kurulu güç verileri, fotovoltaik teknolojinin elektrik üretimindeki ağırlığını giderek artırdığını ortaya koymaktadır (Green, 2019). Fotovoltaik sistemlerin çalışma prensibi, yarı iletken malzemeler aracılığıyla güneş ışınımının doğrudan elektrik enerjisine çevrilmesine dayanır. Bu fiziksel süreç, literatürde fotovoltaik etki olarak tanımlanmaktadır.



Şekil 3.6. Birincil Fotovoltaik etki ile güneş enerjisinin elektrik enerjisine dönüşüm mekanizması.

Güneş ışığının elektrik enerjisine dönüştürülmesi olarak tanımlanan fotovoltaik olayın bilimsel temelleri, ilk kez 1839 yılında Fransız fizikçi Alexandre Edmond Becquerel tarafından ortaya konmuştur. Bununla birlikte, bu ilkenin enerji üretimine yönelik pratik sistemlere dönüşmesi ancak 1900’lü yılların ikinci yarısında gerçekleşebilmiştir. Günümüz fotovoltaik pazarında, toplam üretim kapasitesinin büyük bölümü silikon esaslı yarı iletken malzemelerden oluşan hücreler tarafından karşılanmaktadır. Şekil 3.6 ‘de görüldüğü üzere bu tür hücrelerde, güneşten gelen fotonların yarı iletken madde tarafından soğurulması sonucunda elektron ve boşluk adı verilen yük taşıyıcı çiftleri oluşmakta; bu taşıyıcıların devre içinde hareket etmesiyle elektrik akımı elde edilmektedir (Sharma ve Mishra, 2025; Singh vd., 2021).



Şekil 3.7. PV sistemlerin hücre, modül ve dizi yapısındaki hiyerarşik bileşimi

Fotovoltaik sistemlerin yapısı, en küçük birimden en büyük ölçeğe doğru hücre, modül ve dizi olmak üzere üç temel bileşenden oluşur (Şekil 3.7). Tek bir güneş hücresinin ürettiği elektriksel güç, doğrudan kullanım için yetersiz düzeyde olduğundan, çok sayıda hücre birbirine seri ya da paralel bağlanarak modüller haline getirilir (Razykov vd., 2011; URL-3, 2026). Daha yüksek kapasiteli sistemler elde edilmesi gerektiğinde ise bu modüller bir araya getirilerek dizi yapıları oluşturulur (URL-3, 2026). Fotovoltaik teknolojilerdeki ilerleme, büyük ölçüde yarı iletken malzeme biliminde kaydedilen gelişmelere dayanmaktadır (Razykov vd., 2011). Günümüzde ticari pazarda öne çıkan başlıca teknolojiler, monokristal silikon, polikristal silikon ve ince film yapılarıdır. Monokristal tabanlı paneller, sahip oldukları yüksek dönüşüm verimliliği nedeniyle yaygın bir kullanım alanı bulurken; polikristal paneller, daha düşük imalat maliyetleriyle öne çıkmakta ve pek çok projede tercih edilmektedir. İnce film paneller ise esnek yapıları ve nispeten düşük üretim maliyetleri sayesinde özellikle belirli uygulama alanlarında kullanılmaktadır (Razykov vd., 2011).

Fotovoltaik sistemlerin enerji dönüşüm verimliliği, çeşitli iç ve dış etkenlere bağlı olarak değişim göstermektedir. Bu etkenler arasında panelin çalışma sıcaklığı, güneş ışınımının şiddeti, gölgelenme koşulları ve panel yüzeyinde bulunan fiziksel bozulmalar yer almaktadır. Özellikle gölgelenme ve ışınım düzeyindeki değişimler, sistemin genel performansında belirgin kayıplara yol açabilmektedir (Pradhan vd., 2024). Bunun yanı sıra, güneş hücrelerinde oluşan mikro düzeydeki çatlaklar, kırılmalar veya bağlantı noktalarındaki hatalar da üretilen enerji miktarını olumsuz yönde etkilemektedir.

Literatürdeki bulgular, özellikle büyük boyutlu çatlakların panel güç çıkışında önemli oranda azalmaya neden olduğunu ortaya koymaktadır (Dhimish ve Hu, 2022). Ayrıca çevresel koşullar ve yüzeyde meydana gelen kusurlar, fotovoltaik modüllerin uzun dönemli işletim güvenilirliğini ve performans sürekliliğini doğrudan etkilemektedir (Sharma ve Mishra, 2025). Bu sebeplerle, güneş panellerinin çalışma durumunun belirli aralıklarla izlenmesi ve olası hataların henüz başlangıç aşamasındayken tespit edilmesi büyük önem taşımaktadır (Le ve Nguyen, 2025).

Fotovoltaik alanındaki araştırma ve geliştirme faaliyetleri, daha yüksek dönüşüm verimliliğine sahip ve daha düşük üretim maliyetli sistemler oluşturma amacı taşımaktadır. Bu amaçla, özgün hücre mimarileri tasarlanmakta, ileri üretim teknolojileri uygulanmakta ve akıllı izleme sistemleri entegre edilerek fotovoltaik tesislerin performansı iyileştirilmektedir.

### **3.3. Güneş Paneli Çeşitleri**

Fotovoltaik (PV) teknolojiler, güneş ışığını doğrudan elektrik enerjisine dönüştüren yarı iletken tabanlı sistemlerdir. Bu sistemler, temel olarak fotovoltaik hücrelerden oluşmakta olup, bu hücrelerin bir araya getirilmesiyle modüller ve paneller oluşturulmaktadır. Fotovoltaik teknolojiler, kullanılan yarı iletken malzeme türüne, hücre mimarisine ve üretim yöntemlerine bağlı olarak farklı kategorilere ayrılmaktadır. Bu sınıflandırma; verimlilik, maliyet, üretim süreci, dayanıklılık ve uygulama alanları açısından önemli farklılıklar ortaya koymaktadır (Sayın ve Koç, 2011; URL-3, 2026). Günümüzde güneş paneli teknolojileri genel olarak kristal silikon tabanlı paneller, ince film teknolojileri ve yeni nesil gelişmekte olan teknolojiler olmak üzere çeşitli gruplara ayrılmaktadırlar. Bu teknolojilerin her biri farklı avantaj ve dezavantajlara sahip olup, kullanım alanına göre tercih edilmektedir.

### 3.3.1. Kristal Silikon Tabanlı Fotovoltaik Teknolojiler



Şekil 3.8. Kristal silikon Fotovoltaik hücre örnekleri

Kristal silikon tabanlı fotovoltaik teknolojiler, günümüzde en yaygın kullanılan güneş paneli türünü oluşturmaktadır. Bu paneller, monokristal ve polikristal silikon hücrelerden meydana gelmektedir. Özellikle monokristal silikon hücreler, yüksek kristal saflığı sayesinde daha yüksek verimlilik sunmaktadır. Küresel ölçekte güneş paneli sevkiyatlarının yaklaşık %96'sını monokristal silikon paneller oluşturmakta olup, bu durum teknolojinin baskın konumunu göstermektedir (URL-3, 2026).

Bu panellerde çalışma prensibi, silikon malzemenin güneş ışığını absorbe etmesiyle serbest kalan elektronların hareketi sonucu elektrik akımının oluşmasına dayanmaktadır. Oluşan bu akım, metal kontaklar aracılığıyla toplanarak kullanılabilir elektrik enerjisine dönüştürülmektedir (Sayın ve Koç, 2011; URL-3, 2026).

- Monokristal Silikon Paneller

Monokristal paneller, tek kristal yapıya sahip silisyumdan üretilmektedir. Bu yapı, elektron hareketini kolaylaştırarak daha yüksek verim elde edilmesini sağlar. Bu paneller genellikle koyu siyah renkte olup estetik açıdan da tercih edilmektedir. Yüksek verimlilikleri (%20–22) sayesinde daha az alan kaplayarak daha fazla enerji üretimi sağlamaktadır (URL-3, 2026)


- Polikristal Silikon Paneller

Polikristal paneller, birden fazla kristalin birleşmesiyle oluşan silisyum yapısından üretilmektedir. Üretim süreci daha basit ve maliyet açısından daha avantajlıdır. Ancak kristal yapının düzensiz olması nedeniyle elektron hareketi sınırlanmakta ve bu durum verimliliğin (%15–18) monokristal panellere göre daha düşük olmasına neden olmaktadır (URL-3, 2026).

Kristal silikon panellerin üretim süreci oldukça kapsamlıdır ve temel olarak dört aşamadan oluşmaktadır: hammaddenin elde edilmesi, malzeme işleme, hücre üretimi ve modül montajı. İlk aşamada kuvars, yüksek sıcaklıklarda işlenerek saf silisyuma dönüştürülmektedir. Daha sonra bu silisyum, silindirik ingotlar haline getirilmekte ve ince wafer dilimlerine ayrılmaktadır. Bu waferlar, çeşitli işlemlerden geçirilerek güneş hücrelerine dönüştürülmekte ve son olarak modül haline getirilerek kullanıma hazır hale getirilmektedir (URL-3, 2026).


Kristal silikon teknolojisi, yüksek verimlilik (ticari olarak %20–22), uzun ömür (25 yıl ve üzeri) ve düşük yıllık performans kaybı (<%1) gibi avantajlara sahiptir. Ayrıca PERC, TOPCon ve heterojunction (SHJ) gibi gelişmiş hücre teknolojileri sayesinde verimlilik sürekli olarak artırılmaktadır. Bu özellikler, kristal silikon panelleri günümüzün en güvenilir ve yaygın teknolojisi haline getirmektedir (Sayın ve Koç, 2011; URL-3, 2026).

### 3.3.2. Kadmiyum Tellür (CdTe) Tabanlı Fotovoltaik Teknolojiler



Şekil 3.9. Ultra ince cam üzerine yerleştirilmiş esnek CdTe güneş hücreleri (Mahabaduge ve ark.) (URL-3, 2026)

Kadmiyum tellür (CdTe) tabanlı fotovoltaik teknolojiler, ince film güneş panelleri içerisinde en yaygın kullanılan türlerden biridir. Bu teknoloji, kadmiyum ve tellür elementlerinin birleşiminden oluşan yarı iletken bir malzeme üzerine kuruludur. CdTe paneller, yüksek ışık absorpsiyon kapasitesi sayesinde çok ince katmanlar halinde üretilebilmekte ve bu sayede malzeme kullanımını azaltarak maliyet avantajı sağlamaktadır (URL-3, 2026).




Şekil 3.10. CdTe güneş pilinin yapısı (URL-3, 2026)

CdTe hücrelerin çalışma prensibi, diğer fotovoltaik hücrelere benzer şekilde ışığın absorbe edilmesi sonucu elektronların harekete geçmesi ve elektrik akımının oluşmasına dayanmaktadır (Şekil 3.10). Modern CdTe hücrelerde, ışık absorpsiyonunu artırmak amacıyla kadmiyum selenyum tellür (CdSeTe) gibi ek malzemeler de kullanılmaktadır (URL-3, 2026).

Bu panellerin üretim süreci; hammadde elde edilmesi, hücre üretimi, modül tamamlanması ve kurulum aşamalarını içermektedir. Cd ve Te elementleri genellikle çinko ve bakır madenciliğinin yan ürünleri olarak elde edilmekte olup, bu durum ek madencilik ihtiyacını azaltmaktadır. Üretim sürecinde ince film kaplama teknikleri ve lazer işlemleri kullanılmaktadır (URL-3, 2026).

CdTe teknolojisinin önemli avantajları arasında düşük üretim süresi, düşük karbon emisyonu ve yüksek geri dönüştürülebilirlik oranı (%90'ın üzerinde) yer almaktadır. Ayrıca bu paneller, kristal silikon teknolojisinden sonra en yaygın kullanılan ikinci fotovoltaik teknoloji konumundadır. Bununla birlikte, verimlilik değerleri genellikle %19 civarında olup kristal silikon panellere göre daha düşüktür (Sayın ve Koç, 2011; URL-3, 2026).

### 3.3.3. Bakır İndiyum Galyum Diselenit (CIGS) Tabanlı Fotovoltaik Teknolojiler




Şekil 3.11. Bakır İndiyum Galyum Diselenit (CIGS) güneş pilinin yapısı (URL-3, 2026)

Bakır indiyum galyum diselenit (CIGS) tabanlı fotovoltaik teknolojiler, ince film paneller arasında yüksek verim potansiyeline sahip sistemlerdir. Bu teknoloji,  $\text{Cu}(\text{In}_x\text{Ga}_{1-x})\text{Se}_2$  bileşiğine dayanmaktadır ve bant aralığının ayarlanabilir olması sayesinde güneş ışığının geniş bir spektrumunu absorbe edebilmektedir (URL-3, 2026). CIGS hücreler, doğrudan bant aralığına sahip olmaları nedeniyle yüksek ışık absorpsiyon kapasitesine sahiptir. Laboratuvar ortamında %20'nin üzerinde verim elde edilmiş olsa da ticari modüllerde bu değer genellikle %12–14 aralığında kalmaktadır (URL-3, 2026). Üretim sürecinde eş buharlaştırma (co-evaporation) ve iki aşamalı biriktirme (precursor reaction) gibi yöntemler kullanılmaktadır. Ayrıca molibden (Mo) arka kontak olarak yaygın şekilde kullanılmakta olup, bu yapı hücrenin performansını artırmaktadır (Şekil 3.11). Sodyum (Na) katkısının CIGS performansını iyileştirdiği de yapılan çalışmalarla ortaya konmuştur (URL-3, 2026). CIGS panellerin avantajları arasında yüksek absorpsiyon kapasitesi,

esneklik ve hafiflik yer alırken; üretim süreçlerinin karmaşıklığı ve maliyet faktörleri dezavantaj olarak değerlendirilmektedir (Sayın ve Koç, 2011).


#### 3.3.4. Perovskit Tabanlı Fotovoltaik Teknolojiler



Şekil 3.12. Perovskit güneş hücresi (Dennis Schroeder / National Renewable Energy Laboratory) (URL-3, 2026)

Perovskit tabanlı fotovoltaik teknolojiler, son yıllarda hızlı gelişim gösteren ve yüksek verim potansiyeline sahip yeni nesil güneş hücreleri arasında yer almaktadır (Şekil 3.12). Bu hücreler, metal-halojen yapıları kristal malzemelerden oluşmakta olup ışığı yüksek verimle absorbe edebilmektedir (URL-3, 2026). Perovskit hücrelerin en önemli avantajlarından biri düşük sıcaklıklarda ve çözeltiden üretilebilme özelliğidir. Bu durum, üretim maliyetlerini önemli ölçüde düşürme potansiyeli sunmaktadır. Ayrıca perovskit hücreler, silikon hücrelerle birlikte kullanılarak tandem yapıları oluşturabilmekte ve bu sayede %30'un üzerinde verim değerlerine ulaşabilmektedir (URL-3, 2026). Ancak bu teknolojinin henüz ticari olarak yaygınlaşmamış olmasının temel nedeni, uzun dönem kararlılık ve dayanıklılık problemleridir. Bu nedenle mevcut araştırmalar, verimlilik artışının yanı sıra hücre ömrünü uzatmaya odaklanmaktadır (Sayın ve Koç, 2011; URL-3, 2026).


### 3.3.5. Çoklu Bağlantılı (III-V) Fotovoltaik Teknolojiler



Şekil 3.13. Rekor seviyeye yakın iki bağlantılı III-V güneş pili, galyum indiyum fosfit üst hücresinin lüminesansı nedeniyle kırmızı renkte parlıyor ve malzemenin iyi kalitesini gösteriyor. Fotoğraf: NREL. (URL-3, 2026)

Çoklu bağlantılı (III-V) fotovoltaik teknolojiler, farklı bant aralıklarına sahip yarı iletken katmanların üst üste yerleştirilmesiyle oluşturulmaktadır (Şekil 3.13). Bu yapı sayesinde güneş spektrumunun farklı dalga boyları daha etkin şekilde değerlendirilebilmekte ve çok yüksek verim değerlerine ulaşılabilir. Bu teknolojilerde %45'in üzerinde verim elde edilebildiği rapor edilmiştir (URL-3, 2026). Bu hücreler genellikle galyum arsenit (GaAs), galyum indiyum fosfit (GaInP) ve galyum indiyum arsenit (GaInAs) gibi III-V grubu yarı iletken malzemelerden üretilmektedir. Yüksek maliyetleri nedeniyle bu teknolojiler daha çok uzay uygulamaları ve yoğunlaştırılmış güneş enerjisi sistemlerinde kullanılmaktadır (URL-3, 2026). Araştırmalar, bu teknolojinin maliyetini düşürmeye ve farklı fotovoltaik sistemlerle entegre edilmesine yönelik olarak devam etmektedir (Sayın ve Koç, 2011).

### 3.3.6. Organik Fotovoltaik Teknolojiler



Şekil 3.14. Organik fotovoltatik güneş hücresi (URL-3, 2026)

Organik fotovoltatik (OPV) teknolojiler, karbon bazlı organik moleküller veya polimerler kullanılarak üretilen güneş hücrelerini ifade etmektedir (Şekil 3.14). Bu hücrelerde ışık absorpsiyonu sonucu oluşan eksitonlar, uygun ara yüzeylerde ayrışarak elektrik akımı oluşturmaktadır (URL-3, 2026). OPV panellerin en önemli avantajları arasında düşük maliyetli üretim, esnek yapı ve hafiflik yer almaktadır. Ayrıca yarı saydam özellikleri sayesinde bina entegrasyonlu uygulamalarda estetik avantaj sağlamaktadır. Bununla birlikte, bu teknolojinin verimlilik değerleri yaklaşık %11 seviyelerinde olup, uzun vadeli dayanıklılık sorunları bulunmaktadır (URL-3, 2026). Bu nedenle organik fotovoltatik teknolojiler henüz gelişim aşamasında olup, gelecekte maliyet avantajı ve esneklik gerektiren uygulamalarda önemli bir rol oynaması beklenmektedir.

### 3.4. Güneş Paneli Tasarımı ve Verimlilik Kriterleri

Güneş paneli tasarımında hücrelerin birbirleriyle olan elektriksel bağlantı şekli büyük önem taşımaktadır. Hücrelerin seri bağlanmasıyla çıkış gerilim değeri artırılırken, paralel bağlanmasıyla akım kapasitesi yükseltilmektedir. Bu bağlantı konfigürasyonları, panelin toplam güç çıkışını belirleyen temel unsurlardır. Ayrıca modül tasarımında kullanılan bypass diyotları, özellikle kısmi gölgelenme durumlarında oluşabilecek güç kayıplarını en

aza indirmek amacıyla devreye alınmaktadır. Bu diyotlar sayesinde, gölgelenen hücreler devre dışı bırakılarak diğer hücrelerin üretimine devam etmesi sağlanmaktadır (Iturralde Carrera vd., 2025).

Güneş panellerinde verimlilik, panel üzerine düşen güneş ışıınımı enerjisinin ne kadarının elektrik enerjisine dönüştürülebildiğini ifade etmektedir. Bu değer, üretilen elektrik gücünün, panele gelen toplam güneş ışıınımına oranı olarak tanımlanmaktadır. Ticari silikon tabanlı panellerde verimlilik değerleri genellikle %15 ile %23 arasında değişirken, laboratuvar ortamında geliştirilen yeni nesil hücre teknolojilerinde bu oran çok daha yüksek seviyelere ulaşabilmektedir. Verimliliği etkileyen faktörler teknolojik (malzeme özellikleri), çevresel (sıcaklık, ışıınım, kirlilik), tasarım (panel yönelimi, takip sistemleri) ve operasyonel (bakım, izleme) olmak üzere dört ana kategoride incelenmektedir (Iturralde Carrera vd., 2025).

Panel çalışma sıcaklığı, fotovoltaiik verimliliği etkileyen en kritik parametrelerden biridir. Güneş ışıınımının artması, panel üzerinde daha fazla enerji birikmesine ve sıcaklık değerlerinin yükselmesine neden olmaktadır. Ancak yarı iletken malzemelerin elektriksel özellikleri sıcaklık arttıkça olumsuz yönde değişmekte, bu durum da panel verimliliğinin düşmesine yol açmaktadır. Bu nedenle modern panel tasarımlarında ısı yönetimi, verimliliği korumak adına önemli bir kriter olarak ele alınmaktadır (Iturralde Carrera vd., 2025; Shukla vd., 2025). Araştırmalar, yüksek sıcaklıkların hücrelerde geri dönüşü olmayan hasarlara yol açarak verim kaybını kalıcı hale getirebildiğini göstermektedir.

Gölgelenme durumu, fotovoltaiik panel verimliliğini olumsuz etkileyen bir diğer önemli faktördür. Panel yüzeyinin belirli bir bölümünün gölgelenmesi halinde, özellikle seri bağlı hücrelerden oluşan sistemlerde tüm panelin performansı ciddi oranda düşebilmektedir. Bu durum, kısmi gölgelenme koşullarında önemli miktarlarda güç kayıplarına neden olabilmektedir. Bu nedenle, panel yerleşim planlaması yapılırken gölgelenme etkilerinin dikkatlice analiz edilmesi ve minimize edilmesi gerekmektedir (Iturralde Carrera vd., 2025).


Panel yüzeyinde oluşabilecek fiziksel kusurlar da verimlilik kayıplarına yol açan önemli etmenler arasında yer almaktadır. Mikro çatlaklar, hücre kırıkları, lehimleme hataları ve

bağlantı problemleri gibi kusurlar, panelin enerji üretim kapasitesini zamanla azaltmaktadır. Bu tür kusurların zaman içinde büyümesi, panelin kullanım ömrü boyunca verimliliğinin düşmesine neden olmaktadır. Bu sebeple, hem üretim aşamasında kalite kontrol süreçlerinin titizlikle uygulanması hem de işletme döneminde düzenli bakım faaliyetlerinin gerçekleştirilmesi büyük önem taşımaktadır (Iturralde Carrera vd., 2025).

Güneş panellerinin uzun ömürlü olmasında, tasarımda kullanılan yardımcı bileşenlerin de önemli bir payı bulunmaktadır. Ön cam yüzey, etilen-vinil asetat (EVA) kapsülleme tabakası, arka katman ve alüminyum çerçeve gibi elemanlar, panelin mekanik dayanıklılığını ve çevresel etkilere karşı direncini doğrudan etkilemektedir. Bu bileşenlerin UV ışınlarına, neme, sıcaklık değişimlerine ve mekanik darbelere karşı dayanıklı olması, panel performansının uzun yıllar boyunca korunmasını sağlamaktadır (Iturralde Carrera vd., 2025).

### **3.5. Güneş Paneli Kusur Türleri**


Fotovoltaik (PV) paneller, üretim sürecinden başlayarak taşıma, kurulum ve saha koşullarında çeşitli çevresel ve mekanik stres faktörlerine maruz kalmaktadır. Bu etkenler, panel yüzeyinde ve iç yapısında zamanla performans düşüşüne yol açan kusurların oluşmasına neden olmaktadır. Literatürde tanımlanan başlıca kusur türleri; mikro çatlaklar, hücre kırıkları, busbar kopmaları, potansiyel kaynaklı bozunma (PID) ve delaminasyon olarak sıralanmaktadır (Diallo vd., 2023; Ymer vd., 2025).



Şekil 3.15. EL testi ile görülebilen mikro çatlaklar (URL-4, 2026)

Mikro çatlaklar, güneş hücrelerinde milimetre ölçeğinden mikrometre düzeyine kadar değişen boyutlarda meydana gelen kılcal kırıklardır (Şekil 3.15) (Dhimish ve Hu, 2022). Bu kusurlar genellikle üretim aşamasındaki termal gerilimler, taşıma sırasında oluşan titreşimler, montaj hataları veya yoğun kar yağışı gibi çevresel faktörler nedeniyle ortaya çıkmaktadır (Dhimish ve Hu, 2022). Hücre kalınlıklarının giderek azalması, mikro çatlak oluşum riskini daha da artırmaktadır.

Mikro çatlakların performans üzerindeki etkisi, çatlağın boyutuna ve konumuna bağlı olarak değişmektedir. Küçük boyutlu çatlaklar (%1-11 oranında) panel çıkış gücünde belirgin bir düşüşe yol açmazken, çatlak oranının %20'ye ulaşması durumunda güç kaybı %20 seviyelerine çıkabilmektedir (Dhimish ve Hu, 2022). Daha büyük çatlak alanlarında (%46 ve üzeri) ise güç kaybı %60'a kadar ulaşabilmektedir (Dhimish ve Hu, 2022). Ayrıca, büyük çatlaklar hücre yüzey sıcaklığının artmasına neden olmakta ve bu durum verimliliği olumsuz etkilemektedir.



Şekil 3.16. Busbar kopması (URL-4, 2026)

Busbar kopması, güneş hücreleri üzerindeki ana metalik iletim hatlarının (busbar) bütünlüğünü kaybetmesi sonucu oluşan bir kusur türüdür (Şekil 3.16). Bu kusur, genellikle termal döngüler sırasında farklı malzemelerin farklı termal genleşme katsayılarına sahip olması nedeniyle lehim bağlantı noktalarında oluşan mekanik gerilimlerden kaynaklanmaktadır (Diallo vd., 2023). Ayrıca, hücre yüzeyinde oluşan çatlakların busbar hatlarına kadar ilerlemesi de bu kusura yol açabilmektedir (Dhimish ve Hu, 2022). Busbar kopması, hücre içinde elektriksel iletkenliğin kesintiye uğramasına neden olarak panelin maksimum akım üretim kapasitesini düşürmektedir (Puranik vd., 2024). Elektrolüminesans (EL) görüntüleme yöntemi, busbar kopmalarının tespitinde etkili bir tanı aracı olarak kullanılmaktadır (Puranik vd., 2024).

Potansiyel Kaynaklı Bozunma (Potential Induced Degradation- PID), özellikle yüksek sistem gerilimlerinde çalışan PV dizilerinde gözlemlenen önemli bir performans düşüşü mekanizmasıdır. Bu kusur, panel hücreleri ile topraklanmış modül çerçevesi arasında oluşan yüksek potansiyel farkı nedeniyle kaçak akımların meydana gelmesiyle oluşmaktadır (Dhimish ve Hu, 2022). PID etkisi, hücrelerde kısa devre akım yoğunluğunda ve açık devre geriliminde azalmaya yol açarak %30'a varan oranlarda verimlilik kaybına neden olabilmektedir (Ymer vd., 2025). Bu bozunma türü, aynı zamanda hücre yüzeyinde lokalize sıcak noktaların (hotspot) oluşmasına da zemin hazırlamaktadır (Dhimish ve Hu, 2022). PID etkisinin erken teşhisi, panel performansının korunması açısından büyük önem taşımaktadır.

Delaminasyon, güneş panelini oluşturan farklı katmanların (ön cam, kapsülleme malzemesi EVA, hücreler, arka katman) birbirinden ayrışması durumudur. Bu kusur, genellikle üretim sırasında yetersiz kapsülleme, nem infiltrasyonu veya aşırı sıcaklık döngülerine maruz kalma nedeniyle ortaya çıkmaktadır (Diallo vd., 2023; Fennessy vd., 2025). Delaminasyon, panelin optik özelliklerini bozarak ışık geçirgenliğini azaltmakta ve aynı zamanda nemin hücre yüzeyine ulaşarak korozyona neden olmasına zemin hazırlamaktadır (Ymer vd., 2025). Bu durum, panelin hem anlık verimliliğini düşürmekte hem de uzun vadede kalıcı hasarlara yol açabilmektedir. Delaminasyonun erken evrede tespiti, görsel inceleme ve termal görüntüleme yöntemleri ile mümkün olabilmektedir.

### 3.6. Elektrolüminesans (EL) Görüntüleme Yöntemi

Fotovoltaik sistemlerde enerji üretim kayıplarının engellenmesi ve modüllerin istenen performans düzeyinde çalışmasının sürdürülebilmesi için, panellerde ortaya çıkan hataların erken safhada belirlenmesi kritik öneme sahiptir. Güneş panellerinde sıklıkla rastlanan mikro düzeydeki çatlaklar, hücre kırılmaları, bağlantı noktalarındaki sorunlar ve imalat sürecinden kaynaklanan bozukluklar, çoğu zaman gözle doğrudan fark edilmemektedir. Bu nedenle, panel hücrelerini detaylı şekilde incelemeye olanak veren ileri görüntüleme yöntemlerine ihtiyaç duyulmaktadır. Bu teknikler arasında elektrolüminesans (EL) görüntüleme, özellikle etkinliği kanıtlanmış başlıca yöntem olarak öne çıkmaktadır (Köntges vd., 2014).

EL tekniği, fotovoltaik hücrelerin normal işleyişinin tersine dayalı bir prensiple çalışır. Standart işletim koşullarında güneş hücreleri üzerlerine gelen ışık enerjisini elektrik enerjisine dönüştürürken, elektrolüminesans yönteminde hücreye harici bir elektrik akımı verilmekte ve bu akımın etkisiyle yarı iletken malzemeden ışımaya yayılmaktadır. Yayılan bu ışık çoğunlukla kızılötesi (Infrared) bölgede olduğundan, ancak özel olarak üretilmiş kameralar aracılığıyla görüntülenebilmektedir (Deitsch vd., 2019)

EL görüntüleri üzerinde yapılan incelemelerde, herhangi bir arızası bulunmayan sağlıklı hücreler düzgün ve parlak bir yapı sergilerken; kusurlu bölgeler daha koyu renkli ya da düzensiz alanlar şeklinde ortaya çıkmaktadır. Bu sayede, mikro çatlaklar, hücre kırıkları, busbar kopmaları ve lehim hataları gibi farklı kusur türleri yüksek güvenilirlikle tespit

edilebilmektedir. Söz konusu yöntem, özellikle üretim safhasında kalite kontrol amacıyla yaygın şekilde kullanılmakta olup, son dönemlerde saha koşullarındaki uygulamalarda da kullanılmaya başlanmıştır (Deitsch vd., 2019; Köntges vd., 2014).

EL görüntüleme tekniğinin belirgin avantajlarından biri, son derece küçük boyuttaki kusurların dahi henüz sorun büyümeden belirlenebilmesini sağlamasıdır. Bu özellik, panel performansında ilerleyen zaman içinde oluşabilecek büyük çaplı enerji kayıplarının önlenmesine doğrudan katkıda bulunmaktadır. Bunun yanı sıra, EL yöntemi hücre temelli analiz imkânı sunduğundan, diğer birçok yönteme kıyasla daha ayrıntılı inceleme yapılmasına olanak tanımaktadır (Köntges vd., 2014).

Bununla birlikte, elektrolüminesans görüntüleme yönteminin bazı kısıtlayıcı yönleri de bulunmaktadır. Yöntemin uygulanabilmesi için fotovoltaiik panellere harici bir akım uygulanması gerekmekte olup, bu durum saha koşullarında ek ekipman kullanımını zorunlu kılmaktadır. Ayrıca, görüntüleme işleminin genel olarak karanlık bir ortamda yapılma gerekliliği vardır. Bu durum, yöntemin açık alan uygulamalarında kullanımını sınırlayıcı bir faktör olarak değerlendirilmektedir (Deitsch vd., 2019).

EL yöntemi, termal görüntüleme gibi diğer tanı yöntemleri ile birlikte kullanıldığında daha kapsamlı analizlerin yapılmasına olanak sağlamaktadır. Termal görüntüleme, panelin yüzey sıcaklık dağılımını analiz ederek sıcak nokta (hotspot) gibi sorunları tespit ederken; EL yöntemi, hücrenin iç yapısındaki bozuklukları görünür hale getirmektedir. Bu nedenle, her iki yöntemin birlikte kullanılması, fotovoltaiik sistemlerin performans değerlendirmesinde daha güvenilir sonuçların elde edilmesini sağlamaktadır.

## 4. DERİN ÖĞRENME YÖNTEMLERİ VE BAŞARIM METRİKLERİ


Bu bölümde, elektrolüminesans (EL) görüntüleri üzerinde fotovoltaiik (PV) hücre kusurlarının otomatik olarak sınıflandırılmasında kullanılan derin öğrenme yöntemlerinin kuramsal temelleri ele alınmaktadır. Öncelikle yapay sinir ağlarının temel kavramları açıklanmış, ardından görüntü tabanlı problemlerde öne çıkan evrişimli sinir ağlarının (Convolutional Neural Network – CNN) yapısı ve işleyişi ayrıntılandırılmıştır. Daha sonra, sınırlı büyüklükteki veri kümelerinde yüksek başarımla elde edilmesini sağlayan transfer öğrenme yaklaşımı ve bu çalışmadaki ikili (Defect/Normal) sınıflandırma problemine ilişkin kavramsal çerçeve sunulmaktadır. Bölümün son kısmında ise geliştirilen modellerin değerlendirilmesinde kullanılan başarımla metrikleri tanıtılmaktadır. Böylece, izleyen bölümlerde anlatılacak materyal ve metot ile deneysel bulgular için gerekli kuramsal altyapı oluşturulmaktadır.

### 4.1. Yapay Sinir Ağları ve Temel Kavramlar

Yapay zekânın bir alt dalı olan makine öğrenmesi, verilerden örüntüler çıkararak açıkça programlanmadan karar verebilen sistemlerin geliştirilmesini amaçlamaktadır. Geleneksel makine öğrenmesi yöntemlerinde, başarımla büyük ölçüde veriden el ile çıkarılan özniteliklerin niteliğine bağlıdır. Buna karşın derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla öznitelikleri ham veriden hiyerarşik bir biçimde ve otomatik olarak öğrenebilmesi yönüyle bu yaklaşımlardan ayrılmaktadır (LeCun vd., 2015). Bu özellik, EL görüntüleri gibi düşük kontrastlı ve karmaşık dokusal yapıya sahip görüntülerde, el ile öznitelik mühendisliğine gerek kalmadan ayırt edici bilginin çıkarılmasını olanaklı kılmaktadır.

Yapay sinir ağları, insan beynindeki biyolojik sinir hücrelerinin (nöron) bilgi işleme biçiminden esinlenerek geliştirilmiş hesaplama modelleridir. Ağın temel yapı taşı olan yapay nöron, kendisine ulaşan girdileri belirli ağırlıklarla çarpar, bunları bir eşik (bias) değeriyle toplar ve elde edilen sonucu doğrusal olmayan bir aktivasyon fonksiyonundan geçirerek çıktısını üretir (Şekil 4.1).  $x_1, x_2, \dots, x_n$  girdilerini,  $w_1, w_2, \dots, w_n$  bu girdilere

karşılık gelen ağırlıkları ve  $b$  eşik değerini göstermek üzere, nöronun net girdisi ( $z$ ) Denklem 4.1 ile tanımlanmaktadır.



Şekil 4.1. Yapay nöron modelinin temel bileşenleri

$$z = \sum_{i=1}^n w_i x_i + b \quad (4.1)$$

Net girdi  $z$ , seçilen bir aktivasyon fonksiyonu  $f$  aracılığıyla dönüştürülerek nöronun çıktısı ( $y$ ) elde edilir (Denklem 4.2). Aktivasyon fonksiyonu, ağı doğrusal olmayan davranış kazandırarak karmaşık ilişkilerin öğrenilebilmesini sağlar; aksi takdirde çok katmanlı bir ağı dahi yalnızca doğrusal bir dönüşümü temsil edebilirdi.

$$y = f(z) \quad (4.2)$$


Literatürde yaygın olarak kullanılan aktivasyon fonksiyonlarından üçü Sigmoid, hiperbolik tanjant (Tanh) ve düzeltilmiş doğrusal birim (Rectified Linear Unit – ReLU) fonksiyonlarıdır (Şekil 4.2). Sigmoid fonksiyonu (Denklem 4.3) girdiyi  $(0, 1)$  aralığına sıkıştırır ve özellikle olasılık yorumu gerektiren çıkış katmanlarında tercih edilir. Tanh fonksiyonu (Denklem 4.4) ise çıktıyı  $(-1, 1)$  aralığına taşıyarak sıfır merkezli bir dağılım sağlar.

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (4.3)$$

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (4.4)$$

Sigmoid ve Tanh fonksiyonları, girdi değerleri büyüklük olarak arttıkça türevlerinin sıfıra yaklaşması nedeniyle derin ağlarda kaybolan gradyan (vanishing gradient) sorununa yol açabilmektedir. Bu sorunu büyük ölçüde gideren ReLU fonksiyonu (Denklem 4.5), negatif girdileri sıfırlarken pozitif girdileri değiştirmeden geçirir; hesaplama maliyetinin düşük olması ve derin ağların eğitimi hızlandırması nedeniyle evrişimli sinir ağlarında en yaygın kullanılan aktivasyon fonksiyonu durumuna gelmiştir (Nair ve Hinton, 2010).

$$f(z) = \max(0, z) \quad (4.5)$$



Şekil 4.2. Sigmoid, Tanh ve ReLU aktivasyon fonksiyonlarının davranışı

Tek bir yapay nöronun temsil gücü sınırlı olduğundan, çok sayıda nöron katmanlar hâlinde bir araya getirilerek çok katmanlı algılayıcı (Multilayer Perceptron – MLP) olarak adlandırılan ağlar oluşturulur. Bu ağlarda bilgi, girdi katmanından başlayarak bir veya daha fazla gizli katman üzerinden çıkış katmanına doğru ilerler; bu süreç ileri besleme (forward propagation) adı verilir. Ağdaki katman sayısının ve her katmandaki nöron sayısının artması, modelin daha karmaşık ilişkileri öğrenebilmesine olanak tanımakta; bu derinlik, derin öğrenme kavramının temelini oluşturmaktadır (Goodfellow vd., 2016).

Bir yapay sinir ağıının eğitimi, modelin ürettiği tahminler ile gerçek etiketler arasındaki farkı nicelleştiren bir kayıp fonksiyonunun (loss function) en aza indirilmesi temeline dayanır. Eğitim sırasında kayıp değerinin ağırlıklara göre gradyanları, geri yayılım (backpropagation) algoritması ile katmanlar boyunca geriye doğru hesaplanır (Rumelhart vd., 1986). Elde edilen gradyanlar kullanılarak ağırlıklar, gradyan inişi (gradient descent) yöntemiyle kaybı azaltacak yönde güncellenir (Denklem 4.6). Burada  $\eta$  öğrenme oranını (learning rate),  $L$  ise kayıp fonksiyonunu göstermektedir.

$$w \leftarrow w - \eta \frac{\partial L}{\partial w} \quad (4.6)$$


Öğrenme oranı, ağırlık güncellemelerinin adım büyüklüğünü belirleyen ve modelin yakınsama davranışını doğrudan etkileyen önemli bir hiperparametredir. Eğitim verisinin tamamının ağ üzerinden bir kez geçirilmesi bir dönem (epoch); ağırlıkların güncellenmesinde kullanılan küçük veri grupları ise yığın (batch) olarak adlandırılır. Eğitim sürecinde, modelin eğitim verisini ezberleyip yeni verilere genelleyememesi durumu aşırı öğrenme (overfitting), verideki yapıyı yeterince öğrenememesi durumu ise eksik öğrenme (underfitting) olarak tanımlanır. Aşırı öğrenmenin önüne geçmek amacıyla düzenleme (regularization), seyreltme (dropout) ve veri artırma gibi teknikler kullanılmaktadır; bu tekniklerin bu çalışmadaki uygulaması dördüncü ve beşinci bölümlerde ayrıntılı olarak ele alınmaktadır.

Sonuç olarak yapay sinir ağları, ham veriden ayırt edici öznelilikleri otomatik olarak öğrenebilme yeteneği sayesinde, EL görüntülerinde kusurlu (Defect) ve sağlıklı (Normal) hücrelerin ayırt edilmesi gibi görsel sınıflandırma problemleri için güçlü bir temel sunmaktadır. Ancak görüntü verilerinin yüksek boyutlu yapısı, doğrudan tam bağlantılı ağların kullanımını verimsiz kılmakta ve bu durum, izleyen alt bölümde ele alınan evrişimli sinir ağlarının geliştirilmesine zemin hazırlamaktadır.

## 4.2. Evrişimli Sinir Ağları (CNN)

Görüntü verilerinin doğrudan tam bağlantılı ağlarla işlenmesi iki temel sorunu beraberinde getirir. Birincisi, her pikselin bir sonraki katmandaki tüm nöronlara bağlanması nedeniyle eğitilmesi gereken ağırlık sayısının aşırı derecede artması; ikincisi ise görüntünün düzleştirilmesi sırasında piksellerin uzamsal (konumsal) ilişkilerinin kaybolmasıdır. Evrişimli sinir ağları, yerel bağlantılılık ve ağırlık paylaşımı ilkelerine dayanarak bu sorunları gidermek üzere tasarlanmıştır (LeCun vd., 1998). Bu sayede ağ, görüntüdeki yerel örüntüleri çok daha az parametreyle öğrenebilmekte ve uzamsal yapıyı koruyabilmektedir.

CNN mimarisi, 2012 yılında büyük ölçekli görüntü sınıflandırma yarışmasında elde edilen başarının ardından bilgisayarlı görü alanında baskın yaklaşım durumuna gelmiştir (Krizhevsky vd., 2012). Tipik bir evrişimli sinir ağı, art arda gelen evrişim ve havuzlama katmanlarından oluşan bir öznitelik çıkarımı bölümü ile bu öznitelikleri kullanarak nihai kararı üreten bir sınıflandırma bölümünden meydana gelir (Şekil 4.3). İlk katmanlar kenar ve köşe gibi düşük seviyeli öznitelikleri öğrenirken, daha derin katmanlar bu öznitelikleri birleştirerek dokular ve nesneye özgü karmaşık örüntüler gibi yüksek seviyeli öznitelikleri temsil eder.




Şekil 4.3. Evrişimli sinir ağının genel mimarisi ve EL görüntüsü üzerinde Defect/Normal sınıflandırma akışı

Bu hiyerarşik öznitelik öğrenme yeteneği, EL görüntülerinde kusur tespiti problemi için özellikle uygundur. Çünkü kusurlar çoğunlukla hücre yüzeyinde yerel dokusal düzensizlikler biçiminde ortaya çıkmaktadır: çalışmada kullanılan örneklerde de görüldüğü üzere kusurlu hücreler, busbar hatları boyunca uzanan koyu ve sönük bölgeler ile düzensiz parlaklık dağılımları sergilerken, normal hücreler görece homojen bir parlaklık ve düzenli bir yapı göstermektedir. Evrişimli sinir ağları, bu tür yerel desenleri konumdan bağımsız bir biçimde öğrenebildiğinden, düşük kontrastlı ve gürültülü EL görüntülerinde dahi ayırt edici öznitelikleri başarıyla çıkarabilmektedir.

#### 4.2.1. Evrişim Katmanı

Evrişim katmanı, evrişimli sinir ağlarının temel yapı taşı olup öznitelik çıkarımından sorumludur. Bu katmanda, çekirdek (kernel) veya filtre olarak adlandırılan küçük boyutlu ağırlık matrisleri, girdi görüntüsü üzerinde belirli bir adımla kaydırılarak her konumda yerel bölge ile noktasal çarpımlarının toplamı hesaplanır. Bu işlem sonucunda, girdideki belirli bir örüntünün nerede bulunduğunu gösteren bir öznitelik haritası (feature map) elde edilir. İki boyutlu bir  $I$  girdisi ve  $K$  çekirdeği için evrişim işlemi Denklem 4.7 ile ifade edilmektedir.

$$s(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (4.7)$$



Şekil 4.4. Bir çekirdeğin girdi üzerinde kaydırılmasıyla öznitelik haritasının oluşturulması

Şekil 4.4'te gösterildiği gibi, çekirdek girdi üzerinde kaydırıldıkça her konum için bir öznitelik değeri üretilir. Evrişim işleminin davranışını belirleyen başlıca hiperparametreler

çekirdek boyutu, adım (stride) ve dolgudur (padding). Adım, çekirdeğin her seferinde kaç piksel kaydırılacağını; dolgu ise girdinin kenarlarına eklenen piksellerle çıktı boyutunun nasıl korunacağını denetler. W girdi boyutunu, F çekirdek boyutunu, P dolgu miktarını ve S adım değerini göstermek üzere, çıktı öznitelik haritasının boyutu (O) Denklem 4.8 ile hesaplanmaktadır.

$$O = \frac{W-F+2P}{S} + 1 \quad (4.8)$$


Evrişim işleminin çıktısı, nöron modelinde olduğu gibi bir eşik değeriyle toplanıp doğrusal olmayan bir aktivasyon fonksiyonundan (genellikle ReLU) geçirilerek katmanın nihai öznitelik haritası elde edilir (Denklem 4.9). Bir evrişim katmanında çok sayıda farklı çekirdek bulunur ve her çekirdek, girdideki farklı bir örüntüye duyarlı ayrı bir öznitelik haritası üretir. Böylece ağ, kusur tespitinde önem taşıyan koyu lekeler, parlaklık geçişleri ve çizgisel düzensizlikler gibi farklı yerel desenleri eş zamanlı olarak öğrenebilmektedir.

$$A(i, j) = f(S(i, j) + b) \quad (4.9)$$

#### 4.2.2. Havuzlama Katmanı

Havuzlama (pooling) katmanı, evrişim katmanlarından elde edilen öznitelik haritalarının uzamsal boyutunu küçülterek modelin hesaplama maliyetini ve parametre sayısını azaltır. Bunun yanı sıra havuzlama, özniteliklerin konumundaki küçük değişimlere karşı belirli bir değişmezlik (invariance) kazandırarak modelin genelleme yeteneğini artırır ve aşırı öğrenme riskini azaltır. En yaygın kullanılan tür olan maksimum havuzlama (max pooling), belirlenen pencere içindeki en büyük değeri seçerken (Denklem 4.10), ortalama havuzlama (average pooling) pencere içindeki değerlerin ortalamasını alır (Şekil 4.5).

$$P_{i,j} = \max_{(m,n) \in R} A(i + m, j + n) \quad (4.10)$$



Şekil 4.5. 2×2 boyutlu pencere ile maksimum ve ortalama havuzlama işlemleri

Şekil 4.5'te, 2×2 boyutlu bir pencerenin iki adım aralıkla kaydırılmasıyla öznitelik haritasının boyutunun yarıya indirildiği görülmektedir. Maksimum havuzlama, her bölgedeki en baskın öznitelik tepkisini koruyarak kusura ilişkin güçlü işaretlerin sonraki katmanlara aktarılmasını sağladığından, kusur tespiti uygulamalarında yaygın biçimde tercih edilmektedir.

#### 4.2.3. Tam Bağlantılı Katman ve Sınıflandırma

Öznitelik çıkarımı bölümünün sonunda elde edilen çok boyutlu öznitelik haritaları, düzleştirme (flattening) işlemiyle tek boyutlu bir vektöre dönüştürülür ve bir veya daha fazla tam bağlantılı (fully connected) katmana aktarılır. Bu katmanlar, evrişim ve havuzlama katmanlarınca öğrenilen yüksek seviyeli öznitelikleri birleştirerek sınıflandırma kararını oluşturur. Çıkış katmanında, her sınıfa ait olasılık değerlerinin üretilmesi için çok sınıflı problemlerde softmax fonksiyonu (Denklem 4.11) kullanılır. Softmax, ağıın ürettiği ham skorları (z) toplamı bire eşit olan olasılıklara dönüştürür.

$$\text{softmax}(Z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (4.11)$$


Bu tez çalışmasında ele alınan problem, hücrelerin Defect ve Normal olmak üzere iki sınıftan birine atanmasını gerektiren ikili bir sınıflandırma problemidir. İkili sınıflandırmada çıkış katmanında çoğunlukla tek bir nöron ve sigmoid aktivasyon fonksiyonu kullanılarak girdinin pozitif sınıfa ait olma olasılığı doğrudan kestirilebilir.

Evrişimli sinir ağlarının öznitelik çıkarımı ve sınıflandırmayı tek bir bütün olarak, uçtan uca (end-to-end) öğrenebilmesi, EL görüntülerinde kusur tespiti için el ile öznitelik mühendisliğine gerek kalmadan otomatikleştirilmesini sağlayan temel üstünlük olarak öne çıkmaktadır. İkili sınıflandırmaya ilişkin kavramsal çerçeve ve bu problemde kullanılan kayıp fonksiyonu, izleyen alt bölümlerde ayrıntılı olarak ele alınmaktadır.

### 4.3. Transfer Öğrenme

Derin evrişimli sinir ağları, yüksek başarıma ulaşabilmek için genellikle çok sayıda etiketli örnek içeren büyük veri kümelerine gereksinim duyar. Ancak elektrolüminesans görüntüleriyle kusur tespiti gibi uzmanlık gerektiren alanlarda, etiketli veri elde etmek hem maliyetli hem de zaman alıcıdır; bu çalışmada kullanılan veri kümesi de toplam 1000 görüntüyle sınırlıdır. Bu kısıtı aşmak amacıyla başvurulmuş transfer öğrenme, bir kaynak görevde öğrenilen bilginin, veri bakımından kısıtlı bir hedef göreve aktarılması esasına dayanır (Pan ve Yang, 2010). Böylece, sıfırdan eğitim için gereken büyük veri ve hesaplama gereksinimi önemli ölçüde azaltılmaktadır.

Transfer öğrenme uygulamalarında kaynak görev olarak çoğunlukla, milyonlarca doğal görüntü ve binlerce sınıf içeren ImageNet veri kümesi üzerinde önceden eğitilmiş ağlar kullanılır (Krizhevsky vd., 2012). Bu ağların ilk katmanları, kenar, köşe ve doku gibi pek çok görsel göreve genellenebilen düşük seviyeli öznitelikleri öğrenir; bu özniteliklerin yeni bir hedef göreve aktarılması hem eğitim süresini kısaltmakta hem de sınırlı veriyle daha yüksek başarımlar elde edilmesini sağlamaktadır (Şekil 4.6). Nitekim transfer öğrenme, fotovoltaik sistemlerin görüntü tabanlı arıza ve kusur tespiti çalışmalarında yaygın biçimde benimsenen bir yaklaşımdır (Akram vd., 2020).



Şekil 4.6. ImageNet üzerinde önceden eğitilmiş bir ağı EL görüntüleriyle kusur sınıflandırmaya transferi

#### 4.3.1. Transfer Öğrenme Stratejileri

Transfer öğrenme, uygulamada başlıca iki strateji ile gerçekleştirilir. Birincisi öznitelik çıkarıcı olarak kullanım (feature extraction) stratejisidir. Bu yaklaşımda, önceden eğitilmiş ağı evrişim tabanı olduğu gibi korunur; başka bir deyişle ağırlıkları dondurularak eğitim sırasında güncellenmez. Ağı yalnızca sınıflandırma yapan son katmanları hedef göreve uygun yeni bir sınıflandırıcı baş ile değiştirilir ve sadece bu yeni baş eğitilir (Şekil 4.6a). Bu strateji, hedef veri kümesinin küçük olduğu ve kaynak alanla benzerlik gösterdiği durumlarda, aşırı öğrenme riskini düşük tutması bakımından elverişlidir.

İkinci strateji ise ince ayar (fine-tuning) olarak adlandırılır. Bu yaklaşımda, yeni sınıflandırıcı başın eğitilmesine ek olarak, evrişim tabanının üst katmanlarındaki (ve gerektiğinde tümündeki) ağırlıkların bir bölümü de çözülerek düşük bir öğrenme oranıyla yeniden eğitilir (Şekil 4.6b). Düşük öğrenme oranı, önceden öğrenilmiş değerli özniteliklerin bozulmasını önlerken, ağı hedef alanın özgül örüntülerine uyarlanmasını sağlar. İnce ayar, hedef veri kümesinin görece büyük olduğu veya kaynak alanla arasındaki farkın belirgin olduğu durumlarda daha yüksek başarımlar sunar.

Uygun stratejinin seçimi, büyük ölçüde hedef veri kümesinin büyüklüğüne ve kaynak alanla olan benzerliğine bağlıdır. EL görüntüleri, gri tonlamalı ve düşük kontrastlı


yapılarıyla ImageNet'teki doğal renkli görüntülerden alan bazında farklılaşsa da önceden eğitilmiş ağların öğrendiği kenar ve doku gibi temel öznitelikler bu alana da başarıyla aktarılabilir. Bu nedenle, sınırlı büyüklükteki EL veri kümeleriyle çalışırken, öznitelik çıkarıcı kullanım ile ince ayar stratejilerinin karşılaştırılmalı olarak değerlendirilmesi yaygın bir uygulamadır.

#### 4.3.2. Öne Çıkan Mimariler (ResNet, EfficientNet, MobileNet)

Transfer öğrenmede omurga (backbone) olarak, ImageNet üzerinde önceden eğitilmiş çeşitli evrişimli sinir ağı mimarileri kullanılmaktadır. Aşağıda, literatürde ve fotovoltaik kusur tespiti çalışmalarında öne çıkan üç mimari özetlenmektedir; bu mimarilerin temel özellikleri Tablo 4.1'de karşılaştırılmalı olarak sunulmaktadır.

**ResNet.** He vd. (2016) tarafından önerilen ResNet (Residual Network) mimarisi, çok derin ağların eğitiminde ortaya çıkan kaybolan gradyan sorununu, artık (residual) bağlantılar aracılığıyla büyük ölçüde gidermiştir. Kestirme (shortcut) bağlantılar olarak da adlandırılan bu özdeşlik bağlantıları sayesinde, bir bloğun girdisi çıktısına doğrudan eklenir (Denklem 4.12, Şekil 4.7). Burada  $x$  bloğun girdisini,  $F(x)$  bloğun öğrendiği artık dönüşümü ve  $y$  bloğun çıktısını göstermektedir.

$$y = F(x, \{W_i\}) + x \quad (4.12)$$



Şekil 4.7. ResNet mimarisindeki artık (residual) blok ve özdeşlik kestirme bağlantısı

Bu yapı sayesinde yüzlerce katman içeren ağlar dahi kararlı biçimde eğitilebilmekte; ResNet50 ve ResNet101 gibi sürümleri, transfer öğrenme uygulamalarında sıkça tercih edilmektedir.

**EfficientNet.** Tan ve Le (2019) tarafından önerilen EfficientNet mimarisi, ağın derinliğini, genişliğini ve girdi çözünürlüğünü tek bir bileşik katsayıyla dengeli biçimde ölçeklendiren bileşik ölçekleme (compound scaling) yaklaşımını ortaya koymuştur. B0'dan B7'ye uzanan model ailesi, görece az sayıda parametre ile yüksek sınıflandırma başarımı sağlayarak başarımlar ve hesaplama maliyeti arasında verimli bir denge sunar.

**MobileNet.** Howard vd. (2017) tarafından önerilen ve Sandler vd., (2018) ile geliştirilen MobileNet mimarisi, standart evrişimi derinlemesine ayrılabilir evrişim (depthwise separable convolution) işlemleriyle değiştirerek hesaplama maliyetini ve parametre sayısını önemli ölçüde azaltır. Bu hafif yapısı, mobil ve gömülü cihazlarda çalışmaya elverişli olması nedeniyle, fotovoltaik santrallerin sahada gerçek zamanlı denetimi gibi kaynak kısıtlı uygulamalar için önemli bir avantaj sağlar.

Tablo 4.1. Transfer öğrenmede yaygın kullanılan önceden eğitilmiş mimarilerin karşılaştırılması


| Mimari       | Yıl       | Temel yenilik                                    | Yaklaşık derinlik / parametre                 |
|--------------|-----------|--------------------------------------------------|-----------------------------------------------|
| ResNet       | 2016      | Artık (kestirme) bağlantılar                     | 50–152 katman; $\approx$ 25 milyon (ResNet50) |
| EfficientNet | 2019      | Bileşik ölçekleme (derinlik/genişlik/çözünürlük) | B0–B7; $\approx$ 5,3 milyon (B0)              |
| MobileNet    | 2017–2018 | Derinlemesine ayrılabilir evrişim                | Hafif; $\approx$ 3,4 milyon (V2)              |

Sonuç olarak, bu mimarilerin her biri farklı başarımlar–maliyet dengeleri sunmakta olup, fotovoltaik hücrelerin EL görüntüleri üzerinden kusur tespiti omurga olarak değerlendirilebilmektedir. Mimari seçimi; hedeflenen sınıflandırma başarımı, kullanılabilir veri miktarı ve dağıtım ortamının hesaplama kısıtları birlikte göz önünde bulundurularak yapılmalıdır. Bu çalışmada söz konusu mimarilerin transfer öğrenme ile uyarlanmasına ilişkin deneysel ayrıntılar, izleyen bölümlerde ele alınmaktadır.

#### 4.3.3. Dikkat Mekanizmaları ve Sıkıştırma-Uyarma (SE) Blokları

Evrişimli sinir ağlarında elde edilen öznitelik haritalarının her bir kanalı, farklı görsel örüntülere karşı duyarlılık göstermekte; ancak geleneksel mimariler bu kanalların tümünü eşit önemde değerlendirmektedir. Oysa belirli bir görevde, kanalların bir bölümü ayırt edici bilgi taşıırken bir bölümü görece önemsiz kalabilmektedir. Dikkat (attention) mekanizmaları, ağın girdinin en bilgilendirici bölümlerine odaklanmasını sağlayan ve bu yolla temsil gücünü artıran yöntemlerdir. Görüntü sınıflandırmada öne çıkan bir yaklaşım, her bir öznitelik kanalının önemini veriye bağlı olarak belirleyen kanal bazında dikkat (channel attention) mekanizmasıdır (Hu vd., 2018; Woo vd., 2018).

Hu vd. (2018) tarafından önerilen Sıkıştırma-ve-Uyarma (Squeeze-and-Excitation, SE) bloğu, kanal bazında dikkati hesaplama açısından verimli bir biçimde gerçekleştiren hafif bir yapıdır. Blok, herhangi bir evrişimli mimariye gömülebilmekte ve görece az sayıda ek parametre ile ihmal edilebilir bir hesaplama maliyeti getirmektedir. Bir evrişim işlemiyle elde edilen ve  $H \times W \times C$  boyutundaki öznitelik haritaları (U) üzerinde, SE bloğu birbirini izleyen üç adımdan oluşan bir yeniden ağırlıklandırma uygular (Şekil 4.8). Sıkıştırma (squeeze) adımında her öznitelik kanalı, uzamsal boyutlar ( $H \times W$ ) üzerinden küresel ortalama havuzlama ile tek bir betimleyici değere indirgenir; böylece kanalların genel etkinliğini özetleyen C boyutlu bir kanal betimleyici vektörü (z) elde edilir. Uyarma (excitation) adımında bu vektör ardışık iki tam bağlantılı katmandan geçirilir: ilki kanal sayısını indirgeme oranı r kadar düşüren ( $C \rightarrow C/r$ ) ReLU etkinleştirmeli bir darboğaz katmanı, ikincisi ise boyutu özgün kanal sayısına geri yükselten ( $C/r \rightarrow C$ ) sigmoid etkinleştirmeli katmandır; bu işlem sonucunda her kanal için  $[0, 1]$  aralığında bir ağırlık (s) üretilir. Ölçekleme (scale) adımında ise U'daki her kanal, kendisine karşılık gelen bu ağırlıkla çarpılarak yeniden ağırlıklandırılır; böylece ayırt edici kanallar öne çıkarılırken bilgi taşımayan kanallar bastırılır.



Şekil 4.8. Sigmoid çıktısı, karar eşiği ( $\tau = 0,5$ ) ve Normal/Defect karar bölgeleri

İndirgeme oranı  $r$ , uyarma adımındaki ara katmanın boyutunu ve dolayısıyla bloğun getirdiği ek parametre maliyetini belirleyen bir hiperparametredir; daha büyük  $r$  değerleri daha az parametre ile daha güçlü bir sıkıştırma anlamına gelir. SE bloklarının, ImageNet gibi büyük ölçekli kıyaslama veri kümelerinde, ihmal edilebilir bir hesaplama maliyetiyle sınıflandırma başarımını tutarlı biçimde artırdığı gösterilmiştir (Hu vd., 2018). Kanal bazında dikkatin yanı sıra, kanal ve uzamsal dikkati birlikte ele alan modüller de önerilmiştir (Woo vd., 2018).

Bu özellikleriyle SE bloğu, elektrolüminesans görüntülerinde kusur tespiti için elverişli bir bileşendir. Kusur görüntülerinin yalnızca belirli öznelilik kanallarında belirginleşmesi ve düşük kontrastlı yapıları nedeniyle, kanal bazında yeniden ağırlıklandırma, kusurla ilişkili kanalların öne çıkarılmasına katkı sağlayabilmektedir. Bu nedenle bu tez çalışmasında önerilen model, ResNet50 omurgasının bir SE bloğuyla güçlendirilmesine dayanmaktadır; önerilen mimarinin ayrıntıları ve biçimsel formülasyonu dördüncü bölümde (Bölüm 4.3.2) sunulmaktadır.

#### 4.4. İkili Sınıflandırma

Sınıflandırma, bir girdinin önceden tanımlı sınıflardan birine atanması işlemidir. Sınıf sayısının ikiye indiği özel durum ikili sınıflandırma (binary classification) olarak adlandırılır. Bu tez çalışmasında ele alınan problem ikili niteliktedir: her elektrolüminesans hücre görüntüsü, Defect (kusurlu) veya Normal (sağlıklı) olmak üzere iki sınıftan birine


atanmaktadır. Yaygın kabule göre, tespiti hedeflenen durum pozitif sınıf olarak ele alınır; bu çalışmada kusurlu hücreler pozitif sınıf (1), sağlıklı hücreler ise negatif sınıf (0) olarak kodlanmaktadır. Modelin amacı, ürettiği tahminin gerçek etikete olabildiğince yakın olmasını sağlayacak parametreleri öğrenmektir.

Evrişimli sinir ağı tabanlı ikili sınıflandırmada, ağı çıkış katmanı genellikle tek bir nörondan oluşur ve bu nöronda sigmoid aktivasyon fonksiyonu kullanılır. Böylece ağı ürettiği ham skor ( $z$ ),  $(0, 1)$  aralığında bir değere dönüştürülerek girdinin pozitif sınıfa, yani Defect sınıfına ait olma olasılığı ( $\hat{y}$ ) elde edilir (Denklem 4.13). Olasılığın bu şekilde doğrudan kestirilebilmesi, ikili sınıflandırmada sigmoidli tek nöronlu çıkışı yaygın bir tercih durumuna getirmektedir; iki nöronlu ve softmax aktivasyonlu çıkış ise buna denk bir alternatif oluşturur.

$$\hat{y} = \sigma(z) = \frac{1}{1+e^{-z}} \quad (4.13)$$

Elde edilen olasılık değeri, bir karar eşiği ( $\tau$ ) ile karşılaştırılarak kesikli sınıf etiketine dönüştürülür (Denklem 4.14). Varsayılan olarak eşik değeri 0,5 alınır; tahmin edilen olasılık bu eşiğe eşit veya büyük olduğunda görüntü Defect, küçük olduğunda ise Normal sınıfına atanır (Şekil 4.9). Eşik değeri, uygulamanın gereksinimlerine göre ayarlanabilen bir parametredir. Kusur tespiti bağlamında, kusurlu bir hücrenin gözden kaçırılmasının (yanlış negatif) maliyeti, sağlıklı bir hücrenin yanlışlıkla kusurlu sayılmasının (yanlış pozitif) maliyetinden çoğu kez daha yüksektir. Bu nedenle eşik değeri düşürülerek modelin kusurları yakalama duyarlılığı artırılabilir; eşik seçiminin başarıma etkisi, 4.5 numaralı alt bölümde ROC eğrisi bağlamında ayrıntılı olarak ele alınmaktadır.

$$Karar = f(x) = \begin{cases} Defect, & \hat{y} \geq \tau \\ Normal, & \hat{y} < \tau \end{cases} \quad (4.14)$$



Şekil 4.9. Sigmoid çıktısı, karar eşiği ( $\tau = 0,5$ ) ve Normal/Defect karar bölgeleri

Modelin eğitiminde, ikili sınıflandırma problemlerine özgü bir kayıp fonksiyonu olan ikili çapraz entropi (binary cross-entropy), diğer adıyla log-kayıp kullanılır (Goodfellow vd., 2016). Tek bir örnek için bu kayıp Denklem 4.15 ile tanımlanmaktadır; burada  $y$  örneğin gerçek etiketini (0 veya 1),  $\hat{y}$  ise modelin pozitif sınıf için ürettiği olasılık tahminini göstermektedir. Fonksiyonun yapısı gereği, model gerçek sınıfa düşük bir olasılık atadığında kayıp hızla büyür; böylece model, doğru ve güvenli olasılık tahminleri üretmeye yönlendirilir.

$$L(y, \hat{y}) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (4.15)$$

Veri kümesinin tamamı üzerindeki toplam kayıp ise, tüm örneklerin kayıplarının ortalaması alınarak hesaplanır (Denklem 4.16); burada  $N$  örnek sayısını, alt indis  $i$  ise  $i$ . örneği belirtmektedir. Eğitim süreci, bu ortalama kaybı en aza indirecek ağırlıkların bulunması esasına dayanır.

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (4.16)$$

Söz konusu kayıp fonksiyonu, gradyan inişi ve uyarlanabilir öğrenme oranına sahip Adam gibi optimize ediciler aracılığıyla en aza indirilir (Kingma ve Ba, 2015). Eğitim verisindeki

sınıf dağılımı da modelin başarımını doğrudan etkileyen bir etkidir; sınıflar arasındaki dengesizlik, modelin çoğunluk sınıfına yanlılık göstermesine yol açabilir. Bu çalışmada kullanılan veri kümesi, 500 Defect ve 500 Normal görüntü ile dengeli bir dağılıma sahip olduğundan, bu tür bir yanlılık riski düşüktür. Dengesiz veri kümelerinde ise ağırlıklı kayıp fonksiyonları veya yeniden örnekleme gibi yöntemlere başvurulmaktadır.

Sonuç olarak ikili sınıflandırma, sigmoidli çıkış katmanı ve ikili çapraz entropi kaybı ile EL görüntülerinde Defect/Normal ayrımı için uygun bir çerçeve sunmaktadır. Ancak bir sınıflandırma modelinin başarısı, yalnızca tek bir doğruluk değeriyle yeterince değerlendirilemez; özellikle kusur tespiti gibi yanlış negatiflerin kritik olduğu uygulamalarda, modelin farklı açılardan incelenmesi gerekir. Bu nedenle, izleyen alt bölümde sınıflandırma başarımını çok yönlü biçimde değerlendiren başarım metrikleri ele alınmaktadır.

#### 4.5. Başarım Metrikleri

Bir sınıflandırma modelinin başarımı, özellikle yanlış sınıflandırmaların farklı maliyetler taşıdığı uygulamalarda, tek bir ölçütle yeterince değerlendirilemez; bu nedenle birbirini tamamlayan çeşitli başarım metrikleri bir arada kullanılır. İkili sınıflandırmada bu metriklerin tamamı, modelin tahminleri ile gerçek etiketlerin karşılaştırılmasından elde edilen dört temel sonuca dayanır. Bu çalışmada pozitif sınıf Defect olmak üzere söz konusu sonuçlar aşağıdaki gibi tanımlanır:

- **Doğru Pozitif (DP):** kusurlu bir hücrenin doğru biçimde Defect olarak sınıflandırılması,
- **Doğru Negatif (DN):** sağlıklı bir hücrenin doğru biçimde Normal olarak sınıflandırılması,
- **Yanlış Pozitif (YP):** sağlıklı bir hücrenin yanlışlıkla Defect olarak sınıflandırılması (yanlış alarm),
- **Yanlış Negatif (YN):** kusurlu bir hücrenin yanlışlıkla Normal olarak sınıflandırılması (kaçırılan kusur).

Bu dört nicelik, izleyen alt bölümlerde tanımlanan tüm başarımların metriklerinin temelini oluşturmakta ve bir arada karmaşıklık matrisi (4.5.3) aracılığıyla düzenli biçimde sunulmaktadır.

#### 4.5.1. Doğruluk, Hassasiyet, Geri Çağırma ve F1-Skoru

**Doğruluk (accuracy)**, en yaygın kullanılan başarımların metriği olup, doğru sınıflandırılan örneklerin toplam örnek sayısına oranını ifade eder (Denklem 4.17). Yorumlanması kolay bir ölçüt olmakla birlikte, sınıf dağılımının dengesiz olduğu durumlarda yanıltıcı olabilir; örneğin çoğunluk sınıfını her zaman tahmin eden bir model, gerçekte ayırt etme yeteneği olmasa dahi yüksek bir doğruluk değeri elde edebilir. Bu çalışmadaki veri kümesi dengeli olduğundan doğruluk anlamlı bir gösterge sunsa da, tek başına yeterli değildir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4.17)$$

**Hassasiyet (precision)**, modelin Defect olarak tahmin ettiği örneklerin ne kadarının gerçekte kusurlu olduğunu gösterir (Denklem 4.18). Yüksek hassasiyet değeri, modelin az sayıda yanlış alarm ürettiği anlamına gelir.

$$\text{Hassasiyet} = \frac{DP}{DP+YP} \quad (4.18)$$

**Geri çağırma (recall)**, duyarlılık olarak da adlandırılır ve gerçekte kusurlu olan örneklerin ne kadarının model tarafından doğru biçimde yakalandığını ifade eder (Denklem 4.19). Bu metrik, kusur tespiti açısından kritik önem taşır; çünkü düşük bir geri çağırma değeri, çok sayıda kusurlu hücrenin gözden kaçırıldığı (yanlış negatif) anlamına gelmektedir.

$$\text{Geri Çağırma} = \frac{DP}{DP+YN} \quad (4.19)$$

Hassasiyet ile geri çağırma arasında çoğu zaman bir ödünleşim bulunur: birini artırmaya yönelik müdahaleler diğerini düşürebilir. **F1-Skoru** bu iki metriğin harmonik ortalamasını olarak tek bir değerde dengeler (Denklem 4.20). Harmonik ortalama, iki değerden düşük olanı daha fazla cezalandırdığından, F1-Skoru ancak hassasiyet ve geri çağırmanın her ikisi

de yüksek olduğunda yüksek bir değer alır. Bu özelliği nedeniyle F1-Skoru, özellikle sınıf dengesizliğinin bulunduğu durumlarda doğruluktan daha bilgilendirici bir ölçüt olarak kabul edilir.

$$F_1 = 2 \frac{\text{Hassasiyet} \cdot \text{Geri Çağırma}}{\text{Hassasiyet} + \text{Geri Çağırma}} \quad (4.20)$$


#### 4.5.2. ROC Eğrisi ve AUC

Bir ikili sınıflandırıcının verdiği karar, 4.4 numaralı alt bölümde belirtildiği gibi bir karar eşiğine bağlıdır ve farklı eşik değerleri, doğru pozitif ile yanlış pozitif sayıları arasında farklı dengeler ortaya çıkarır. ROC (Receiver Operating Characteristic) eğrisi, tüm olası eşik değerleri boyunca Doğru Pozitif Oranı (duyarlılık, yani Denklem 4.19'da tanımlanan geri çağırma) ile Yanlış Pozitif Oranı arasındaki ilişkiyi görselleştirir. Bu bağlamda, sağlıklı hücrelerin doğru biçimde tanınma oranını veren özgüllük (Denklem 4.21) ve bunun tümleyeni olan Yanlış Pozitif Oranı (Denklem 4.22) tanımlanır.

$$\text{Özgüllük} = \frac{DN}{DP+YP} \quad (4.21)$$

$$YPO = \frac{YP}{YP+DN} = 1 - \text{Özgüllük} \quad (4.22)$$

ROC eğrisinde köşegen doğrusu, ayırt etme yeteneği olmayan rastgele bir sınıflandırıcıyı temsil eder; eğrinin sol üst köşeye (ideal nokta) yaklaşması ise modelin başarımının yüksek olduğunu gösterir (Şekil 4.10). Eğri altında kalan alan, AUC (Area Under the Curve – eğri altındaki alan) değeri ile nicelleştirilir. AUC, 0,5 (rastgele tahmin) ile 1,0 (kusursuz ayırt etme) arasında değer alır ve modelin sınıfları ayırt etme yeteneğini, belirli bir eşik değerinden bağımsız bir biçimde tek bir sayıyla özetler. Bu özelliği, AUC'yi farklı modellerin karşılaştırılmasında ve dengesiz veri kümelerinin değerlendirilmesinde özellikle değerli kılar.



Şekil 4.10. Örnek bir ROC eğrisi ve eğri altındaki alan (AUC)

#### 4.5.3. Karmaşıklık Matrisi

Karmaşıklık matrisi (confusion matrix), bir sınıflandırma modelinin tahminlerini gerçek etiketlerle karşılaştırarak özetleyen iki boyutlu bir tablodur. İkili sınıflandırma için  $2 \times 2$  boyutundaki bu matrister satırlar gerçek sınıfı, sütunlar ise model tarafından tahmin edilen sınıfı gösterir (Şekil 4.11). Köşegen üzerindeki hücreler doğru sınıflandırmaları (DP ve DN), köşegen dışındaki hücreler ise hatalı sınıflandırmaları (YN ve YP) temsil eder.

|              |        | Tahmin Edilen Sınıf         |                             |
|--------------|--------|-----------------------------|-----------------------------|
|              |        | Defect                      | Normal                      |
| Gerçek Sınıf | Defect | <b>DP</b><br>Doğru Pozitif  | <b>YN</b><br>Yanlış Negatif |
|              | Normal | <b>YP</b><br>Yanlış Pozitif | <b>DN</b><br>Doğru Negatif  |

Şekil 4.11. İkili sınıflandırma için karmaşıklık matrisinin yapısı

Karmaşıklık matrisinin temel üstünlüğü, önceki alt bölümlerde tanımlanan tüm başarımların bu dört hücreden türetilmesi ve modelin hatalarını sınıf bazında görünür kılmasıdır. Özellikle kusur tespiti gibi uygulamalarda, kaçırılan kusurları ifade eden yanlış negatifler ile yanlış alarmları ifade eden yanlış pozitiflerin ayrı ayrı izlenebilmesi, modelin zayıf yönlerinin belirlenmesi açısından büyük önem taşır. Böylece, yalnızca toplam doğruluk değerinin gizleyebileceği sınıfa özgü hatalar açık biçimde ortaya konabilir.

Sonuç olarak, bu alt bölümde ele alınan doğruluk, hassasiyet, geri çağırma, F1-Skoru, ROC eğrisi, AUC ve karmaşıklık matrisi; bir arada değerlendirildiğinde, geliştirilen sınıflandırma modellerinin başarımlarını çok yönlü bir biçimde ölçme olanağı sunmaktadır. Bu bölümde kuramsal temelleri ortaya konan derin öğrenme yöntemleri ve başarımların metrikleri, izleyen bölümlerde sunulacak deneysel çalışmaların ve elde edilen bulguların değerlendirilmesinde temel çerçeveyi oluşturacaktır.

## 5. MATERİYAL VE YÖNTEM

Bu bölümde, elektrolüminesans (EL) görüntüleri üzerinde fotovoltaiik (PV) hücre kusurlarının ikili olarak sınıflandırılması amacıyla geliştirilen yaklaşımın materyal ve metodu ayrıntılı bir biçimde sunulmaktadır. Üçüncü bölümde kuramsal temelleri ortaya konan derin öğrenme yöntemleri ve başarımların metriklerinin, bu çalışmadaki somut uygulaması ele alınmaktadır. Bu kapsamda öncelikle çalışmada kullanılan veri kümesi; kaynağı, sınıf dağılımı ve görüntü özellikleri bakımından tanıtılmaktadır. Ardından, ham panel görüntülerinden hücre düzeyinde sınıflandırmaya uygun bir veri kümesi elde edilmesini sağlayan ön işleme ve veri hazırlama adımları açıklanmaktadır. Sonraki kısımda, sınıflandırmada omurga olarak değerlendirilen derin öğrenme modellerinin mimarisi ve transfer öğrenme ile uyarlanması ele alınmaktadır. Bölümün son kısmında ise modellerin eğitim süreci, veri bölünmesi, hiperparametre ayarları ve optimizasyon yaklaşımı çerçevesinde sistematik biçimde aktarılmaktadır. Böylece, beşinci bölümde sunulacak deneysel bulguların elde edildiği yöntemsel çerçeve bütünüyle tanımlanmış olmaktadır. Bu tez çalışmasında iki veri kümesi kullanılmıştır: birincil veri kümesi, gerçek bir üretim hattından elde edilen ve ikili (Defect/Normal) olarak etiketlenen kendi elektrolüminesans hücre kümemizdir; ikincil olarak ise önerilen SE tabanlı modelin katkısını daha zorlu ve çok sınıflı bir ortamda sınamak amacıyla kamuya açık ELPV kıyaslama kümesi (kusur olasılığına göre dört sınıf) kullanılmıştır.

### 5.1. Veri Seti

Derin öğrenme tabanlı sınıflandırma modellerinin başarımları, büyük ölçüde kullanılan veri kümesinin niteliğine, temsil gücüne ve sınıflar arasındaki dengeye bağlıdır. Bu nedenle, geliştirilen yöntemin değerlendirilebilmesi için öncelikle veri kümesinin kapsamlı bir biçimde tanımlanması gerekmektedir. Bu çalışmada kullanılan veri kümesi, gerçek bir üretim hattından elde edilen EL panel görüntülerinden bölütlenmiş hücre görüntülerinden oluşmakta; her hücre görüntüsü kusurlu (Defect) veya sağlıklı (Normal) olmak üzere iki sınıftan birine ait olacak biçimde etiketlenmiştir. İzleyen alt başlıklarda veri kümesinin kaynağı, sınıf dağılımı ve görüntü özellikleri ayrıntılı olarak sunulmaktadır. Bu bölümde

önce birincil (kendi) veri kümesi (Alt bölüm 5.1.1–5.1.2), ardından doğrulama amacıyla kullanılan kamuya açık ELPV veri kümesi (Alt bölüm 5.1.3) tanıtılmaktadır.

### 5.1.1. Veri Setinin Tanımı ve Kaynağı

Çalışmada kullanılan görüntüler, GTC Güneş Sanayi ve Ticaret A.Ş.'ne ait üretim hattından elde edilmiştir. Üretim hattında yer alan EL cihazı Şekil 5.1'de yer almaktadır. Fotovoltaik panel üretimi yapan bu tesisin kalite kontrol hattında, lamination öncesi alınan elektrolüminesans panel görüntülerinden veri seti elde edilmiştir. Panel görüntüleri, hücrelere uygulanan doğru akım sonucu ortaya çıkan elektrolüminesans ışımının yüksek çözünürlüklü kameralarla kaydedilmesiyle, karanlık bir görüntüleme ortamında üretilmiştir. Söz konusu görüntülerin elde edildiği veri toplama ortamı ve görüntüleme düzeneği, bu tez çalışmasının dayandığı veri kümesini ortaya koyan çalışmalarda ayrıntılı biçimde betimlenmiştir (Aktaş vd., 2026).



Şekil 5.1. EL Görüntüleme Cihazı

Elektrolüminesans cihazından alınan görüntüler panel düzeyinde olduğundan ve her panel, ızgara yapısı içinde çok sayıda hücre barındırdığından, kusur analizinin hücre düzeyinde yapılabilmesi için panel görüntülerinin hücrelere ayrıştırılması gerekmektedir. Bu ayrıştırma işlemi, ilgili alt bölümde (5.2.1) açıklanan geliştirilmiş RLSA tabanlı

segmentasyon yaklaşımıyla gerçekleştirilmiş ve her hücre ayrı bir görüntü olarak kaydedilmiştir (Doğan, 2025). Bu tez çalışmasında, söz konusu hücre görüntü havuzundan, ikili sınıflandırma problemine uygun ve sınıflar arasında büyük ölçüde dengeli olacak biçimde, toplam 1040 hücre görüntüsünden (540 kusurlu, 500 normal) oluşan bir alt küme seçilerek kullanılmıştır.

Veri kümesindeki kusurlu (Defect) sınıf; mikro çatlaklar, hücre kırıkları, busbar kaynaklı kusurlar ve üretim sürecinden kaynaklanan yapısal hatalar gibi farklı kusur türlerini bir arada barındırmaktadır. İkinci bölümde ayrıntılı olarak ele alınan bu kusur türleri, EL görüntülerinde çoğunlukla koyu, sönük veya düzensiz bölgeler biçiminde kendini göstermektedir. Sağlıklı (Normal) sınıf ise herhangi bir yapısal, elektriksel veya malzeme kaynaklı kusur içermeyen, homojen ve düzenli bir ışımaya deseni sergileyen hücrelerden oluşmaktadır. Kusurlu sınıfın farklı kusur türlerini tek bir sınıf altında toplaması, problemin Defect/Normal biçimindeki ikili yapısıyla uyumludur ve modelin, kusur türünden bağımsız olarak kusurun varlığını saptamasını hedeflemektedir.

### 5.1.2. Sınıf Dağılımı ve Görüntü Özellikleri


Çalışmada kullanılan veri kümesi, 540 görüntü içeren Defect ve 500 görüntü içeren Normal sınıflarından oluşmakta olup toplam 1040 hücre görüntüsü içermektedir. Sınıf dağılımının büyük ölçüde dengeli olması, üçüncü bölümde belirtildiği üzere, modelin çoğunluk sınıfına yanlılık göstermesi riskini azaltmakta ve doğruluk metriğinin anlamlı bir gösterge olarak yorumlanabilmesine olanak tanımaktadır. Veri kümesinin sınıf bazında dağılımı Tablo 5.1'de sunulmaktadır

Tablo 5.1. Veri kümesinin sınıf dağılımı.

| Sınıf             | Etiket | Görüntü Sayısı |
|-------------------|--------|----------------|
| Normal (Sağlıklı) | 0      | 500            |
| Defect (Kusurlu)  | 1      | 540            |
| <b>Toplam</b>     |        | <b>1040</b>    |

Veri kümesindeki görüntüler,  $227 \times 227$  piksel boyutunda ve gri tonlamalı elektrolüminesans hücre görüntüleridir. EL görüntülerinin düşük kontrastlı ve dokusal

açından karmaşık yapısı, sınıflar arasındaki ayırt edici örüntülerin görece ince ayrıntılarda gizli olmasına yol açmaktadır. Şekil 5.2'de, her iki sınıfa ait örnek hücre görüntüleri sunulmaktadır. Görsellerden de izlenebileceği üzere, kusurlu hücrelerde busbar hatları boyunca uzanan koyu ve sönük bölgeler, çizgisel çatlak izleri ve düzensiz parlaklık dağılımları gözlenirken; sağlıklı hücreler görece homojen bir parlaklık ve düzenli bir yapı sergilemektedir. Bu görsel farklılıklar, evrimsel sinir ağlarının yerel dokusal örüntüleri öğrenerek iki sınıfı ayırt edebilmesi için elverişli bir temel oluşturmaktadır.




Şekil 5.2. Veri kümesinden örnek EL hücre görüntüleri: (a)–(d) kusurlu (Defect) hücreler; (e)–(h) sağlıklı (Normal) hücreler.

### 5.1.3. Doğrulama Veri Seti: ELPV

Önerilen modelin katkısının, ikili ayrımın görece kolay olduğu birincil veri kümesinin ötesinde, daha zorlu ve çok sınıflı bir ortamda da değerlendirilebilmesi amacıyla kamuya açık ELPV (Electroluminescence of PV cells) kıyaslama kümesi kullanılmıştır. ELPV, 44 farklı fotovoltaik modülden çıkarılmış 2.624 adet  $300 \times 300$  piksel, 8-bit gri tonlamalı hücre görüntüsünden oluşmakta ve her görüntü hem hücre tipiyle (monokristal/polikristal) hem de uzman değerlendirmesine dayalı bir kusur olasılığı değeriyle etiketlenmiş durumdadır (Buerhop-Lutz vd., 2018; Deitsch vd., 2019). Bu tez çalışmasında, ELPV kümesinin ön işleme sonrasında elde edilen ve toplam 2601 hücre görüntüsü içeren sürümü kullanılmıştır (ayrıntılı sınıf dağılımı Bölüm 5.1'de sunulmaktadır).


Bu çalışmada kusur olasılığı değerleri, literatürdeki yaygın kullanıma uygun biçimde dört düzeye ayrılarak problem dört sınıflı bir sınıflandırma olarak ele alınmıştır: kusursuz (0,0), düşük (0,33), orta (0,67) ve yüksek (1,0) kusur olasılığı. Sınıf dağılımı belirgin biçimde dengesizdir; özellikle orta (0,67) sınıfı yalnızca yaklaşık 106 örnek içermektedir. Bu dengesizlik ve kusur derecesinin ayırt edilmesindeki güçlük, veri kümesini birincil kümeye kıyasla çok daha zorlayıcı kılmakta ve modeller arasındaki başarımların farklarının belirginleşmesine olanak tanımaktadır. Veri kümesi <https://github.com/zae-bayern/elpv-dataset> adresinden erişilebilir durumdadır. Dört kusur-olasılığı sınıfına ait örnek monokristal hücre görüntüleri Şekil 5.3'te sunulmaktadır.



Şekil 5.3. ELPV veri kümesinden dört kusur-olasılığı sınıfına ait örnek monokristal hücre görüntüleri (soldan sağa: kusursuz 0,0; düşük 0,33; orta 0,67; yüksek 1,0).

## 5.2. Ön İşleme ve Veri Hazırlama

Ham EL panel görüntülerinin doğrudan sınıflandırma modellerine verilmesi mümkün olmadığından, görüntülerin model girişine uygun hâle getirilmesi için bir dizi ön işleme ve veri hazırlama adımı uygulanmıştır. Bu adımlar; panel görüntülerinin hücrelere ayrıştırılması, hücre görüntülerinin modelin beklediği biçime dönüştürülmesi ve eğitim verisinin veri artırma teknikleriyle çeşitlendirilmesi olmak üzere üç ana aşamadan oluşmaktadır. Söz konusu adımların genel iş akışı Şekil 5.4'te özetlenmekte; izleyen alt başlıklarda ise her aşama ayrıntılı olarak açıklanmaktadır.




Şekil 5.4. Hücre segmentasyonu, görüntü ön işleme ve veri artırma adımlarını içeren genel ön işleme ve veri hazırlama iş akışı

### 5.2.1. Hücre Segmentasyonu

Elektrolüminesans cihazından elde edilen görüntüler panel düzeyinde olup, paneldeki her hücrenin ayrı ayrı değerlendirilebilmesi için panel görüntülerinin hücrelere bölütlenmesi gerekmektedir. Panellerin farklı sayıda hücre ve busbar içermesi, değişken aydınlatma koşulları ve ızgara yapısındaki düzensizlikler, hücrelerin otomatik olarak ayrıştırılmasını zorlaştırmaktadır. Bu çalışmada hücre segmentasyonu, klasik Run-Length Smoothing Algorithm (RLSA) yönteminin morfolojik işlemler ve bağlı bileşen analizi ile güçlendirilmesiyle elde edilen geliştirilmiş bir RLSA tabanlı yaklaşımla gerçekleştirilmiştir (Aktaş vd., 2026; Doğan, 2025).

Söz konusu yaklaşımda, panel görüntüsü öncelikle gri tonlamaya ve ardından ikili (binary) görüntüye dönüştürülmekte; RLSA uygulanarak hücre bölgelerinin yatay ve dikey sürekliliği güçlendirilmektedir. Bu işlemin tek başına yetersiz kaldığı durumlarda, küçük nesnelerin elenmesi, hücre sınırlarını belirginleştiren morfolojik kapama (genişleme

ardından aşınma) işlemleri ve bağlı bileşen analizi uygulanmaktadır. Son aşamada, ilk geçerli hücrenin sınırlayıcı kutu koordinatları belirlenerek panelin tekrar eden geometrik yapısından yararlanılmakta ve her hücre, ilgi bölgesi (Region of Interest – ROI) mantığıyla ayrı bir görüntü olarak kesilip kaydedilmektedir. Bu yaklaşımın, busbar sayısından bağımsız olarak farklı panel yapılarındaki hücreleri yüksek doğrulukla ayrıştırabildiği ve 1040 panel görüntüsü üzerinde yürütülen değerlendirmede yaklaşık %97 düzeyinde bir segmentasyon başarısına ulaştığı bildirilmiştir (Doğan, 2025). Şekil 5.5'te panel görüntüsü ve panel görüntüsündeki hücrelerin otomatik ayrıştırma işlemi yer almaktadır. Kamuya açık ELPV veri kümesi ise hücre düzeyinde ve boyut ile perspektif bakımından normalize edilmiş biçimde sağlandığından, bu küme için ayrıca bir hücre segmentasyonu uygulanmamıştır.



Şekil 5.5. 60 Hücreli Panel'in EL görüntüsü ve her hücrenin ayrıştırılmış hali

### 5.2.2. Görüntü Ön İşleme

Segmentasyon sonucunda elde edilen hücre görüntüleri, sınıflandırma modellerinin girişine uygun hâle getirilmek üzere bir dizi ön işleme adımından geçirilmiştir. İlk olarak, gri tonlamalı (tek kanallı) EL görüntüleri, ImageNet üzerinde önceden eğitilmiş mimarilerin üç kanallı (RGB) giriş beklemesi nedeniyle, gri kanalın üç kez kopyalanmasıyla üç kanallı biçime dönüştürülmüştür. İkinci olarak, tüm görüntüler modelin giriş katmanının beklediği  $227 \times 227$  piksel boyutuna ölçeklenmiştir. Böylece tüm örneklerin tek tip bir giriş tensörü oluşturması sağlanmıştır.

Son olarak, modelin daha kararlı ve hızlı yakınsamasını sağlamak amacıyla piksel değerleri normalleştirilmiştir. Bu kapsamda piksel yoğunluk değerleri, Denklem 4.1 ile tanımlanan

minimum–maksimum normalleştirme yoluyla  $[0, 1]$  aralığına ölçeklenmiştir; burada  $x$  ham piksel değerini,  $x_{\min}$  ve  $x_{\max}$  ise sırasıyla en küçük ve en büyük piksel değerlerini göstermektedir. Önceden eğitilmiş ağların kullanıldığı durumlarda, giriş istatistiklerinin kaynak veri kümesiyle uyumlu olması için ImageNet ortalama ve standart sapma değerleriyle standartlaştırma da uygulanabilmektedir.

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4.1)$$


Burada:

$x$  orijinal veri değerini,  $x_{\min}$  veri kümesindeki en küçük değeri,  $x_{\max}$  veri kümesindeki en büyük değeri ve  $x'$  normalize edilmiş veri değerini göstermektedir.

### 5.2.3. Veri Artırma Teknikleri

Derin öğrenme modellerinin sınırlı büyüklükteki veri kümelerinde aşırı öğrenmeye eğilim göstermesi, veri artırma (data augmentation) tekniklerinin kullanımını gerekli kılmaktadır. Veri artırma, mevcut görüntülere çeşitli dönüşümler uygulayarak eğitim verisinin görsel çeşitliliğini yapay olarak artırır ve modelin genelleme yeteneğini güçlendirir (Shorten ve Khoshgoftaar, 2019). Bu çalışmada veri artırma amacıyla, EL hücre görüntülerinin geometrik yapısını koruyan dönüşümler tercih edilmiştir: 90, 180 ve 270 derecelik döndürmeler ile yatay ve dikey ekseninde yansıtma işlemleri uygulanmıştır. Bu dönüşümler, hücre üzerindeki kusur görüntülerinin konumdan bağımsız biçimde öğrenilmesini desteklemekte ve gerçekçi olmayan görüntüler üretmediğinden artırma kaynaklı yanlışlık riskini düşük tutmaktadır.

Veri artırma işlemlerinin yalnızca eğitim kümesine uygulanması, çalışmanın yöntemsel güvenilirliği açısından kritik önem taşımaktadır. Doğrulama ve test kümelerine herhangi bir artırma uygulanmamış; böylece bu kümelerdeki görüntülerin eğitim kümesindeki örneklerin dönüştürülmüş kopyalarıyla örtüşmesinin önüne geçilerek veri sızıntısı (data leakage) engellenmiştir. Bu sayede, modelin başarımı yalnızca daha önce görülmemiş özgün örnekler üzerinden, yansız bir biçimde değerlendirilebilmektedir. Uygulanan veri artırma tekniklerine ilişkin örnek görüntüler Şekil 5.6'da sunulmaktadır.



Şekil 5.6. Bir örnek hücre görüntüsüne uygulanan döndürme ve yansıtma tabanlı veri artırma sonuçları

### 5.3. Derin Öğrenme Modelinin Mimarisi

Bu çalışmada, EL görüntülerinde kusur tespiti problemi için transfer öğrenme tabanlı bir derin öğrenme modeli önerilmektedir. Önerilen model, ImageNet üzerinde önceden eğitilmiş bir ResNet50 omurgasının, kanal bazında dikkat sağlayan bir Sıkıştırma ve Uyarma (Squeeze-and-Excitation, SE) bloğu ile güçlendirilmesine dayanmaktadır. Önerilen modelin başarımı, aynı veri bölünmesi ve aynı eğitim koşulları altında üç temel (baz) transfer öğrenme modeliyle (ResNet50, EfficientNetB0, MobileNetV2) karşılaştırmalı olarak değerlendirilmektedir. İzleyen alt başlıklarda sırasıyla; baz modeller ve seçim gerekçesi, SE bloğuyla güçlendirilen önerilen model ve son olarak transfer öğrenme ile ince ayar süreci ayrıntılı biçimde açıklanmaktadır.

#### 5.3.1. Baz Modeller ve Seçim Gerekçesi

Çalışmada, farklı başarımlar maliyet dengeleri sunan ve fotovoltaik kusur tespiti alanında sıkça başvurulan üç evrişimli sinir ağı mimarisi temel (baz) model olarak değerlendirilmiştir. ResNet50, EfficientNetB0 ve MobileNetV2. Bu mimarilerin baz

alınması, hem önerilen modelin başarımının nesnel bir biçimde değerlendirilebilmesini hem de başarımla hesaplama maliyeti arasındaki denge ilişkisinin analiz edilmesine olanak sağlamaktadır.

ResNet50, artık (residual) bağlantıları sayesinde derin ağların kararlı biçimde eğitilebilmesini sağlayan ve transfer öğrenme uygulamalarında güçlü bir başvuru modeli olarak öne çıkan bir mimaridir (He vd., 2016). EfficientNetB0, derinlik, genişlik ve çözünürlüğü dengeli biçimde ölçeklendiren bileşik ölçekleme yaklaşımıyla, görece az sayıda parametre ile yüksek başarımla sunmaktadır (Tan ve Le, 2019). MobileNetV2 ise derinlemesine ayrılabilir evrişim işlemleri sayesinde düşük parametre sayısı ve hesaplama maliyetiyle dikkat çekmekte; bu hafif yapısı, fotovoltaik santrallerin sahada gerçek zamanlı ve gömülü denetimi gibi kaynak kısıtlı uygulamalar için önemli bir avantaj sağlamaktadır (Sandler vd., 2018).

Önerilen modelin omurgası olarak ResNet50 seçilmiştir. Bu tercihin başlıca gerekçesi; ResNet50'nin artık bağlantıları sayesinde derin temsil gücünü kararlı biçimde sunması, transfer öğrenmede yaygın ve güvenilir bir başvuru modeli olması ve ürettiği yüksek boyutlu öznetelik haritalarının ( $8 \times 8 \times 2048$ ) kanal bazında dikkat mekanizmalarıyla zenginleştirilmeye elverişli olmasıdır. Baz mimariler ile ResNet50'nin bir SE bloğuyla güçlendirilmesiyle elde edilen önerilen modelin temel özellikleri Tablo 5.2'de karşılaştırmalı olarak sunulmaktadır.

Tablo 5.2. Baz mimariler ve önerilen modelin temel özellikleri.

| Model                                 | Yaklaşık Parametre Sayısı | Öne Çıkan Yapı                     | Giriş Boyutu              |
|---------------------------------------|---------------------------|------------------------------------|---------------------------|
| ResNet50                              | $\approx 25,6$ milyon     | Artık bağlantılar                  | $227 \times 227 \times 3$ |
| EfficientNetB0                        | $\approx 5,3$ milyon      | Bileşik ölçekleme                  | $227 \times 227 \times 3$ |
| MobileNetV2                           | $\approx 3,5$ milyon      | Derinlemesine ayrılabilir evrişim  | $227 \times 227 \times 3$ |
| <b>Önerilen model (ResNet50 + SE)</b> | $\approx 26,1$ milyon     | Artık bağlantı + kanal dikkat (SE) | $227 \times 227 \times 3$ |

### 5.3.2. Önerilen Model: SE ile Güçlendirilmiş ResNet50

Önerilen model ImageNet üzerinde önceden eğitilmiş ResNet50 omurgasının ürettiği öznitelik haritalarının bir Sıkıştırma ve Uyarma (SE) bloğuyla kanal bazında yeniden ağırlıklandırılması ve elde edilen temsilin bir sınıflandırıcı aracılığıyla Defect/Normal olasılığına dönüştürülmesi esasına dayanmaktadır. Böylece ResNet50'nin güçlü artık temsil yeteneği, kanal dikkati sağlayan hafif bir bileşenle birleştirilerek kusur örüntülerinin ayırt edilmesi güçlendirilmektedir.

ResNet50 omurgasının ürettiği öznitelik haritaları ile sınıflandırıcı baş arasına bir SE bloğu eklenmiştir (Hu vd., 2018). Evrişimli katmanların ürettiği tüm kanalları eşit önemde değerlendiren geleneksel yaklaşımın aksine SE bloğu, her kanalın katkısını veriye bağlı olarak yeniden ağırlıklandırarak ayırt edici kanalların öne çıkarılmasını, bilgi taşımayan kanalların ise bastırılmasını sağlamaktadır. EL görüntülerinde kusur örüntülerinin yalnızca belirli öznitelik kanallarında belirginleşmesi nedeniyle, bu kanal bazında dikkat mekanizmasının modelin ayırt etme gücünü artırması beklenmektedir.


SE bloğu üç adımdan oluşmaktadır. Sıkıştırma (squeeze) adımında, C kanallı öznitelik haritalarının her bir kanalı, uzamsal boyutlar üzerinden küresel ortalama havuzlama ile tek bir betimleyici değere indirgenir (Denklem 4.2); burada  $X_c$ , c'inci kanalın  $H \times W$  boyutundaki öznitelik haritasını göstermektedir. Uyarma (excitation) adımında, elde edilen kanal betimleyici vektörü  $z$ ; biri indirgeme oranı  $r$  ile boyut düşüren ReLU etkinleştirmeli, diğeri özgün kanal sayısına geri yükselten sigmoid etkinleştirmeli iki tam bağlantılı katmandan geçirilerek  $[0, 1]$  aralığında kanal ağırlıkları  $s$  üretilir (Denklem 4.3); burada  $\delta$  ReLU fonksiyonunu,  $\sigma$  sigmoid fonksiyonunu,  $W_1$  ve  $W_2$  ise tam bağlantılı katmanların ağırlık matrislerini ifade etmektedir. Ölçekleme adımında ise her kanal, kendisine ait ağırlıkla çarpılarak yeniden ağırlıklandırılır (Denklem 4.4). Bu çalışmada indirgeme oranı  $r = 16$  olarak belirlenmiştir.

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (4.2)$$

$$s = \sigma(W_2 \cdot \delta(W_1 \cdot z)) \quad (4.3)$$

$$\tilde{x}_c = s_c \cdot X_c \quad (4.4)$$

SE bloğunca yeniden ağırlıklandırılan öznitelik haritaları, sınıflandırıcı başa aktarılmaktadır. Sınıflandırıcı baş; öznitelik haritalarını tek bir öznitelik vektörüne indirgeyen küresel ortalama havuzlama (global average pooling) katmanını, aşırı öğrenmeyi sınırlamaya yönelik bir seyreltme (dropout,  $p = 0,30$ ) katmanını ve girdinin Defect sınıfına ait olma olasılığını üreten, sigmoid aktivasyonlu tek nöronlu bir çıkış katmanını içermektedir. Önerilen modelin genel mimarisi ile SE bloğunun içyapısı Şekil 5.7'de sunulmaktadır.



Şekil 5.7. Önerilen modelin genel mimarisi: ImageNet ön-eğitilmiş ResNet50 omurgası, kanal dikkat sağlayan SE bloğu ve sigmoidli sınıflandırıcı. Sağda SE bloğunun içyapısı gösterilmektedir.

### 5.3.3. Transfer Öğrenme ve İnce Ayar Süreci

Hem önerilen model hem de baz modeller, ImageNet veri kümesi üzerinde önceden eğitilmiş ağırlıklarla başlatılmıştır (Krizhevsky vd., 2012; Pan ve Yang, 2010). Önceden eğitilmiş ağların bin sınıflı bir problem için tasarlanmış özgün sınıflandırıcı katmanları kaldırılarak, yerlerine bu çalışmadaki ikili sınıflandırma problemine uygun yeni

sınıflandırıcı yerleştirilmiştir. Bu transfer öğrenme yaklaşımı, kaynak alandan aktarılan kenar ve doku gibi genellenebilir görsel özniteliklerden yararlanarak, sınırlı büyüklükteki EL veri kümesinde dahi yüksek başarımlar elde edilmesini olanaklı kılmaktadır. Çok sınıflı ELPV değerlendirmesinde ise çıkış katmanı, dört kusur-olasılığı sınıfı için softmax aktivasyonlu dört nöronlu bir katman olarak düzenlenmiştir.

Önerilen model ve baz modeller, iki aşamalı bir ince ayar (fine-tuning) yordamıyla eğitilmiştir. İlk aşamada, önceden eğitilmiş omurganın tüm katmanları dondurularak yalnızca yeni eklenen bileşenlerin eğitilmesi sağlanmıştır; bu bileşenler önerilen modelde SE bloğu ile sınıflandırıcı baş, baz modellerde ise yalnızca sınıflandırıcı baştır. Bu aşamanın amacı, rastgele başlatılan yeni katmanların ürettiği büyük gradyan güncellemelerinin, omurganın değerli önceden öğrenilmiş özniteliklerini bozmasının önüne geçmektir. İkinci aşamada, omurganın üst katmanları kademeli olarak çözülmüş ve ağırların tamamı çok düşük bir öğrenme oranıyla yeniden eğitilmiştir.

Düşük öğrenme oranının tercih edilmesi, önceden öğrenilmiş genel özniteliklerin felaketle sonuçlanan unutma biçiminde bozulmasını önlemekte; aynı zamanda hem omurganın hem de SE bloğunun, EL görüntülerine özgü ince dokusal örüntülere uyarlanmasını sağlamaktadır. Böylece, kaynak alandan aktarılan genel görsel bilgi korunurken, modelin hedef alandaki kusur örüntülerine duyarlılığı artırılmıştır.

Kamuya açık ELPV kıyaslama kümesindeki çok sınıflı değerlendirmede, hesaplama kaynaklarının kısıtlı olması nedeniyle önceden eğitilmiş omurga sabit bir öznitelik çıkarıcı olarak kullanılmış (dondurulmuş) ve yalnızca SE bloğu ile sınıflandırıcı baş eğitilmiştir. Bu yaklaşım, SE bloğunun sabit omurga öznitelikleri üzerindeki katkısının yalıtılarak değerlendirilmesine de olanak tanımakta; söz konusu protokolde veri artırma uygulanmamıştır.

#### **5.4. Modelin Eğitim Süreci**

Bu bölümde hazırlanan veri kümesi ve mimari üzerinde modellerin eğitilmesine ilişkin yöntemsel ayrıntılar sunulmaktadır. Eğitim sürecinin yansız ve tekrarlanabilir biçimde yürütülmesi için izlenen veri bölünmesi, belirlenen hiperparametreler ile kullanılan kayıp

fonksiyonu ve optimizasyon algoritması sırasıyla açıklanmaktadır. Karşılaştırmanın adil olabilmesi amacıyla, değerlendirilen tüm mimariler aynı veri bölünmesi, aynı hiperparametre yapılandırması ve aynı eğitim yordamı kullanılarak eğitilmiştir.

#### 5.4.1. Eğitim-Doğrulama-Test Bölünmesi

Modellerin başarımı hem birincil GTC veri kümesinde hem de doğrulama amaçlı ELPV veri kümesinde, sınıf dağılımını koruyan tabakalı 5-katlı çapraz doğrulama (stratified 5-fold cross-validation) protokolü ile değerlendirilmiştir. Bu yaklaşımda veri kümesi, sınıf oranları her katta korunacak biçimde beş eşit parçaya (kata) ayrılmış; her yinelemede dört kat model eğitimi için, kalan bir kat ise test için kullanılmış ve süreç, her katın tam olarak bir kez test kümesi olacağı biçimde beş kez tekrarlanmıştır. Bölme işleminde kullanılan rastgele değer sabitlenerek sonuçların yinelenebilirliği ve tüm modellerin aynı kat bölünmesi üzerinde adil biçimde karşılaştırılabilmesi güvence altına alınmıştır. Eğitim aşamasında erken durdurma (early stopping) kararının verilebilmesi amacıyla, her katın eğitim verisinin küçük bir bölümü doğrulama alt kümesi olarak ayrılmıştır.

Test katının eğitim ve model seçim süreçlerinden tamamen ayrı tutulması, doğrulama alt kümesinin hem erken durdurma hem de nihai başarımlar raporlaması için birlikte kullanılmasından kaynaklanabilecek veri sızıntısının (data leakage) önlenmesi bakımından kritik önem taşımaktadır. Bu titiz ayırım sayesinde, raporlanan başarımlar değerlerinin modelin gerçek genelleme yeteneğini yansıtmaları güvence altına alınmıştır. GTC veri kümesi için raporlanan metrikler beş katın ortalaması ve standart sapması (ort.  $\pm$  std) biçiminde; karmaşıklık matrisleri ise beş kattan elde edilen kat-dışı (out-of-fold) tahminlerin birleştirilmesiyle sunulmuştur. GTC veri kümesinde 5-katlı çapraz doğrulama için sınıf bazında kat dağılımı Tablo 5.3'te verilmiştir.

Tablo 5.3. GTC veri kümesinde 5-katlı çapraz doğrulama için kat başına sınıf dağılımı (dört kat eğitim, bir kat test).

| Sınıf         | Eğitim (4 kat) | Test (1 kat) | Toplam |
|---------------|----------------|--------------|--------|
| Normal        | 400            | 100          | 500    |
| Defect        | 432            | 108          | 540    |
| <b>Toplam</b> | 832            | 208          | 1040   |

Dört sınıflı ELPV veri kümesinde de aynı tabakalı 5-katlı çapraz doğrulama protokolü uygulanmıştır. Belirgin sınıf dengesizliği nedeniyle bu veri kümesinde tüm katlardan elde edilen kat-dışı (out-of-fold) tahminler birleştirilerek nihai başarımlar hesaplanmıştır. Bölme öncesinde birebir yinelenen görüntüler tespit edilip çıkarılmış ve adil karşılaştırma için tüm modeller aynı kat bölünmesini kullanmıştır.

#### 5.4.2. Hiperparametre Ayarları

Modellerin eğitiminde kullanılan hiperparametreler, tüm mimariler için aynı tutularak adil bir karşılaştırma sağlanmıştır. Eğitim sürecini niteliksel olarak belirleyen temel tercihler; giriş boyutu, optimizasyon algoritması, kayıp fonksiyonu ve çıkış aktivasyonu olarak sabitlenmiştir. Öğrenme oranı, yığın boyutu, dönem sayısı ve erken durdurma gibi niceliksel hiperparametre değerleri ise deneysel olarak belirlenmiştir. Kullanılan hiperparametreler Tablo 5.4'te özetlenmektedir.

Tablo 5.4. Model eğitiminde kullanılan hiperparametreler.

| Hiperparametre                      | Değer                                       |
|-------------------------------------|---------------------------------------------|
| Giriş boyutu                        | $227 \times 227 \times 3$                   |
| Çıkış aktivasyon fonksiyonu         | Sigmoid                                     |
| Kayıp fonksiyonu                    | İkili çapraz entropi (binary cross-entropy) |
| Optimizasyon algoritması            | Adam                                        |
| Başlangıç öğrenme oranı             | $1e-4$                                      |
| İnce ayar öğrenme oranı             | $1e-5$                                      |
| Yığın boyutu (batch size)           | 16                                          |
| Dönem sayısı (epoch)                | 40 (20 + 20 fine-tuning)                    |
| Erken durdurma                      | 6 (transfer learning), 7 (fine-tuning)      |
| Değerlendirme yöntemi (GTC ve ELPV) | Tabakalı 5-katlı çapraz doğrulama           |
| Çıkış aktivasyonu (ELPV)            | Softmax (4 sınıf)                           |
| Kayıp fonksiyonu (ELPV)             | Kategorik çapraz entropi                    |
| Sınıf ağırlıklandırma (ELPV)        | Uygulandı (sınıf dengesizliği için)         |

### 5.4.3. Kayıp Fonksiyonu ve Optimizasyon Algoritması

İkili sınıflandırma problemine uygun olarak, modelin eğitiminde kayıp fonksiyonu olarak üçüncü bölümde tanımlanan ikili çapraz entropi (binary cross-entropy) kullanılmıştır (Denklem 4.15 ve 4.16). Bu kayıp fonksiyonu, modelin gerçek sınıfa düşük bir olasılık atadığı durumlarda hızla büyüyerek modeli doğru ve güvenilir olasılık tahminleri üretmeye yönlendirmektedir. Kaybın en aza indirilmesinde, uyarlanabilir öğrenme oranına sahip ve derin öğrenme uygulamalarında yaygın biçimde tercih edilen Adam optimizasyon algoritmasından yararlanılmıştır (Kingma ve Ba, 2015). Çok sınıflı ELPV probleminde ise kayıp fonksiyonu olarak kategorik çapraz entropi (categorical cross-entropy) kullanılmış; sınıf dengesizliğinin etkisini azaltmak amacıyla eğitimde sınıf ağırlıkları (class weights) dikkate alınmıştır.

Eğitim sürecinde aşırı öğrenmenin önüne geçmek amacıyla erken durdurma (early stopping) yönteminden yararlanılmıştır (Prechelt, 1998). Bu yöntemde, her dönem sonunda doğrulama kümesi üzerindeki kayıp izlenmiş; doğrulama kaybının önceden belirlenen sayıda dönem boyunca iyileşmemesi durumunda eğitim sonlandırılmış ve en düşük doğrulama kaybını veren dönemdeki ağırlıklar nihai model olarak korunmuştur. Böylece, modelin eğitim verisini ezberlemeye başladığı noktadan önce eğitimin durdurulması ve genelleme yeteneği en yüksek modelin seçilmesi sağlanmıştır. Eğitim sürecinin yürütüldüğü donanım ve yazılım ortamına ilişkin ayrıntılar, deneysel kurulumun ele alındığı beşinci bölümde (5.1) sunulmaktadır.

Bu bölümde tanıtılan veri kümesi, ön işleme adımları, model mimarisi ve eğitim süreci; beşinci bölümde sunulacak deneysel bulguların yöntemsel temelini oluşturmaktadır. Karşılaştırılan transfer öğrenme modellerinin eğitim ve test sonuçları ile bunların başarımlarını metrikleri açısından değerlendirilmesi, izleyen bölümde ayrıntılı olarak ele alınmaktadır.

## 6. BULGULAR VE TARTIŞMA

Bu bölümde önerilen Squeeze-and-Excitation bloğu ile güçlendirilmiş ResNet50 mimarisinin ve karşılaştırma amacıyla kullanılan üç baz modelin (ResNet50, MobileNetV2 ve EfficientNetB0) deneysel sonuçları sunulmaktadır. Değerlendirme iki ayrı veri seti üzerinde gerçekleştirilmiştir:

1. Gerçek bir üretim hattından (GTC Güneş Sanayi ve Ticaret A.Ş.) elde edilen ve kusurlu (Defects) ile normal (Normal) olmak üzere iki sınıf içeren özgün veri seti.
2. Literatürde yaygın olarak kullanılan ve dört sınıflı yapıya sahip ELPV veri seti (Deitsch vd., 2019).

GTC veri setinde ikili sınıflandırma görevi baz modeller tarafından dahi çok yüksek doğrulukla çözülebildiğinden, önerilen SE tabanlı iyileştirmenin katkısı özellikle daha zorlu bir ölçüt olan ELPV veri seti üzerinde ortaya konmaktadır. Bu bölüm; deneysel kurulumun, her iki veri seti için eğitim ve test sonuçlarının ve model karşılaştırmaları ile ablasyon çalışmasının sunulduğu alt bölümlerden oluşmaktadır.

### 6.1. Deneysel Kurulum

Tüm modeller, adil bir karşılaştırma sağlamak amacıyla aynı donanım ve yazılım ortamında, aynı ön işleme adımları ve aynı hiperparametre yapılandırması kullanılarak eğitilmiştir. Deneyler; Intel Core i9-14900 işlemci, 24 GB RAM ve NVIDIA GeForce RTX 4080 GPU ile donatılmış bir iş istasyonu üzerinde gerçekleştirilmiştir. Modeller, Spyder tümleşik geliştirme ortamında Python 3.12 ve TensorFlow 2.14 derin öğrenme çerçevesi kullanılarak geliştirilmiştir. Ön işleme ve görselleştirme aşamalarında NumPy 1.26, OpenCV 4.8, scikit-learn 1.3, Matplotlib 3.8 kütüphaneleri kullanılmıştır.

Modellerin tamamı ImageNet üzerinde ön eğitilmiş ağırlıklarla transfer öğrenme yaklaşımıyla eğitilmiştir. Eğitim her model için 40 epok boyunca sürdürülmüştür. Ayrıntılı hiperparametre yapılandırması Tablo 6.1'de verilmiştir.

Değerlendirme protokolü olarak, sınıf dağılımını koruyan 5 katlı tabakalı çapraz doğrulama (stratified 5-fold cross-validation) benimsenmiştir. Bu yaklaşımda veri seti beş eşit parçaya ayrılmış, her katta dört parça eğitim, bir parça test için kullanılmış ve süreç beş kez tekrarlanmıştır. Raporlanan tüm metrikler, beş katın ortalaması biçiminde sunulmaktadır. Eğitim ve doğrulama eğrileri beş katın ortalaması ile birlikte  $\pm$  standart sapma bandı gösterilerek çizdirilmiştir.

Deneylerde kullanılan veri setleri Bölüm 4'te ayrıntılı olarak tanıtılmıştır. GTC veri seti toplam 1040 görüntüden oluşmakta olup 540'ı kusurlu (Defects), 500'ü normal (Normal) sınıfına aittir. ELPV veri seti ise kusur olasılığına göre dört sınıfa ayrılmış toplam 2601 görüntüden oluşmaktadır: Kusursuz (0,0) 1493 görüntü (%57,4), Düşük (0,33) 288 görüntü (%11,1), Orta (0,67) 105 görüntü (%4,0) ve Yüksek (1,0) 715 görüntü (%27,5). Görüldüğü üzere ELPV veri seti belirgin bir sınıf dengesizliğine sahiptir; özellikle Orta (0,67) sınıfı yalnızca 105 örnek içermektedir. Model başarımı; GTC için doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1-skoru ve AUC metrikleriyle; dört sınıflı ELPV için ise doğruluk ile ortalama kesinlik, duyarlılık ve F1 metrikleriyle değerlendirilmiştir.

Tablo 6.1. Deneylerde kullanılan hiperparametre yapılandırması.


| Hiperparametre                | Değer                                                     |
|-------------------------------|-----------------------------------------------------------|
| Girdi görüntü boyutu          | $227 \times 227 \times 3$                                 |
| Yığın boyutu (batch size)     | batch size                                                |
| Optimizasyon algoritması      | Adam                                                      |
| Öğrenme oranı (learning rate) | $1e-4$                                                    |
| Kayıp fonksiyonu              | GTC: binary crossentropy / ELPV: categorical crossentropy |
| Epok sayısı                   | 40                                                        |
| Çapraz doğrulama              | 5 katlı tabakalı (stratified 5-fold)                      |
| Transfer öğrenme              | ImageNet ön eğitilmiş ağırlıklar                          |
| Veri artırma (augmentation)   | Döndürme ve yansıtma tabanlı                              |

## 6.2. GTC Veri Seti Üzerindeki Sonuçlar


Bu bölümde GTC veri seti üzerinde üç baz modelin (*ResNet50*, *MobileNetV2*, *EfficientNetB0*) 5 katlı çapraz doğrulama ile elde edilen eğitim ve test sonuçları sunulmaktadır. Önerilen *ResNet50+SE* modelinin GTC üzerindeki sonuçları da tablolara eklenmiştir. Baz modeller ve önerilen modelin test metrikleri ve karmaşıklık matrisleride tezde sunulmuştur.

### 6.2.1. Eğitim ve Doğrulama Eğrileri


Şekil 6.1-6.6 üç baz modelin 40 epok boyunca elde edilen eğitim/doğrulama doğruluk ve kayıp eğrilerini göstermektedir. Her üç model de hızlı bir yakınsama davranışı sergilemektedir. İlk beş epok içinde eğitim doğruluğu %99'un üzerine çıkmakta, doğrulama doğruluğu ise %98 seviyesine ulaşmaktadır. Eğitimin sonuna doğru eğitim doğruluğu tüm modellerde %100'e yaklaşmaktadır. Doğrulama doğruluğu ise platoya ulaştığı seviyede *ResNet50* için yaklaşık %99,0, *EfficientNetB0* için %98,8 ve *MobileNetV2* için %98,3 civarında seyretmektedir. Eğrilerdeki dar standart sapma bantları, katlar arasında tutarlı bir başarımla elde edildiğini göstermektedir.




Şekil 6.1. ResNet50 modeli eğitim ve doğrulama doğruluk eğrileri




Şekil 6.2. ResNet50 modeli eğitim ve doğrulama kayıp eğrileri




Şekil 6.3. EfficientNetB0 modeli eğitim ve doğrulama doğruluk eğrileri



Şekil 6.4. EfficientNetB0 modeli eğitim ve doğrulama kayıp eğrileri



Şekil 6.5. MobileNetV2 modeli eğitim ve doğrulama doğruluk eğrileri



Şekil 6.6. MobileNetV2 modeli eğitim ve doğrulama kayıp eğrileri

### 6.2.2. Aşırı Öğrenme Analizi

Aşırı öğrenme (overfitting) eğilimi, eğitim ve doğrulama kayıp eğrileri arasındaki fark üzerinden incelenmiştir (Şekil 6.2, 6.4 ve 6.6). Her üç modelde de eğitim kaybı epok ilerledikçe sıfıra yaklaşırken, doğrulama kaybı düşük ve büyük ölçüde kararlı bir seviyede kalmaktadır: ResNet50 için 0,02, EfficientNetB0 için 0,037 ve MobileNetV2 için 0,050. Doğrulama kaybının mutlak değerlerinin düşük olması ve eğitim-doğrulama kayıpları arasındaki farkın makul sınırlar içinde kalması, modellerin ciddi bir aşırı öğrenme sergilemediğini ve iyi bir genelleme başarımına sahip olduğunu göstermektedir.

Modeller arasında en belirgin (ancak yine de sınırlı) aşırı öğrenme eğilimi MobileNetV2'de gözlenmektedir; bu modelde doğrulama kaybı, yaklaşık 15. epoktan sonra hafif bir yükseliş eğilimi ve görece daha geniş bir standart sapma bandı sergilemektedir. ResNet50 ve EfficientNetB0 ise doğrulama kaybını epok boyunca daha kararlı biçimde korumaktadır. Bu davranışta, Bölüm 4'te açıklanan erken durdurma ve düzenlileştirme (regularization) stratejilerinin ve veri artırma tekniklerinin belirleyici bir rolü bulunmaktadır.

### 6.2.3. Karmaşıklık Matrisi ve Test Metrikleri

Baz modellerin GTC veri seti üzerindeki test başarımları Tablo 6.2'de özetlenmiştir. Değerler 5 katlı çapraz doğrulamanın ortalaması ve standart sapması olarak verilmiştir. ResNet50, %99,04 doğruluk ve 0,9908 F1-skoru ile en yüksek başarımlı elde etmiş; EfficientNetB0 (%98,94 doğruluk) ona çok yakın bir performans göstermiştir. MobileNetV2 ise %98,27 doğruluk ile görece daha düşük, ancak yine de yüksek bir başarımlı sergilemiştir. Tüm modellerde duyarlılık (recall) değerinin %98,8'in üzerinde olması, kusurlu hücrelerin neredeyse tamamının doğru biçimde tespit edildiğini göstermektedir. Bu durum üretim hattının kalite kontrolü açısından kritik bir özelliktir.


Tablo 6.2. GTC veri seti üzerinde baz modellerin test metrikleri

| Model                     | Doğruluk | Kesinlik | Duyarlılık | F1     | AUC    |
|---------------------------|----------|----------|------------|--------|--------|
| ResNet50                  | 0,9904   | 0,9837   | 0,9981     | 0,9908 | 0,9999 |
| EfficientNetB0            | 0,9894   | 0,9836   | 0,9963     | 0,9899 | 0,9994 |
| MobileNetV2               | 0,9827   | 0,9780   | 0,9889     | 0,9834 | 0,9990 |
| ResNet50+SE<br>(Önerilen) | 0,9923   | 0,9923   | 0,9923     | 0,9923 | 0,9923 |


Şekil 6.7-6.9, üç baz modelin karmaşıklık matrislerini göstermektedir. Matrisler, 5 katlı test tahminlerinin birleştirilmesiyle (toplam 1040 görüntü: 540 kusurlu, 500 normal) elde edilmiştir. Tablo 6.3'te bu matrislerin sayısal değerleri (DP: doğru pozitif, YN: yanlış negatif, YP: yanlış pozitif, DN: doğru negatif; pozitif sınıf = kusurlu) karşılaştırmalı olarak verilmiştir. ResNet50 yalnızca 1 kusurlu hücreyi kaçırmış ve 9 normal hücreyi hatalı biçimde kusurlu olarak sınıflandırmıştır. MobileNetV2 ise 6 kusuru kaçırmış ve 12 yanlış alarm üretmiştir; bu da onun görece daha düşük başarımlı tutarlıdır.

Tablo 6.3. GTC veri seti üzerinde baz modellerin karmaşıklık matrisi değerleri (5 kat toplamı).


| Model                  | DP (Kusur) | YN | YP | DN (Normal) |
|------------------------|------------|----|----|-------------|
| ResNet50               | 539        | 1  | 9  | 491         |
| EfficientNetB0         | 538        | 2  | 9  | 491         |
| MobileNetV2            | 534        | 6  | 12 | 488         |
| ResNet50+SE (Önerilen) | 540        | 0  | 8  | 492         |




Şekil 6.7. ResNet50 modeline ait karmaşıklık matrisi



Şekil 6.8. EfficientNetB0 modeline ait karmaşıklık matrisi



Şekil 6.9. MobileNetV2 modeline ait karmaşıklık matrisi




Şekil 6.10. ResNet50+SE (Önerilen) modeline ait karmaşıklık matrisi

#### 6.2.4. ROC Eğrisi ve AUC Değerlendirmesi


Modellerin ayırt etme kapasitesi ROC (Alıcı İşletim Karakteristiği) eğrileri ve AUC (eğri altında kalan alan) değerleri ile değerlendirilmiştir (Şekil 6.11-6.13). Üç baz modelin de AUC değeri 1'e son derece yakındır: ResNet50 için 0,9999, EfficientNetB0 için 0,9994 ve

MobileNetV2 için 0,9990. ROC eğrilerinin tamamı grafiğin sol üst köşesine yapışık bir seyir izlemektedir. Bu da modellerin kusurlu ve normal sınıfları neredeyse kusursuz biçimde ayırt ettiğini göstermektedir.


Bu sonuçlar GTC veri setindeki ikili sınıflandırma görevinin baz modeller tarafından bile üst sınıra (doygunluk noktasına) çok yakın bir başarımla çözüldüğünü açıkça ortaya koymaktadır. Dolayısıyla önerilen SE bloğu tabanlı iyileştirmenin katkısı bu veri seti üzerinde istatistiksel olarak anlamlı biçimde gözlemlenmemektedir. Bu durum çalışmanın daha zorlu ve dört sınıflı bir ölçüt olan ELPV veri seti ile genişletilmesinin (Bölüm 5.3) temel gerekçesini oluşturmuştur.



Şekil 6.11. ResNet50 modeline ait ROC eğrisi



Şekil 6.12. EfficientNetB0 modeline ait ROC eğrisi



Şekil 6.13. MobileNetV2 modeline ait ROC eğrisi


### 6.3. ELPV Veri Seti Üzerindeki Sonuçlar

Bu bölümde dört sınıflı ELPV veri seti üzerinde dört modelin (ResNet50, ResNet50+SE, MobileNetV2, EfficientNetB0) 5 katlı çapraz doğrulama ile elde edilen sonuçları


sunulmaktadır. ELPV veri setinde her hücre, kusur olasılığına göre dört sınıftan birine (Kusursuz 0,0 / Düşük 0,33 / Orta 0,67 / Yüksek 1,0) atanmaktadır. Belirgin sınıf dengesizliği ve sınıflar arası görsel benzerlik nedeniyle bu veri seti, GTC 'deki ikili göreve kıyasla çok daha zorlu bir değerlendirme ortamı sunmakta ve modeller arasındaki başarımların farklarını görünür kılmaktadır.

### 6.3.1. Eğitim ve Doğrulama Eğrileri


Şekil 6.14-6.21, dört modelin ELPV veri seti üzerindeki temsili (kat 0) eğitim ve doğrulama doğruluk/kayıp eğrilerini göstermektedir. GTC 'nin aksine, doğrulama doğruluğu belirgin biçimde daha düşük seviyelerde ve daha dalgalı bir seyirde platoya ulaşmaktadır; bu durum ELPV görevinin görece zorluğunu yansıtmaktadır. En yüksek doğrulama doğruluğuna, eğitim doğruluğunu %95 seviyesine taşıyabilen ve doğrulama doğruluğunu %76 civarında koruyan ResNet50+SE modeli ulaşmaktadır. Baz modeller ise daha düşük doğrulama doğruluğu (yaklaşık %66-%72 aralığında) sergilemektedir. Eğrilerdeki gürültünün, azınlık sınıflarının (özellikle 105 örnekli Orta sınıf) düşük temsil gücüyle ilişkili olduğu değerlendirilmektedir.




Şekil 6.14. ResNet50 modeli ELPV eğitim ve doğrulama doğruluk eğrisi




Şekil 6.15. ResNet50 modeli ELPV eğitim ve doğrulama kayıp eğrisi




Şekil 6.16. ResNet50+SE modeli ELPV eğitim ve doğrulama doğruluk eğrisi




Şekil 6.17. ResNet50+SE modeli ELPV eğitim ve doğrulama kayıp eğrisi




Şekil 6.18. EfficientNetB0 modeli ELPV eğitim ve doğrulama doğruluk eğrisi



Şekil 6.19. EfficientNetB0 modeli ELPV eğitim ve doğrulama kayıp eğrisi



Şekil 6.20. MobileNetV2 modeli ELPV eğitim ve doğrulama doğruluk eğrisi



Şekil 6.21. MobileNetV2 modeli ELPV eğitim ve doğrulama kayıp eğrisi

### 6.3.2. Aşırı Öğrenme Analizi

ELPV veri setinde aşırı öğrenme eğilimi, GTC 'ye kıyasla çok daha belirgindir. Tüm modellerde eğitim kaybı epok ilerledikçe düşmeye devam ederken, doğrulama kaybı bir platoya ulaşmakta veya yükselişe geçmektedir. Bu davranış en belirgin biçimde ResNet50+SE modelinde gözlenmektedir. Yaklaşık 10. epoktan sonra eğitim kaybı 0,1 seviyesine kadar inerken doğrulama kaybı 0,75'ten 0,9'a doğru bir sürüklenme göstermekte ve eğitim-doğrulama açığı genişlemektedir. Bu durum, yüksek kapasiteli modelin dengesiz veri setindeki çoğunluk sınıflarını giderek daha güçlü biçimde öğrenmesiyle açıklanabilir. Buna karşın baz modellerde eğitim-doğrulama açığı daha dardır. Ancak bu, daha iyi bir genellemeden çok, modellerin görevi daha sınırlı ölçüde öğrenebilmesinden kaynaklanmaktadır. Örneğin EfficientNetB0'da eğitim kaybı 0,69 seviyesinin altına inememektedir. Aşırı öğrenmeye rağmen ResNet50+SE, hem en yüksek doğrulama doğruluğunu hem de en yüksek F1 değerini elde etmektedir. Bölüm 4'te açıklanan erken durdurma, düzenleme ve veri artırma stratejileri bu eğilimi sınırlamakta, ancak dengesiz ve zorlu ELPV veri setinde tamamen ortadan kaldıramamaktadır.


### 6.3.3. Karmaşıklık Matrisi ve Test Metrikleri

Modellerin ELPV veri seti üzerindeki test başarımları Tablo 6.4'te özetlenmiştir. Önerilen ResNet50+SE modeli, %76,09 doğruluk ve 0,559 F1 değeriyle tüm modeller arasında en yüksek başarımlı elde etmektedir. Onu %70,17 doğrulukla MobileNetV2 izlemekte; düz ResNet50 (%66,24) ve EfficientNetB0 (%65,90) ise en düşük doğruluk değerlerini vermektedir. Bu tablo, GTC 'de gözlenemeyen model farklarının ELPV 'de belirgin biçimde ortaya çıktığını ve önerilen SE tabanlı iyileştirmenin bu zorlu ölçütte açık bir üstünlük sağladığını göstermektedir.


Tablo 6.4. ELPV veri seti üzerinde modellerin ortalama test metrikleri.

| Model                  | Doğruluk | Kesinlik | Duyarlılık | F1     |
|------------------------|----------|----------|------------|--------|
| ResNet50               | 0,6624   | 0,5367   | 0,5862     | 0,5340 |
| MobileNetV2            | 0,7017   | 0,5253   | 0,5554     | 0,5358 |
| EfficientNetB0         | 0,6590   | 0,5264   | 0,5695     | 0,5240 |
| ResNet50+SE (Önerilen) | 0,7609   | 0,5624   | 0,5561     | 0,5590 |


Şekil 6.22-6.25, dört modelin tahminlerinin birleştirilmesiyle elde edilen  $4 \times 4$  karmaşıklık matrislerini göstermektedir (toplam 2601 görüntü). Tüm modeller, çoğunlukta olan Kusursuz (0,0) ve Yüksek (1,0) sınıflarını görece başarıyla sınıflandırırken, azınlık sınıfları olan Düşük (0,33) ve özellikle yalnızca 105 örnek içeren Orta (0,67) sınıfında zorlanmaktadır. Önerilen ResNet50+SE modeli, Kusursuz sınıfında 1493 örneğin 1258'ini ve Yüksek sınıfında 715 örneğin 576'sını doğru sınıflandırarak çapraz köşede en güçlü yoğunlaşmayı sağlamaktadır.




Şekil 6.22. ResNet50 modeline ait ELPV karmaşıklık matrisi



Şekil 6.23. ResNet50+SE modeline ait ELPV karmaşıklık matrisi



Şekil 6.24. EfficientNetB0 modeline ait ELPV karmaşıklık matrisi




Şekil 6.25. MobileNetV2 modeline ait ELPV karmaşıklık matrisi

Modellerin sınıf bazlı F1 değerleri Tablo 6.5'te ve karşılaştırmalı olarak Şekil 6.26'da verilmiştir. ResNet50+SE modeli dört sınıfın üçünde- Kusursuz (0,8373), Düşük (0,4810) ve Yüksek (0,7994)- en yüksek F1 değerini elde etmektedir. Buna karşın, en az örneğe sahip Orta (0,67) sınıfında en düşük F1'i (0,1182) SE modeli vermektedir. Bu bulgu, SE bloğunun kanal-bazlı dikkat mekanizmasıyla iyi temsil edilen çoğunluk sınıflarının ayırt

ediciliğini belirgin biçimde artırdığını; ancak aşırı seyrek olan Orta sınıfının bu iyileşmeden pay alamadığını göstermektedir. Genel başarımda ise SE modelinin üstünlüğü net biçimde korunmaktadır.

Tablo 6.5. ELPV veri seti üzerinde modellerin sınıf bazlı F1 değerleri.

| Model                  | Kusursuz (0) | Düşük (0,33) | Orta (0,67) | Yüksek (1) |
|------------------------|--------------|--------------|-------------|------------|
| ResNet50               | 0,7521       | 0,4303       | 0,1800      | 0,7737     |
| ResNet50+SE (Önerilen) | 0,8373       | 0,4810       | 0,1182      | 0,7994     |
| MobileNetV2            | 0,7895       | 0,4107       | 0,1853      | 0,7578     |
| EfficientNetB0         | 0,7550       | 0,4214       | 0,1628      | 0,7568     |



Şekil 6.26. Modellerin ELPV veri setinde sınıf bazına F1 karşılaştırması

ELPV veri setinin dört sınıflı ve belirgin biçimde dengesiz yapısı nedeniyle, model başarımları bu veri seti için doğruluk, ortalama kesinlik/duyarlılık/F1, sınıf bazlı F1 ve karmaşıklık matrisleri üzerinden değerlendirilmiştir. Dengeli ikili GTC görevinde bilgilendirici olan ROC eğrisi ve AUC analizi, çok sınıflı ve yüksek dengesizliğe sahip problemlerde ayırt edici gücü sınırlı kalabildiğinden bu veri seti için ayrıca raporlanmamıştır.

## 6.4. Model Karşılaştırması

### 6.4.1. Önerilen Model ve Baz Modellerin Karşılaştırılması

Bu alt bölümde önerilen ResNet50+SE modeli ile üç baz model, her iki veri seti üzerinde karşılaştırmalı olarak değerlendirilmektedir (Tablo 6.6). GTC sonuçları Bölüm 5.2'den, ELPV sonuçları Bölüm 5.3'ten alınmıştır. GTC veri setinde tüm modeller doygunluğa yakın (%98- %99) ve birbirine çok yakın başarımlar sergilerken, ELPV veri setinde modeller belirgin biçimde ayrışmakta ve önerilen ResNet50+SE modeli %76,09 doğrulukla açık ara en iyi sonucu vermektedir.

Tablo 6.6. Önerilen model ile baz modellerin her iki veri seti üzerindeki karşılaştırması.

| Model          | GTC (Doğ. / F1 / AUC)    | ELPV (Doğ. / F1) | Açıklama       |
|----------------|--------------------------|------------------|----------------|
| ResNet50       | 0,9904 / 0,9908 / 0,9999 | 0,6624 / 0,5340  | Baz model      |
| EfficientNetB0 | 0,9894 / 0,9899 / 0,9994 | 0,6590 / 0,5240  | Baz model      |
| MobileNetV2    | 0,9827 / 0,9834 / 0,9990 | 0,7017 / 0,5358  | Baz model      |
| ResNet50+SE    | 0,9923 / 0,9923 / 0,9990 | 0,7609 / 0,5590  | Önerilen model |

Tablo 6.6, çalışmanın iki veri setli tasarımının gerekçesini açıkça ortaya koymaktadır: GTC 'nin doygun ikili görevinde modeller arası fark ayırt edilemezken, dört sınıflı ve dengesiz ELPV veri setinde önerilen model, en güçlü baz modele (MobileNetV2, %70,17) göre yaklaşık 6 puan, düz ResNet50'ye (%66,24) göre ise yaklaşık 9,85 puan daha yüksek doğruluk elde etmektedir. Bu sonuç, önerilen SE tabanlı iyileştirmenin katkısının özellikle zorlu koşullarda belirginleştiğini göstermektedir.

### 6.4.2. SE Bloğunun Katkısı

Önerilen katkının izole edilmesi amacıyla ResNet50 (SE 'siz) ile ResNet50+SE modellerinin doğrudan karşılaştırılmasına bakılmıştır. Bölüm 5.2'de gösterildiği üzere GTC veri setinde ikili görev doygunluğa ulaştığından, SE bloğunun bu veri setindeki katkısı ölçüm gürültüsünün içinde kalmakta ve anlamlı biçimde ayrıştırılamamaktadır. Bu nedenle SE bloğunun katkısı esas olarak, ayırt ediciliği daha yüksek olan dört sınıflı ELPV veri seti üzerinde değerlendirilmektedir (Tablo 6.7).

Tablo 6.7. SE bloğunun katkısına ilişkin ablasyon karşılaştırması (ResNet50 vs. ResNet50+SE).

| Veri Seti / Metrik | ResNet50 | ResNet50+SE | $\Delta$ (Fark) | Yorum             |
|--------------------|----------|-------------|-----------------|-------------------|
| GTC- Doğruluk      | 0,9904   | 0,9923      | -               | İyileşme          |
| ELPV- Doğruluk     | 0,6624   | 0,7609      | +0,0985         | Belirgin iyileşme |
| ELPV- F1           | 0,5340   | 0,5590      | +0,0250         | İyileşme          |
| ELPV- Kesinlik     | 0,5367   | 0,5624      | +0,0257         | İyileşme          |
| ELPV- Duyarlılık   | 0,5862   | 0,5561      | -0,0301         | Hafif düşüş       |

Tablo 6.7, SE bloğunun ELPV veri setinde doğruluğu 0,0985 (yaklaşık 9,85 puan), F1'i 0,0250 ve kesinliği 0,0257 artırdığını göstermektedir. Duyarlılıkta gözlenen hafif düşüş (-0,0301), esas olarak en seyrek sınıf olan Orta (0,67) sınıfındaki F1 düşüşünden. Diğer üç sınıfın tamamında SE modeli daha yüksek F1 değeri elde etmektedir.

Bu davranış, SE bloğunun teorik gerekçesiyle tutarlıdır (Hu vd., 2018). SE bloğu, kanallar arası bağımlılıkları modelleyerek özellik haritalarını kanal-bazlı olarak yeniden ölçeklemekte ve ayırt edici kanalları öne çıkarmaktadır. Bu kanal-bazlı dikkat mekanizması, yeterince temsil edilen sınıflarda ayırt ediciliği belirgin biçimde güçlendirmekte; ancak aşırı seyrek Orta sınıfında yeterli örnek bulunmadığından bu kazanç gerçekleşmemektedir. Genel başarımda ise SE bloğunun net ve tutarlı bir iyileştirme sağladığı sonucuna ulaşılmaktadır.

## 7. SONUÇLAR VE ÖNERİLER

Tezin bu son bölümünde, tez kapsamında elde edilen bulgular bütüncül biçimde değerlendirilmektedir. Çalışmanın bilimsel ve uygulamaya dönük katkıları, karşılaşılan sınırlılıklar ve gelecekte yürütülebilecek çalışmalara ilişkin öneriler sunulmaktadır.

### 7.1. Genel Değerlendirme

Bu tez çalışmasında, fotovoltaiik güneş hücrelerinde elektrolüminesans (EL) görüntüleri üzerinden kusur tespiti problemi ele alınmış ve Sıkıştır-Uyar (Squeeze-and-Excitation, SE) bloğu ile güçlendirilmiş bir ResNet50 mimarisi önerilmiştir. Önerilen model; ResNet50, MobileNetV2 ve EfficientNetB0 baz modelleriyle birlikte, bir üretim hattından elde edilen ikili sınıflı (GTC) veri seti ile kamuya açık ve dört sınıflı (ELPV) veri seti olmak üzere iki farklı veri seti üzerinde, 5 katlı tabakalı çapraz doğrulama protokolüyle karşılaştırmalı olarak değerlendirilmiştir.

GTC veri setinde tüm modeller %98-%99 aralığında, birbirine oldukça yakın ve doygunluğa ulaşmış bir başarımla sergilemiştir. Bu durum, kusurlu/normal ayırımına dayanan ikili sınıflandırma görevinin görece kolay olduğunu ve baz modellerin bile bu görevi neredeyse kusursuz biçimde çözebildiğini göstermektedir. Ancak söz konusu doygunluk, önerilen SE tabanlı iyileştirmenin katkısının bu veri seti üzerinde ölçülebilir biçimde ortaya konmasını engellemiştir. Modeller arasındaki farklar ölçüm gürültüsünün içinde kalmıştır. Buna karşın, belirgin sınıf dengesizliğine sahip dört sınıflı ELPV veri seti, modeller arasındaki farkları görünür kılan ayırt edici bir ölçüt işlevi görmüştür. Bu veri setinde önerilen ResNet50+SE modeli, %76,09 doğruluk ve 0,559 F1 değeriyle tüm modeller arasında en yüksek başarımla elde etmiş; düz ResNet50'ye kıyasla doğrulukta yaklaşık 9,85 puanlık bir iyileşme sağlamıştır. Bu bulgu, SE bloğunun kanal-bazlı dikkat mekanizmasının, zorlu ve dengesiz koşullarda ayırt edici özelliklerin öne çıkarılmasına somut bir katkı sunduğunu doğrulamaktadır (Hu vd., 2018).

Bununla birlikte, elde edilen bulgular tek yönlü bir üstünlük tablosu sunmamaktadır. SE bloğu, yeterince temsil edilen üç sınıfta (Kusursuz, Düşük ve Yüksek) en yüksek F1 değerini sağlarken, yalnızca 105 örnek içeren en seyrek sınıf olan Orta sınıfında F1 değerinin düşmesine yol açmıştır. Bu davranış, kanal-bazlı dikkat mekanizmasının iyi temsil edilen sınıflar lehine çalıştığını ve aşırı seyrek sınıfların bu kazanımdan yeterince pay alamadığını göstermektedir. Ayrıca çalışma, metodolojik açıdan önemli bir çıkarım sunmaktadır. Doygunluğa ulaşmış bir ölçüt, mimari katkıları gizleyebilmektedir. Bir katkının gerçek değeri ancak yeterince zorlu ve gerçekçi bir ölçüt üzerinde ortaya çıkabilmektedir. İki veri setli değerlendirme tasarımı bu nedenle çalışmanın güvenilirliği açısından belirleyici olmuştur.

Uygulama açısından bakıldığında, önerilen SE tabanlı ResNet50 modeli, EL görüntülerinde çok seviyeli kusur sınıflandırması için güçlü bir aday sunmaktadır. Özellikle üretim hattı kalite kontrol süreçlerinde, kusurların yalnızca varlığını değil şiddetini de ayırt edebilecek otomatik sistemlerin geliştirilmesine katkı sağlayabilecek bir potansiyel taşımaktadır.

## 7.2. Çalışmanın Katkıları

Bu tez çalışmasının en önemli katkısı, elektrolüminesans görüntülerinde fotovoltaiik hücre kusuru tespiti için Sıkıştır-Uyar bloğuyla güçlendirilmiş bir ResNet50 mimarisinin önerilmesi ve etkinliğinin deneysel olarak ortaya konmasıdır. Önerilen model ResNet50, MobileNetV2 ve EfficientNetB0 olmak üzere üç yaygın mimaridir. Bu mimariler aynı hiperparametre yapılandırması ve 5 katlı tabakalı çapraz doğrulama protokolü altında adil biçimde karşılaştırılmıştır. SE bloğunun net etkisi, ResNet50 ile ResNet50+SE modellerinin doğrudan karşılaştırılmasına dayanan bir ablasyon çalışmasıyla izole edilmiş ve ELPV veri seti üzerinde doğrulukta yaklaşık 9,85 puanlık bir iyileşme belgelenmiştir. Çalışmanın bir diğer önemli katkısı, değerlendirmenin biri gerçek bir üretim hattından elde edilen özgün ikili GTC veri seti, diğeri kamuya açık ve dört sınıflı ELPV veri seti olmak üzere iki tamamlayıcı veri seti üzerinde yürütülmesidir. Ayrıca SE bloğunun çoğunluk sınıflarında sağladığı kazanım ile en seyrek sınıf olan Orta sınıfındaki başarımların düşüşü birlikte ve şeffaf biçimde raporlanmıştır. Böylece kanal-bazlı dikkat mekanizmasının davranışı dürüst bir bakışla tartışılmıştır. Son olarak, çalışmanın gerçek bir üretim

hattından (GTC Güneş Sanayi ve Ticaret A.Ş.) elde edilen verilere dayanması, elde edilen sonuçların uygulamaya dönük değerini artırmaktadır.

### 7.3. Sınırlılıklar

Çalışmanın sonuçları değerlendirilirken çeşitli sınırlılıkların göz önünde bulundurulması gerekmektedir. Bunların başında veri setlerine ilişkin kısıtlar gelmektedir. GTC veri setinde ikili sınıflandırma görevinin görece kolay ve veri setinin sınırlı boyutlu (1040 görüntü) olması, SE bloğunun katkısının bu veri seti üzerinde ölçülememesine yol açmıştır. ELPV veri setinde ise belirgin bir sınıf dengesizliği söz konusudur. Özellikle yalnızca 105 örnek içeren Orta sınıfının aşırı seyrekliği, tüm modellerin bu sınıftaki başarımını düşürmüş ve seyrek sınıflara ilişkin metrikleri istatistiksel olarak daha az güvenilir kılmıştır.

Modelleme ve değerlendirme sürecine ilişkin sınırlılıklar da bulunmaktadır. ELPV veri setinde, özellikle yüksek kapasiteli ResNet50+SE modelinde eğitim-doğrulama açığının genişlediği, yani bir aşırı öğrenme eğiliminin ortaya çıktığı gözlemlenmiştir. Uygulanan düzenleme stratejileri bu eğilimi sınırlamış ancak tamamen ortadan kaldıramamıştır. Ayrıca deneyler tek bir hiperparametre yapılandırması ve 40 epok üzerinden yürütülmüştür. SE bloğu incelenmiş ancak alternatif dikkat mekanizmalarıyla karşılaştırma yapılmamıştır. Son olarak model iki veri setiyle sınırlı biçimde değerlendirilmiş; farklı EL veri setleri arasında çapraz genelleme ve gerçek saha koşullarında dağıtım denenmemiştir.

### 7.4. Gelecek Çalışmalar için Öneriler

Bu çalışma gelecekte yürütülebilecek çeşitli araştırma yönlerine işaret etmektedir. Öncelikle, sınıf dengesizliğinin daha etkili biçimde ele alınması önem taşımaktadır; odak kaybı (focal loss) (Lin vd., 2017), sınıf-dengeli örnekleme ve seyrek sınıflara yönelik hedefli veri artırma yaklaşımları değerlendirilebilir.

Mimari açıdan ECA (Efficient Channel Attention) gibi farklı dikkat modülleri ile dönüştürücü (transformer) tabanlı öz-dikkat mekanizmaları incelenebilir. Veri açısından, birden fazla EL veri setinin birleştirilmesi, çapraz veri seti genelleme testleri ve daha geniş

özgün veri kümelerinin oluşturulması modelin sağlamlığını güçlendirebilir. Modelin güvenilirliğini artırmak amacıyla, Grad-CAM ve dikkat görselleştirmeleri yoluyla kararların gerçek kusur bölgelerine dayanıp dayanmadığı doğrulanabilir.

## KAYNAKLAR

- Akram, M. W., Lib, G., Jina, Y., Chenc, X., Zhua, C. and Ahmada, A. (2020). Automatic detection of photovoltaic module defects in infrared images with isolated and develop-model transfer deep learning. *Solar Energy*, 198(November 2019), 175–186.
- Aktaş, M., Doğan, F. and Türkoğlu, İ. (2026). A hybrid CNN–Transformer approach for photovoltaic cell defect classification using electroluminescence imaging. *Sensors*, 26(8), 2450. <https://doi.org/10.3390/s26082450>.
- Buerhop-Lutz, C., Deitsch, S., Maier, A., Gallwitz, F., Berger, S., Doll, B. and Brabec, C. J. (2018). A benchmark for visual identification of defective solar cells in electroluminescence imagery. *European PV Solar Energy Conference and Exhibition (EU PVSEC)*. <https://doi.org/10.4229/35thEUPVSEC20182018-5CV.3.15>.
- Deitsch, 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(July 2018), 455–468.
- Dhimish, M. and Hu, Y. (2022). Rapid testing on the effect of cracks on solar cells output power performance and thermal operation. *Scientific Reports*, 12(12168), 1–11.
- Diallo, S., Melhaoui, F. Z., Rafi, M. and Ellassoudi, A. (2023). Understanding Photovoltaic Module Degradation: An Overview of Critical Factors , Models , and Reliability Enhancement Methods. *E3S Web of Conferences*, 00011.
- Diaz, J. J. V., Vlaminck, M., Lefkaditis, D., Vargas, S. A. O. and Luong, H. (2020). Solar Panel Detection within Complex Backgrounds Using Thermal Images Acquired by UAVs. *sensors*, 20(6219), 1–16.
- Dişli, F. (2018). Fotovoltaik Panellerin Üzerindeki Toz Yoğunluğunun Görüntü İşleme İle Tespiti.
- Doğan, F. (2025). Güneş panellerinde busbar sayısından bağımsız otomatik hücre segmentasyonu için geliştirilmiş RLSA tabanlı bir yaklaşım. *International Science and Art Research Center (ISARC) Bildiriler Kitabı*, 829–841.
- Dokur, E. ve Koç, M. (2019). Atmosferik Verilerden Görüntü İşleme Teknikleri İle Güneş Enerji Sistemleri İçin Bulutluluk Oranı Tayini.
- Fennessy, A., Onea, V., Walshe, J., Doran, J., Purcar, M. and Amarandei, G. (2025). Suitability of Existing Photovoltaic Degradation Models for Agrivoltaic Systems. *Energies*, 18(1937).

- Goodfellow, I., Bengio, Y. and Courville, A. (2016). Deep learning. MIT Press.
- Green, M. A. (2019). Photovoltaic technology and visions for the future. *Progress in Energy*, 1(1).
- He, K., Zhang, X., Ren, S. and Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T. and Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv:1704.04861*.
- Hu, J., Shen, L. and Sun, G. (2018). Squeeze-and-excitation networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7132–7141.
- IEA PVPS. (2025). Snapshot of Global PV Markets - 2025. Tarihinde adresinden erişildi [https://iea-pvps.org/snapshot-reports/snapshot-2025/?utm\\_source=chatgpt.com](https://iea-pvps.org/snapshot-reports/snapshot-2025/?utm_source=chatgpt.com)
- Iturralde Carrera, L. A., Garcia-Barajas, M. G., Constantino-Robles, C. D., Álvarez-Alvarado, J. M., Castillo-Alvarez, Y. and Rodríguez-Reséndiz, J. (2025). Efficiency and Sustainability in Solar Photovoltaic Systems : A Review of Key Factors and Innovative Technologies. *Eng.*, 6(50), 1–25.
- Jaffery, Z. A., Dubey, A. K., Irshad and Haque, A. (2017). Scheme for predictive fault diagnosis in photo-voltaic modules using thermal imaging. *Infrared Physics and Technology*, 83, 182–187.
- Kingma, D. P. and Ba, J. (2015). Adam A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*.
- Köntges, M., Kurtz, S., Packard, C., Jahn, U., Berger, K. A., Kato, K. and Iseghem, M. Van. (2014). Review of Failures of Photovoltaic Modules.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 25, 1097–1105.
- Lai, Y., Hsieh, C., Liao, T., Huang, C. and Kuo, C. J. (2025). Deep learning-based automatic defect detection of photovoltaic modules in infrared , electroluminescence , and red – green – blue images. *Energy Conversion and Management*, 332(September 2024), 119783.
- Le, P. T. and Nguyen, Q. L. (2025). Defect analysis and performance evaluation of photovoltaic modules using quantitative electroluminescence imaging. *Clean Energy*, 9(2), 177–189.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.

- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K. and Dollár, P. (2017). Focal loss for dense object detection. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2980–2988.
- Masita, K., Hasan, A., Shongwe, T. and Abu, H. (2025). Deep learning in defects detection of PV modules : A review. *Solar Energy Advances*, 5(September 2024), 100090.
- Nair, V. and Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning (ICML)*, 807–814.
- Pan, S. J. and Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359.
- Pathak, S. P., Patil, D. S. and Patel, S. (2022). Solar panel hotspot localization and fault classification using deep learning approach. *Procedia Computer Science*, 204, 698–705.
- Pierdicca, R., Malinverni, E. S., Piccinini, F., Paolanti, M., Felicetti, A. and Zingaretti, P. (2020). Deep Convolutional Neural Network For Automatic Detection Of Damaged Photovoltaic Cells. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(June 2018), 4–7.
- Pradhan, S., Kundu, S., Bhattacharjee, A., Mondal, S., Chakrabarti, P. and Maity, S. (2024). Thermal and optical analysis of industrial photovoltaic modules under partial shading in diverse environmental conditions. *Solar Energy*, 284(October 2023), 113097.
- Prechelt, L. (1998). Early stopping — but when? G. B. Orr and K.-R. Müller (Ed.), *Neural networks: Tricks of the trade içinde* (ss. 55–69). Springer.
- Puranik, V. E., Kumar, R. and Gupta, R. (2024). Unveiling the Potential of Electroluminescence Characteristics in Investigating Different Types of Defects and Degradations in c-Si PV Module. *SiliconPV Conf Proc 1, 1*, 1–6.
- Razykov, T. M., Ferekides, C. S., Morel, D., Stefanakos, E. and Ullal, H. S. (2011). Solar photovoltaic electricity : Current status and future prospects. *Solar Energy*, 85(8), 1580–1608.
- Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4510–4520.

Sayın, S. ve Koç, İ. (2011). Güneş Enerjisinden Aktif Olarak Yararlanmada Kullanılan Fotovoltaik (Pv) Sistemler Ve Yapılarda Kullanım Biçimleri. S.Ü. Müh.-Mim. Fak. Derg.

Sharma, P. and Mishra, R. K. (2025). Comprehensive study on photovoltaic cell 's generation and factors affecting its performance : A Review. Materials for Renewable and Sustainable Energy, 14(1), 1–28.

Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. Journal of Big Data, 6(1), 60.

Shukla, A., Kumar, S., Yadav, D., Singh, J., Bahadur, R., Hasnain, S. M. M. and Zairov, R. (2025). Measured and simulated energy , economics and environmental ( 3E ) performance of a building applied solar PV ( BAPV ) system using advanced open-source simulation software. Unconventional Resources, 7(May), 100199.

Singh, B. P., Goyal, S. K. and Kumar, P. (2021). Solar pv cell materials and technologies: Analyzing the recent developments. Materials Today: Proceedings, 43, 2843–2849.

SolarPower Europe. (2025). Global Market Outlook for Solar Power 2025-2029 Focus on India. [https://www.solarpowereurope.org/press-releases/new-report-world-installed-600-gw-of-solar-in-2024-could-be-installing-1-tw-per-year-by-2030?utm\\_source=chatgpt.com](https://www.solarpowereurope.org/press-releases/new-report-world-installed-600-gw-of-solar-in-2024-could-be-installing-1-tw-per-year-by-2030?utm_source=chatgpt.com)

Tan, M. and Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. International Conference on Machine Learning (ICML), 6105–6114.

URL-3. (2026). <https://www.energy.gov/cmei/systems/photovoltaics> (Erişim Tarihi: 29.03.2026).

URL-4. (2026). <https://sinovoltaics.com> (Erişim Tarihi: 27.04.2026).

Wang, J., Bi, L., Sun, P., Jiao, X., Ma, X., Lei, X. and Luo, Y. (2023). Deep-Learning-Based Automatic Detection of Photovoltaic Cell Defects in Electroluminescence Images. sensors, 23(297).

Woo, S., Park, J., Lee, J.-Y. and Kweon, I. S. (2018). CBAM: Convolutional block attention module. Proceedings of the European Conference on Computer Vision (ECCV), 3–19.

Ymer, E. T., Lemu, H. G. and Tolcha, M. A. (2025). Identification of the key material degradation mechanisms affecting silicon solar cells : Systematic literature review. Results in Engineering, 27(May), 106113.