



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

**HASARLI GÜNEŞ PANELİ HÜCRELERİNİN DERİN ÖĞRENME
YÖNTEMLERİYLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

YÜCEL KOÇ

TEMMUZ

**HASARLI GÜNEŞ PANELİ HÜCRELERİNİN DERİN ÖĞRENME
YÖNTEMLERİYLE SINIFLANDIRILMASI**

YÜCEL KOÇ

YÜKSEK LİSANS TEZİ
YENİLENEBİLİR ENERJİ VE UYGULAMALARI ANABİLİM DALI

Danışman
Dr. Öğr. Üyesi Yavuz ÜNAL

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TEMMUZ 2022

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Yücel KOÇ tarafından hazırlanan “Hasarlı Güneş Paneli Hücrelerinin Derin Öğrenme Yöntemleriyle Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Yenilenebilir Enerji ve Uygulamaları Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Yavuz ÜNAL

Bilgisayar Yazılımı Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Başkan : Doç. Dr. Turgut ÖZSEVEN

Bilgisayar Bilimleri Anabilim Dalı, Tokat Gaziosmanpaşa Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Üye : Doç. Dr. Ünal KURT

Elektrik Makineleri Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Tez Savunma Tarihi: 22/07/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada:

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu bildirir,
- Aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

(İmza)

Yücel KOÇ

22/07/2022

HASARLI GÜNEŞ PANELİ HÜCRELERİNİN DERİN ÖĞRENME YÖNTEMLERİYLE SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

YÜCEL KOÇ

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2022

ÖZET

Güneş enerjisi alternatif enerji kaynağıdır. Bir güneş enerjisi sisteminin temelini oluşturan güneş pilleri, esas olarak kristal silikon yapıdadır. Güneş panel hücrelerinde üretim esnasında veya kurulum sonrasında hatalar oluşabilir. Geleneksel görüntüleme yöntemleri ile güneş hücrelerindeki hataları tespit etmek çok zordur. Güneş hücrelerindeki bu hatalar, özel ekipmanlar ile çekilen elektrolüminans görüntüleri ile tespit edilebilmektedir. Bu çalışmada, derin öğrenme yöntemi ile güneş panel hücrelerinin elektrolüminans (EL) görüntülerinden hasar tespiti yapılmıştır. 6528 adet monokristal ve polikristal yapıdaki farklı güneş panel hücrelerinin elektrolüminans (EL) görüntüleri kullanılmıştır. Görüntü sınıflandırmada, hızlı ve başarılı sonuçlar elde etmek için derin öğrenme algoritmaları kullanılmıştır. 300x300 boyutundaki görüntüler sağlam, kırık ve çatlak şeklinde kategorilere ayrılarak evrişimli sinir ağı ile eğitilmiştir. Çalışmada CNN modellerinden Xception, Vgg16, Vgg19, Resnet50, DenseNet201 ve MobileNet kullanılmıştır. Monokristal ve polikristal güneş hücreleri, CNN modelleri ile ayrı ayrı analiz edilmiştir. Modellerin doğruluk ve sınıflandırma sonuçlarına göre evrişimli sinir ağı modelleri ile başarılı tespitler yapılmıştır.

Sayfa Adedi : 82
Anahtar Kelimeler : Derin öğrenme, Elektrolüminesans görüntü, Güneş panel hücreleri
Danışman : Dr. Öğr. Üyesi Yavuz ÜNAL

CLASSIFICATION OF DAMAGED SOLAR PANEL CELLS BY DEEP LEARNING METHODS

(M. Sc. Thesis)

YUCEL KOÇ

AMASYA UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2022

ABSTRACT

Solar energy is an alternative energy source. Solar cells, which form the basis of a solar energy system, are mainly of crystalline silicon structure. Errors may occur in solar panel cells during production or after installation. It is very difficult to detect errors in solar cells with conventional imaging methods. These errors in solar cells can be detected with electroluminescent images taken with special equipment. In this study, damage detection was performed from electroluminance (EL) images of solar panel cells using deep learning method. Electroluminance (EL) images of 6528 monocrystalline and polycrystalline different solar panel cells were used. In image classification, deep learning algorithms are used to obtain fast and successful results. Images with the size of 300x300 were divided into categories as intact, broken and cracked and trained with convolutional neural networks. In the study, CNN models Xception, Vgg16, Vgg19, Resnet50, DenseNet201 and MobileNet were used. Monocrystalline and polycrystalline solar cells were analyzed separately with CNN models. According to the accuracy and classification results of the models, successful determinations were made with convolutional neural network models.

Page Number : 82
Keywords : Deep learning, Electroluminescence image, Solar panel cells
Supervisor : Asst. Prof. Dr. Yavuz ÜNAL

ÖN SÖZ ve TEŞEKKÜR

Yüksek lisans eğitimimden itibaren desteğini esirgemeyen tez danışmanım Dr. Öğr. Üyesi Yavuz ÜNAL'a teşekkürlerimi sunarım. Tüm süreçte yanımda olan sevgili eşim ve çocuklarıma sabır ve destekleri için minnettarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ ve TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	x
ŞEKİLLER DİZİNİ	xii
RESİMLER DİZİNİ.....	xv
SİMGELER VE KISALTMALAR DİZİNİ	xvi
1. GİRİŞ.....	1
1.1. Literatür Taraması	3
2. GÜNEŞ ENERJİSİ.....	6
2.1. Fotovoltaik Sistemler	8
2.2. Fotovoltaik Sistem Elemanları	9
2.3. Fotovoltaik Hücre Yapısı	10
2.4. Fotovoltaik Hücre, Modül ve Dizi	11
2.5. Fotovoltaik Hücre Çeşitleri	11
2.6. Fotovoltaik Sistem Verimi Etkileyen Sebepler	13
2.6.1. Hot spot etkisi	13
2.6.2. Gölgeleme	13
2.6.3. Kablo arızaları.....	14
2.6.4. Mikro çatlaklar.....	14
2.6.5. Tozlanma.....	15
2.7. Elektrolüminans Görüntüleme	16

	Sayfa
3. MATERYAL VE YÖNTEM.....	18
3.1. Veri Setinin Oluşturulması.....	18
3.2. Veri Çoğaltma	19
3.3. Derin Öğrenme Geliştirme Platformu	20
3.4. Derin Öğrenme.....	21
3.5. Evrişimli Sinir Ağları	23
3.5.1. Giriş katmanı.....	24
3.5.2. Evrişim katmanı	24
3.5.3. Havuzlama katmanı	25
3.5.4. Düzleştirme katmanı	26
3.5.5. Tam bağlı katman	27
3.5.6. Seyreletme katmanı	27
3.5.7. Normalizasyon katmanı	28
3.5.8. Aktivasyon fonksiyonları.....	28
3.5.9. Çıkış katmanı	30
3.6. Transfer Öğrenme	31
3.6.1. Vgg16.....	32
3.6.2. Vgg19.....	33
3.6.3. Mobilenet	33
3.6.4. Xception.....	34
3.6.5. Resnet50.....	35
3.6.6. Densenet201.....	35
3.7. Başarım Ölçütleri	36
3.7.1. Karışıklık matrisi	36

	Sayfa
3.7.2. Doğruluk	37
3.7.3. Kesinlik	37
3.7.4. Duyarlılık	38
3.7.5. F1 skor	38
4. BULGULAR	39
4.1. MobileNet Analiz Sonuçları.....	39
4.2. Xception Analiz Sonuçları	44
4.3. VGG16 Analiz Sonuçları	49
4.4. Vgg19 Analiz Sonuçları	54
4.5. Resnet50 Analiz Sonuçları	59
4.6. DenseNet201 Analiz Sonuçları	64
4.7. Monokristal EL Görüntülerin Analiz Sonuçları.....	69
4.8. Polikristal EL Görüntülerin Analiz Sonuçları	70
5. SONUÇ VE ÖNERİLER.....	73
KAYNAKLAR	75
ÖZGEÇMİŞ	82

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 3.1. Veri setindeki görsellerin sınıflandırılmış dağılımı	18
Çizelge 3.2. Veri çoğaltma sonrası görsellerin sınıflandırılmış dağılımı	20
Çizelge 3.3. Karışıklık matrisi	37
Çizelge 4.1. Monokristal görüntülerde mobilenet modelinin eğitim doğruluğu	39
Çizelge 4.2. Monokristal görüntülerde mobilenet modelinin sınıflandırma raporu	39
Çizelge 4.3. Polikristal görüntülerde mobilenet modelinin eğitim doğruluğu.....	42
Çizelge 4.4. Polikristal görüntülerde mobilenet modelinin sınıflandırma raporu	42
Çizelge 4.5. Monokristal görüntülerde xception modelinin eğitim doğruluğu.....	44
Çizelge 4.6. Monokristal görüntülerde xception modelinin sınıflandırma raporu.....	45
Çizelge 4.7. Polikristal görüntülerde xception modelinin eğitim doğruluğu.....	47
Çizelge 4.8. Polikristal görüntülerde xception modelinin sınıflandırma raporu.....	47
Çizelge 4.9. Monokristal görüntülerde vgg16 modelinin eğitim doğruluğu	49
Çizelge 4.10. Monokristal görüntülerde vgg16 modelinin sınıflandırma raporu	50
Çizelge 4.11. Polikristal görüntülerde vgg16 modelinin eğitim doğruluğu.....	52
Çizelge 4.12. Polikristal görüntülerde vgg16 modelinin sınıflandırma raporu	52
Çizelge 4.13. Monokristal görüntülerde vgg19 modelinin eğitim doğruluğu	54
Çizelge 4.14. Monokristal görüntülerde vgg19 modelinin sınıflandırma raporu	55
Çizelge 4.15. Polikristal görüntülerde vgg19 modelinin eğitim doğruluğu.....	57
Çizelge 4.16. Polikristal görüntülerde vgg19 modelinin sınıflandırma raporu	57
Çizelge 4.17. Monokristal görüntülerde resnet50 modelinin eğitim doğruluğu.....	59
Çizelge 4.18. Monokristal görüntülerde resnet50 modelinin sınıflandırma raporu.....	59
Çizelge 4.19. Polikristal görüntülerde resnet50 modelinin eğitim doğruluğu	61
Çizelge 4.20. Polikristal görüntülerde resnet50 modelinin sınıflandırma raporu.....	62

Çizelge	Sayfa
Çizelge 4.21. Monokristal görüntülerde densenet modelinin eğitim doğruluğu	64
Çizelge 4.22. Monokristal görüntülerde densenet modelinin sınıflandırma raporu	64
Çizelge 4.23. Polikristal görüntülerde densenet modelinin eğitim doğruluğu.....	66
Çizelge 4.24. Polikristal görüntülerde densenet modelinin sınıflandırma raporu	66
Çizelge 4.25. Monokristal görüntülerde modellerin doğruluk raporu	69
Çizelge 4.26. Monokristal sağlam görüntülerde modellerin sınıflandırma raporu.....	69
Çizelge 4.27. Monokristal çatlak görüntülerde modellerin sınıflandırma raporu.....	70
Çizelge 4.28. Monokristal kırık görüntülerde modellerin sınıflandırma raporu.....	70
Çizelge 4.29. Polikristal görüntülerde modellerin doğruluk raporu	71
Çizelge 4.30. Polikristal sağlam görüntülerde modellerin sınıflandırma raporu	71
Çizelge 4.31. Polikristal çatlak görüntülerde modellerin sınıflandırma raporu.....	71
Çizelge 4.32. Polikristal kırık görüntülerde modellerin sınıflandırma raporu.....	72

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 2.1. Türkiye güneş enerjisi potansiyeli atlası.....	7
Şekil 2.2. Türkiye’deki güneş santralleri kurulu gücün yıllara göre dağılımı	7
Şekil 2.3. Türkiye’de 2021 yılı yenilenebilir enerji kaynaklarından üretilen enerji.....	8
Şekil 2.4. Fotovoltaik sistemin çalışma yapısı.....	9
Şekil 2.5. Fotovoltaik hücrelerin çalışma yapısı.....	10
Şekil 2.6. Fotovoltaik hücre, modül ve dizi	11
Şekil 2.7. Monokristal ve polikristal güneş panelleri	12
Şekil 2.8. Elektrolüminans sistemin yapısı.....	17
Şekil 3.1. Google colaboratory platformu.....	21
Şekil 3.2. Yapay zekâ, makine öğrenimi ve derin öğrenme ilişkisi.....	22
Şekil 3.3. Derin öğrenme süreci.....	22
Şekil 3.4. Cnn temel mimarisi.....	23
Şekil 3.5. Evrişim işlemi.....	24
Şekil 3.6. Ortalama değer havuzlama yöntemi	25
Şekil 3.7. En büyük değer havuzlama yöntemi.....	26
Şekil 3.8. Örnek bir düzleştirme işlemi	26
Şekil 3.9. Tam bağlı katman yapısı.....	27
Şekil 3.10. Seyreltme işlemi	28
Şekil 3.11. Sigmoid fonksiyonu ve türevi.....	29
Şekil 3.12. Relu fonksiyonu ve türevi.....	29
Şekil 3.13. Hiperbolik tanjant fonksiyonu ve türevi.....	30
Şekil 3.14. Transfer öğrenme mimarisi.....	31
Şekil 3.15. Vgg16 mimari yapısı	32

Şekil	Sayfa
Şekil 3.16. Vgg19 mimari yapısı	33
Şekil 3.17. Mobilenet genel mimarisi	34
Şekil 3.18. Xception mimari yapısı.....	34
Şekil 3.19. Derin sinir ağı ve resnet modeli.....	35
Şekil 4.1. Monokristal görüntülerde mobilenet modelinin eğitim ve test doğruluğu....	40
Şekil 4.2. Monokristal görüntülerde mobilenet modelinin eğitim ve test kayıp grafiği .	41
Şekil 4.3. Monokristal görüntülerde mobilenet modelinin karışıklık matrisi.....	41
Şekil 4.4. Polikristal görüntülerde mobilenet modelinin eğitim ve test doğruluğu	42
Şekil 4.5. Polikristal görüntülerde mobilenet modelinin eğitim ve test kayıp grafiği	43
Şekil 4.6. Polikristal görüntülerde mobilenet modelinin karışıklık matrisi	44
Şekil 4.7. Monokristal görüntülerde xception modelinin eğitim ve test doğruluğu.....	45
Şekil 4.8. Monokristal görüntülerde xception modelinin eğitim ve test kayıp grafiği ...	46
Şekil 4.9. Monokristal görüntülerde xception modelinin karışıklık matrisi	46
Şekil 4.10. Polikristal görüntülerde xception modelinin eğitim ve test doğruluğu	47
Şekil 4.11. Polikristal görüntülerde xception modelinin eğitim ve test kayıp grafiği	48
Şekil 4.12. Polikristal görüntülerde xception modelinin karışıklık matrisi	49
Şekil 4.13. Monokristal görüntülerde vgg16 modelinin eğitim ve test doğruluğu.....	50
Şekil 4.14. Monokristal görüntülerde vgg16 modelinin eğitim ve test kayıp grafiği.....	51
Şekil 4.15. Monokristal görüntülerde vgg16 modelinin karışıklık matrisi.....	51
Şekil 4.16. Polikristal görüntülerde vgg16 modelinin eğitim ve test doğruluğu	52
Şekil 4.17. Polikristal görüntülerde vgg16 modelinin eğitim ve test kayıp grafiği	53
Şekil 4.18. Polikristal görüntülerde vgg16 modelinin karışıklık matrisi	54
Şekil 4.19. Monokristal görüntülerde vgg19 modelinin eğitim ve test doğruluğu.....	55
Şekil 4.20. Monokristal görüntülerde vgg19 modelinin eğitim ve test kayıp grafiği	56

Şekil	Sayfa
Şekil 4.21. Monokristal görüntülerde vgg19 modelinin karışıklık matrisi.....	56
Şekil 4.22. Polikristal görüntülerde vgg19 modelinin eğitim ve test doğruluğu	57
Şekil 4.23. Polikristal görüntülerde vgg19 modelinin eğitim ve test kayıp grafiği	58
Şekil 4.24. Polikristal görüntülerde vgg19 modelinin karışıklık matrisi	58
Şekil 4.25. Monokristal görüntülerde resnet50 modelinin eğitim ve test doğruluğu	60
Şekil 4.26. Monokristal görüntülerde resnet50 modelinin eğitim ve test kayıp grafiği .	60
Şekil 4.27. Monokristal görüntülerde resnet50 modelinin karışıklık matrisi	61
Şekil 4.28. Polikristal görüntülerde resnet50 modelinin eğitim ve test doğruluğu.....	62
Şekil 4.29. Polikristal görüntülerde resnet50 modelinin eğitim ve test kayıp grafiği.....	63
Şekil 4.30. Polikristal görüntülerde resnet50 modelinin karışıklık matrisi	63
Şekil 4.31. Monoskristal görüntülerde densenet modelinin eğitim ve test doğruluğu....	65
Şekil 4.32. Monokristal görüntülerde densenet modelinin eğitim ve test kayıp grafiği .	65
Şekil 4.33. Monokristal görüntülerde densenet modelinin karışıklık matrisi.....	66
Şekil 4.34. Polikristal görüntülerde densenet modelinin eğitim ve test doğruluğu	67
Şekil 4.35. Polikristal görüntülerde densenet modelinin eğitim ve test kayıp grafiği	68
Şekil 4.36. Polikristal görüntülerde densenet modelinin karışıklık matrisi	68

RESİMLER DİZİNİ

Resim	Sayfa
Resim 1.1. Güneş panelinin elektrolüminans görüntüsü	2
Resim 2.1. Sıcak bölge etkisine maruz kalan güneş hücresi.....	13
Resim 2.2. Gölgelemiş güneş paneli.....	14
Resim 2.3. Mikro çatlak oluşmuş polikristal güneş hücresi	15
Resim 2.4. Tozlanmış güneş panelleri	16
Resim 2.5. Sağlam, çatlak ve kırık güneş hücreleri	17
Resim 3.1. Veri setindeki görsellerin örnek görünümü	19
Resim 3.2. Veri çoğaltma öncesi ve sonrası görüntüler.....	20

SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir

Simgeler

Açıklama

kw	Kilowatt
mw	Megawatt
tw	Terawatt
gw	Gigawatt
h	Saat
gb	Gigabyte

Kısaltmalar

Açıklama

YES	Yenilenebilir enerji sistemleri
GES	Güneş enerji sistemi
YEKDEM	Yenilenebilir enerji kaynaklarını destekleme
OECD	Ekonomik kalkınma ve iş birliği örgütü
MTEP	Milyon ton eş değer petrol
DA	Doğru akım
AA	Alternatif akım
FV	Fotovoltaik
MGN	Maksimum güç noktası
GEPA	Türkiye güneş enerjisi potansiyeli atlası
MİB	Merkezi işlem birimi
GİB	Grafik işlem birimi

CNN	Evriřimli sinir ađı
EL	Elektrolüminans
YEK	Yenilenebilir enerji kaynađı
DN	Dođru negatifler
DP	Dođru pozitifler
YN	Yanlıř negatifler
YP	Yanlıř pozitifler
CCD	Charged coupled device
CMOS	Complementary metal oxide semiconductor
DVM	Destek vektör makinesi

1. GİRİŞ

Günümüzde, yaşam standartlarının yükselmesi ile enerji kullanımında belirgin bir artış olmuştur. Yenilenebilir enerji kaynakları bu talepleri karşılamak için önemli bir rol oynayabilecektir. Bu kaynaklardan enerji üretim teknolojisi hızla gelişen ve gelecek vaat eden uygulamalarından birisi güneş paneli sistemleridir (Li ve Lam, 2007; Taherbaneh, Rezaie, Ghafoorifard, Rahimi ve Menhaj, 2010).


Fotovoltaik (FV) endüstrisi, kristal silikon güneş pilleri ve modüllerinin hakimiyetindedir. Güvenilir FV sistemi çalışması için, sahada kurulu FV modülleri üzerinde periyodik kontroller yapmak, zaman içindeki performanslarını değerlendirmek, sorunları önceden çözmek ve çalışma sırasında ortaya çıkabilecek sorunları teşhis etmek önemlidir. Modül arızası sadece bir güç kaybını değil, aynı zamanda sistem sahipleri için bir gelir kaybını da yeniden ortaya koymaktadır (Laronde, Charki ve Bigaud, 2010).

Fotovoltaik güç üretiminin veriminin azalması, malzeme kusurlarından, nakliye sırasında veya kurulum esnasında meydana gelen hasarlardan kaynaklanabilir (Koch, Weber, Fladung ve Sobottka, 2016). Güneş panel hücrelerindeki sorunlar, kurulumdan sonra hemen ortaya çıkabilir veya fotovoltaik modüller elektriksel, mekanik ve termal streslere maruz kaldığından daha uzun bir zaman çerçevesinde kendini gösterebilir (Pingel, Zemen, Frank, Geipel ve Berghold, 2009). Güneş pillerinde ortaya çıkan çatlaklar, fotovoltaik (FV) modülünün güç çıkışını azaltır (Grunow, Clemens, Hoffmann, Litzenburger ve Podlowski, 2005).

Elektrolüminesans (EL), yüksek çözünürlüklü görüntüler oluşturmamasından sebebiyle güneş hücreleri başta olmak üzere FV sistem bileşenlerindeki kusurların tespitinde yaygın olarak kullanılmaktadır. EL görüntüleme FV hücrelerdeki gözle görülemeyen çatlak, kırık gibi hasarları önceden tespit etmeyi sağlayan bir yöntemdir (Breitenstein ve diğerleri, 2011). EL testler üreticiler tarafından yapılmaktadır fakat FV panellerin nakliyesi, kurulum süreci ve çevresel koşullar nedeniyle sonradan hasarlar oluşabilmektedir

Fotovoltaik EL görüntüleri elde edebilmek için güneş paneline sabit voltaj verilerek kızılötesi ışık yayması sağlanır. Daha sonra kızılötesi lense sahip özel CCD kameralar ile bu

kızılötesi ışıklar yakalanır ve görüntü elde edilir. Güneş hücrelerinin kusurlu bölümleri normal olarak aktif olmayacağı için algılanan görüntülerde siyah olarak görünürler. Bu sayede, EL görüntüleri tespit edilen güneş hücrelerinin kusur içerip içermediğini belirlemek mümkündür (Tsai ve Luo, 2010). Resim 1.1’de bir güneş panelinin EL görüntüsü yer almaktadır (Chindarkkar, Priyadarshi, Shiradkar, Kottantharayil ve Velmurugan, 2020).



Resim 1.1. Güneş panelinin elektrolüminans görüntüsü

Derin öğrenme, verilen özellikleri insan etkisini olmadan kendisinin keşfedip değerlendirmelerde bulunabilen, yapay zekanın bir alt dalıdır. Günümüzdeki sektörlerin çok daha büyük verileri kullanmasıyla popülerliğini artırmıştır. Yapısındaki çok katmanlı sinir ağları sayesinde çok karmaşık problemleri bile çözebilme yeteneğine sahiptir.

EL görüntülerindeki çatlak, kırık şeklindeki kusurları manuel olarak belirlemek karmaşık ve zaman alıcı bir süreçtir (Acharya, Sahu ve Jena, 2021). Bu kontrolü otomatik hale getirmek amacıyla, evrişimli sinir ağı (CNN) kullanılarak güneş hücrelerindeki kusurların hızlı bir şekilde tespit edileceği bir model geliştirildi.

Derin öğrenme ile görüntüler piksel bazlı analiz edildiği için sınıflandırma yapabilmek diğer yöntemlere göre daha kolaydır. Bu çalışmada elde edilen fotovoltaik EL görüntüleri çatlak, kırık ve sağlam şeklinde kategorilere ayrılmıştır. Bu kategorilerdeki görüntüler ön eğitilmiş evrişimsel sinir ağı modelleri kullanılarak görüntülerin %80’i eğitim, %20’si de test

amacıyla kullanılmıştır. Sınıflandırma başarı ölçütleri ile değerlendirilmiştir. Çalışmada CNN modellerinden; VGG16, VGG19, Resnet50, DenseNet201, Xception ve MobileNet kullanılmıştır.

1.1. Literatür Taraması

Bu bölümde, derin öğrenme yöntemi kullanarak Elektrolüminans görüntü sınıflandırılmasının yapıldığı çalışmalardan bir kısmı sunulmuştur.

Buerhop-Lutz ve arkadaşları (2018), 2426 Elektrolüminesans veri setini derin öğrenme yöntemiyle eğitmek için kullanmışlar. Veri setinin %75'ini eğitim için (1.968 hücre) eğitim için ve %25'ini (656 hücre) test için kullanılmış. Derin öğrenme modellerinden VGG-19 modelini kullanarak %88,42 oranında doğruluk tespit etmişlerdir.

Nawei Zhang ve arkadaşları (2020), 2886 monokristal ve 2154 polikristal güneş panel hücrelerinden oluşan 300x300 piksel EL görüntülerini kullanmışlardır. Yapay sinir ağları yönteminden DAN modelini kullanarak %76,2 oranında doğruluk tahmin etmişlerdir.

Ahmad Maroof Karimi ve arkadaşları (2019), 3550 Elektrolüminans görüntü setini sağlam, çatlak ve kırık olarak üç sınıfa ayırmışlardır. Görüntü setini %80'ini test ve %20'sini de eğitim olarak kullanmışlardır. Destek vektör makinesi, Rastgele orman ve evrişimsel sinir ağları (CNN) öğrenme modellerini kullanmışlardır. Evrişimsel sinir ağları (CNN) öğrenme modeli ile %99,71 oranında doğruluk tespit etmişlerdir.

Qian ve arkadaşları (2020), iki farklı veri setini kullanarak fotovoltaiik hücreler üzerindeki mikro kırıkları tespit edebilmek için analizler yapmışlardır. Çalışmada kullanılan ilk veri setinde 452x452 piksel boyutunda 40 hasarlı, 80 sağlam fotovoltaiik hücre, diğer veri setinde 300x300 piksel boyutunda 44 farklı FV panelden alınan EL görüntüleri kullanılmıştır. İki veri seti de derin öğrenme modelleri ile eğitilerek mikro kırık tespiti için sistem eğitilmiştir. Sonradan eğitilen sistemin, CNN öğrenme modellerinden daha başarılı sonuçlar ortaya çıkardığı tespit edilmiştir.

Deitsch ve arkadaşları (2019), monokristal ve polikristal FV modülden oluşan 1968 EL görüntüsünü kullanarak, hasarlı hücreleri DVM ve CNN kullanarak sınıflandırmaya

çalışmışlardır. CNN öğrenme modeli %88,42, DVM ise %82,44 oranında doğruluk sonuçları bulmuşlardır.

Rahman ve arkadaşları (2021), EL görüntülerdeki mikro kırıkların tespiti için çalışma yapmışlardır. CNN modellerinden VGG16, VGG19, Inceptionv3, ResNet50v2 ve Xception kullanmışlardır. Monokristal hücrelerde %96,97, polikristal hücrelerde %97,06 doğruluk oranı ile başarılı sınıflandırma yapmışlardır.

Mantel ve arkadaşları (2019), FV panellerdeki hasarlı hücreleri saptayabilmek için 753 panelden alınan 47244 FV hücre ile çalışma yapmışlardır. Veri setindeki FV hücrelerin sorunları uzman kişiler tarafından hasar durumuna göre seviyelere ayrılmıştır. DVM ile yapılan analize göre %99,7 doğruluk oranı ile sınıflandırma yapılmıştır.

Demirci ve arkadaşları (2019), yaptıkları çalışmada 2624 FV hücre içeren EL görüntü veri setini, evrişimli sinir ağları kullanarak sınıflandırmışlardır. Az sayıda görüntü olduğu için transfer öğrenme yöntemi seçmişlerdir. Transfer öğrenimi için Alexnet, Googlenet, MobileNetv2 ve Squeezenet mimarilerini seçmişlerdir. FV hücrelerdeki hataları %75'in üzerinde doğrulama oranıyla tespit etmişlerdir.

Mathias ve arkadaşları (2020), güneş hücrelerini sağlam ve kırık şeklinde sınıflandırabilmek için DVM ve geri yayımlı sinir ağı kullanmışlardır. Sinir ağları 2000 EL görüntüsünden oluşan bir veri seti ile eğitmişler ve 300 test görüntüsünden oluşan bir veri seti ile test etmişlerdir. DVM ile %92,67, geri yayımlı sinir ağı ile %93,67 sınıflandırma doğruluğu elde etmişlerdir.

Chindarkkar ve arkadaşları (2020), Hindistan'ın farklı bölgelerinde bulunan FV santrallerinden toplanan EL görüntüleri derin sinir ağını eğitmek için kullanmışlardır. EL görüntülerini, düşük çözünürlüklü CMOS tabanlı kamera kullanılarak çekmişlerdir. Derin sinir ağı modeli yapılan sınıflandırmada güneş hücresindeki çatlakları tespit başarıları %98,59 olmuştur.

Fan ve arkadaşları (2022), polikristal güneş hücreleri üzerindeki mikro çatlakları tespit etmek için Resnet modelini kullanmışlardır. Bu yöntem sayesinde hasar algılama doğruluğunu %99,11 bulmuşlardır.

Winston ve arkadaşları (2021), FV panellerdeki sıcak noktanın etkisi incelemişlerdir. Mikro çatlaklardan ve sıcak noktalardan etkilenen farklı FV modüllerini tespit etmek için karşılaştırmalı bir arıza tespit yöntemi geliştirmişlerdir. Sınıflandırma işlemini, İleri Beslemeli Geri Yayılımlı Sinir Ağı ve DVM teknikleri kullanılarak gerçekleştirmişlerdir. İleri beslemeli geri yayılım sinir ağı için ortalama %87 ve DVM modeli ile %99 doğruluk oranı ile başarılı bir analiz yapmışlardır.




2. GÜNEŞ ENERJİSİ

Güneş Dünya'daki en mühim yenilenebilir enerji kaynağıdır. Güneş enerjisi temiz ve çevreci bir enerji kaynağı olduğundan dolayı fosil enerji kaynaklarına göre çok daha avantajlıdır. Türkiye coğrafi konumundan dolayı güneş enerjisi kapasitesi yönünden oldukça iyi durumdadır (Yılmaz, 2012).


Güneşten bir dakika içerisinde dünyaya ulaşan enerji, bir yıl içerisinde tüketilen enerjiden çok daha büyüktür. Bu derece önemli YEK'nın değerlendirilmesi için yapılan çalışmalar artmıştır. Fosil kaynakların çevreye zarar vermesinden dolayı ülkelerin yenilikçi enerji kaynaklarına geçişi hızlanmıştır. Güneş enerjisi kullanım oranı yıllar geçtikçe artış göstermektedir. 1970'li yıllardan sonra güneş enerjisinden elektrik üretimi hız kazanmıştır. Güneş enerji sistemlerinde teknolojik açıdan ilerleme meydana gelmiş ve maliyet açısından azalma olmuştur. GES'lerin temiz enerji kaynağı olmasından dolayı ve kurulum aşamasından sonra az maliyetle verimli üretim yapması güneş enerjisine olan ilginin yükselmesini sağlamaktadır (ETKB, 2021).

Ülkemizin coğrafi yapısı sebebiyle güneş enerjisi potansiyeline yüksektir. GEPA verilerine göre, ortalama yıllık toplam güneşlenme zamanı 2741,07 saat ve ortalama yıllık toplam güneş radyasyon miktarı ise 1527,46 kWh/m² olarak tespit edilmiştir. Şekil 2.1.'de Türkiye güneş enerjisi potansiyeli atlasında ülkemizdeki güneş enerji potansiyeli ve aylık ortalama global radyasyon değerleri görülmektedir. Türkiye'nin Güney Bölgeleri ve Güney Doğu Anadolu Bölgesi güneş enerjisi ve güneşlenme süreleri açısından büyük potansiyeli vardır (ETKB, 2021).



Şekil 2.1. Türkiye güneş enerjisi potansiyeli atlası

Ülkemizde güneş enerjisine olan ilgi son yıllarda gittikçe artmıştır. Şekil 2.2’de (ETKB, 2021) görüldüğü gibi 2014 yılından 2020 yılına kadar olan süre içerisinde güneş enerjisinden üretilen enerji miktarı sürekli artış göstermiştir.




Şekil 2.2. Türkiye’deki güneş santralleri kurulu gücün yıllara göre dağılımı

Son yıllarda lisanssız enerji kaynaklarının ürettiği enerji miktarı önemli ölçüde artmıştır. 2015 yılı içerisinde 0,4 GW olan enerji üretimi, 2021 yılında 7,4 GW düzeyine kadar çıkmıştır. 2021 yılı içerisinde ülkemizdeki lisanssız kurulu gücün %92’lik kısmını GES’ler oluşturmaktadır. Şekil 2.3’de yenilenebilir enerji kaynaklarından üretilen enerji miktarı

gösterilmiştir (Çolakoğlu, Aslan, İyikul ve Özenbaş, 2021). Ülkemizdeki sınırlı sayıda bulunan lisanssız GES'lerin artışına yardımcı olan faktörler sıralanmıştır:

- 2019 yılına kadar lisanssız GES'lerin YEKDEM alım garantilerinden faydalanabiliyor olması,
- GES'lerinin büyüklüğünün üretilen enerji verimine etkisinin olmaması,
- Güneş panel fiyatları ve GES işletme harcamalarının zamanla azalması,
- Ülkemizdeki güneş enerjisi potansiyelinin fazla olması,




Şekil 2.3. Türkiye’de 2021 yılı yenilenebilir enerji kaynaklarından üretilen enerji

2.1. Fotovoltaik Sistemler

FV sistemlerde güneş enerjisini elektrik enerjisine çevirebilmek amacıyla güneş panelleri kullanılır. FV panellerinden gelen DA çıkış olarak alınır. DA ile çalışan yükler doğrudan beslenebilir. Güneş ışıyım şiddeti gün içerisinde zamana göre değişiklik gösterir. Aynı zamanda mevsimsel şartlarda çok etkilidir. Bu yüzden üretilen elektrik miktarı yetersiz kalabilir veya üretilen elektrik ihtiyaçtan fazla olabilir. Elektrik enerjisinin ihtiyaçtan fazlası akülerde saklanır. Güneş panellerinin ürettiği elektrik enerjisi ihtiyaçtan az olması

durumunda akülerde bulunan enerji kullanılarak ihtiyaç giderilmiş olur. AA ile çalışan bir yük besleneceği durumlarda DA'yı AA'ya çevirecek bir evirici kullanılır (Bahtiyar, 2006). Şekil 2.4'de bir FV sistemin çalışma yapısı gösterilmiştir (Köroğlu, Teke, Bayındır ve Tümay, 2010). Şekildeki örnekte güneş panelleri, akü, şarj kontrol birimi, evirici ve belirli amaca yönelik yükler bulunmaktadır.



Şekil 2.4. Fotovoltaik sistemin çalışma yapısı

2.2. Fotovoltaik Sistem Elemanları


Bir FV sistem; güneş panelleri, evirici, batarya, şarj regülatörü ve farklı elektronik destek devreleri bir araya gelerek oluşur. Güneşin elektrik üretmek için yeterli olmadığı zamanlarda veya gece saatlerinde kullanılmak amacıyla sistemde batarya yer alır. Güneş panelleri gün içerisinde elektrik enerjisi üreterek bunu batarya içerisinde depolar ve güneş panellerinden üretilen enerjinin yetmediği durumlarda enerji bataryadan alınır.

Bataryanın aşırı şarj olması ve tamamen boşalarak zarar görmesini önlemek amacıyla kullanılan şarj kontrol birimi ise bataryanın durumuna göre güneş hücrelerinden gelen akımı keser. AA elektriğin kullanılması gereken durumlarda, sisteme bir evirici dahil edilerek

bataryadaki DA gerilim, 220 volta dönüştürülür. Bazı sistemlerde, güneş hücrelerinin MGN'de çalışmasını sağlayan MGN izleyici cihazı bulunur (Köroğlu, Teke, Bayındır ve Tümay, 2010).

2.3. Fotovoltaik Hücre Yapısı

FV hücreler üzerlerine ışık geldiği esnada uçlarında elektrik gerilimi meydana gelir. FV hücrenin oluşturduğu enerji, yüzey kısmına gelen güneş ışınımı kadardır. FV sistemlerin güneş ışığını absorbe edebilmesi için yarıiletken malzemeden oluşması gerekmektedir (Özçelik, 2016).



Şekil 2.5. Fotovoltaik hücrelerin çalışma yapısı


FV hücre, yarıiletkende n ve p tipi bölgeler meydana getirilerek oluşturulabilir. Şekil 2.5’de görüldüğü gibi meydana gelen n ve p tipi bölgelerin geçiş bölgesindeki p-n eklemi kesiminde, bir elektrik bölgesi oluşur. Yarıiletken malzemenin FV hücre gibi çalışması için eklem bölgesinde FV olayın yapılması gerekir.

FV işlem iki basamakta oluşur: eklem bölgesine ışık düşürülerek elektron-hol çiftleri oluşturulur. Sonra ise; elektron-hol çiftleri bölgedeki elektrik alan yardımı sayesinde birbirinden kopar. Bu sayede, birbirlerinden uzaklaşan elektron-hol çiftleri, FV hücrenin uçlarında bir enerji oluşmasını sağlar (Özçelik, 2016).

2.4. Fotovoltaik Hücre, Modül ve Dizi

Fotovoltaik (FV), güneşten gelen ışığı doğrudan elektriğe dönüştüren bir teknolojidir. Fotovoltaik hücrenin yapısı, klasik p-n diyotuna çok benzemektedir. Işık hücre üzerine geldiğinde, absorbe edilen fotonlar elektron sistemine aktarılır. Birleşme noktalarında yük taşıyıcılarının oluşmasını sağlar. Yük taşıyıcıları, bir sıvı elektrolit içindeki elektron-iyon çiftleri veya katı bir yarı iletken malzemedeki elektron deliği çiftleri olabilir. Mevcut devrenin direncinin karesi, elektriğe dönüştürülen güçtür. Fotonun kalan gücü hücrenin sıcaklığını yükseltir (Patel, 1999).

Tek bir FV hücresi küçük olduğu için ürettiği enerjide azdır. Daha fazla enerji üretmek için hücreler birbirine bağlanır. FV modülleri, çeşitli boyut ve güç çıkışında FV dizileri oluşturmak için birleştirilebilir ve bağlanabilir. Şekil 2.6'da FV hücre, modül ve dizi görüntüleri yer almaktadır (Li, 2011).




Şekil 2.6. Fotovoltaik hücre, modül ve dizi

2.5. Fotovoltaik Hücre Çeşitleri

FV sistemler, güneşten gelen ışığı emer ve elektrik enerjisine dönüştürür. Monokristal ve polikristal en fazla tercih edilen panel türleridir. Her ikisi de elektrik enerjisi üretir fakat aralarında dikkat edilmesi gereken bazı önemli farklılıklar bulunmaktadır.

Monokristal ve polikristal güneş panelleri, dayanıklı olduğu için silikondan yapılır. Temel değişiklik, kullanılan silikon güneş hücresinin türüdür. Monokristal güneş panelleri, tek bir silikon kristalinden yapılmıştır. Polikristal güneş panelleri ise eritilmiş birçok silikon parçasından meydana gelen güneş hücreleridir.

Monokristal güneş panelinde, güneş hücreleri oluşturmak için, silikon çubuklar halinde biçimlendirilerek dilimlere bölünür. Tek bir kristal silikondan meydana gelen güneş panellerine monokristal adı verilir. Güneş hücresi, tek bir kristalden yapıdan meydana geldiği için elektronlar hareket için çok fazla alana sahiptir. Bu da monokristal panellerin verimliliğini arttırmaktadır. Şekil 2.7’de monokristal ve polikristal güneş panelleri gösterilmektedir (Yılmaz, 2021).



Şekil 2.7. Monokristal ve polikristal güneş panelleri


Monokristal panel hücreleri çoğunlukla siyahtır. Polikristal paneller hücreleri de genellikle mavidir. Panelin hangi çeşit olduğu sadece rengine bakılarak tespit edilmez. Polikristal panel hücrelerine bakıldığında dalgalı bir yapı mevcuttur. Monokristal panel hücreleri ise düz bir yapıya sahiptir. Monokristal yapıdaki güneş hücreleri, polikristal hücrelerine kıyasla daha yüksek verime sahiptir. Bunun yanında monokristal panel hücreleri de polikristal panel hücrelerine göre daha maliyetlidir (Yılmaz, 2021).

2.6. Fotovoltaik Sistem Verimi Etkileyen Sebepler

2.6.1. Hot spot etkisi

Güneş panellerinin üzerine düşen güneş enerjisinin yaklaşık %80 ile %90'ı ısıya dönüşür. Bundan dolayı güneş enerjisi sistem tasarımları yapılırken güneş panellerinin soğuma ihtiyacının da düşünülmesinde fayda vardır.

Eğer güneş panelinin içindeki seri bağlı hücrelerden herhangi birisinin ürettiği akım diğer hücrelerden daha düşükse, panel yük durumuna geçebilir ve gerilim ters dönebilir. Böyle bir durumda güneş panelimiz yük durumunda çalıştığı için hücrenin sıcaklığı yükselmeye başlayacaktır, hatta yanmaya bile başlayabilir, işte bu duruma hot spot etkisi denilmektedir. Bu etki altında kalan hücrenin sıcaklığı 150 derecenin üzerine çıkarsa da tamamen bozulur (Uyar, 2015). Resim 2.1'de sıcak bölge sorununa maruz kalan bir güneş panel hücresi gösterilmiştir (Kaz, 2021).



Resim 2.1. Sıcak bölge etkisine maruz kalan güneş hücresi

2.6.2. Gölgeleme

FV sistemler, tam veya kısmi olarak gölgeleme yüzünden çok fazla verim kaybı yaşamaktadır. Gün içerisindeki güneşin hareketi gölgelemenin düzeyini etkilemektedir. Yapılan çalışmalar neticesinde, gölgelemenin performansı çok azalttığı kabul edilmiştir. Gölgelemenmeden kaynaklanan sorunu en aza indirmek için DA-DA iyileştiriciler, mikro

eviriciler ve bypass diyotlar gibi deęişik teknolojik gelişmeler üzerine çalışmalar artmıştır (Salvadores ve Francisco, 2015).



Resim 2.2. Gölgeleşmiş güneş paneli

Güneş panellerinden daha fazla performans alabilmek için resim 2.2’deki gibi gölge sorunlarına dikkat edilmesi gerekmektedir (Solar Çatı, 2021).


2.6.3. Kablo arızaları

Kablo arızaları, FV sistemde yer alan DA ve AA kablolardaki sorunlar yüzünden oluşmaktadır. FV sistem tasarlanırken kabloların boyutlandırılması önemlidir. FV paneller DA kablolar yardımıyla eviriciye bağlanmalıdır. İletken kabloların akım taşıma kapasitesi ve ortaya çıkabilecek gerilim düşümü, kabloların belirlenmesindeki en önemli kısımdır. (Deniz, 2013). Kablolar hava şartları ve çevresel etkenlerden dolayı zaman içerisinde yıpranır ve korozyona uğrar. Bu sorunlar üretilen gücün azalmasına, kısa devrenin meydana gelmesine ve ileri zamanlarda yangın çıkmasına bile sebep olabilir (Elektrikport, 2021).

2.6.4. Mikro çatlaklar

Mikro çatlaklar, güneş hücrelerinde oluşan çıplak gözle görülemeyen bir hata türüdür. Güneş hücrelerinde mikro çatlakların oluşması, yalnızca yapısal bütünlüğü bozmaz, aynı zamanda mikro çatlaklar içeren güneş hücreleri yüzünden panellerde yangın tehlikesi oluşturabilecek sıcak noktaların oluşmasına sebep olabilir. Üretim hattından çıkan güneş hücrelerinin

ortalama %5 ile %10'u mikro çatlak içerebilir. Aynı zamanda çevresel koşullarda güneş hücrelerinde mikro çatlakların oluşmasına sebep olabilir. Resim 2.3'de polikristal bir güneş hücresinde oluşan mikro kırık gösterilmektedir (Teo ve Abdullah, 2018).



Resim 2.3. Mikro çatlak oluşmuş polikristal güneş hücresi

2.6.5. Tozlanma

FV panel yüzeyinin kirlenmesi veya panel yüzeyinde kar birikmesi sebebiyle emilen güneş radyasyonu azalmaktadır. Bunun sonucunda üretilen enerji miktarında düşüş yaşanmaktadır. Araştırma sonuçları, tozlanma nedeniyle panel yüzeylerinin kirlenmesi verimi %15'e yakın oranda düşürmektedir (Maghami ve diğerleri, 2016). Resim 2.4'de tozlanmış güneş panelleri yer almaktadır (Gürbüz, 2018).




Resim 2.4. Tozlanmış güneş panelleri

2.7. Elektrolüminans Görüntüleme


Elektrolüminans (EL) görüntüleme, fotovoltaik modüllerin görsel muayenesi için kullanılan bir tekniktir (Köntges ve diğerleri, 2014). Fotovoltaik modüllerin yüksek çözünürlüklü görüntülerini yakalamayı ve kusurların tanımlanmasını sağlar (Bothe ve diğerleri, 2006).

Şekil 2.8'deki görüntüde (Tsai, Wu ve Li, 2012) elektrolüminans görüntülemenin çalışma mantığı gösterilmiştir. Kızılötesi filtreye sahip özel kamera ile karanlık ortamda güneş panelinin görüntüsü alınarak bilgisayar ortamına aktarılmaktadır. Oluşan elektrolüminans görüntüler durumlarına göre değerlendirilerek hasarlı olup olmadıkları tespit edilmektedir.



Şekil 2.8. Elektrolüminans sistemin yapısı

Resim 2.5’deki görüntüde (Buerhop-Lutz ve diğerleri, 2018) Elektrolüminans test sonrası elde edilen sağlam, çatlak ve kırık durumdaki güneş hücreleri bulunmaktadır. Güneş hücrelerinin sağlamlığını dışarıdan herhangi bir ekipman olmadan tespit etmek çok zordur. O yüzden bu görüntüleme sayesinde güneş hücrelerindeki kusurları bularak değiştirmek, güneş panellerinden alınan veriminde artmasını sağlamaktadır. İleri zamanlarda oluşabilecek daha büyük sorunların önüne geçilmiş olacaktır.



Resim 2.5. Sağlam, çatlak ve kırık güneş hücreleri

3. MATERYAL VE YÖNTEM


3.1. Veri Setinin Oluşturulması

Veri seti (Buerhop-Lutz ve diğerleri, 2018), genel kullanıma açık olan Github platformundan temin edilmiştir. İçeriğinde 44 farklı güneş panelinin çeşitli derecelerde bozulmalara sahip 300x300 piksel, 8 bit gri tonlamalı 2.426 görsel bulunmaktadır. Veri setinde güneş panel hücrelerinin sağlam, çatlak ve kırık şekilleri yer almaktadır. Güneş modüllerinden 26 tanesi polikristal ve 18 tanesi de monokristal yapıdadır.

Görüntü seti tek tek kontrol edilerek tekrar sınıflandırma yapılmıştır. Hatalı sınıflandırılan görüntüler çıkartılarak 2176 Elektrolüminans görüntü ile çalışmaya devam edilmiştir. Görüntüler sağlam, çatlak ve kırık olarak üç kategoriye ayrılmıştır. Bu görüntülerden %80'i eğitim için geriye kalan %20'si de test amacıyla kullanılmıştır.

Çizelge 3.1. Veri setindeki görsellerin sınıflandırılmış dağılımı

Modül Yapısı	Sınıflandırma		
	Sağlam	Çatlak	Kırık
Monokristal	453	346	198
Polikristal	901	151	127




Resim 3.1. Veri setindeki görsellerin örnek görünümü

Resim 3.1’de veri setindeki EL görüntülerin sınıflandırılması yer almaktadır. Monokristal ve polikristal yapıdaki EL görüntüleri kategorilere ayrılarak etiketlenmiştir.

3.2.Verİ Çoğaltma

Derin öğrenmede işlenecek veri sayısının az olması öğrenimi kısıtlayacağından analizin başarı oranı da düşecektir. Aynı zamanda kullanılacak görsel sayısının düşüklüğü sistemin ezberleme yapmasına da sebep olabilir. Bunun için veri setindeki görseller döndürme, gürültü ekleme gibi yöntemler ile çoğaltılır.

Bu çalışmada, veri setinde bulunan EL görüntüler 90 derecelik döndürme ile çoğaltılmıştır. Üç sınıfa ayrılmış görüntüler içerisinde kırık ve çatlak görseller az sayıdadır. Bu kategorilerdeki görsellerin başarılı sınıflandırılması için bu işlem yapılmıştır.



Resim 3.2. Veri çoğaltma öncesi ve sonrası görüntüler


Veri setindeki EL görüntüler çoğaltma işleminden sonra çizelge 3.2'deki gibi değerlere ulaşmıştır. Görüntü sayısının fazla olması sinir ağındaki eğitimin başarı oranını arttıracaktır. Derin öğrenme büyük veri setlerini analiz ettiği için veri sayısı ne kadar çok olursa değerlendirme sonucu başarı yüzdesi o derecede yüksek çıkacaktır.

Çizelge 3.2. Veri çoğaltma sonrası görsellerin sınıflandırılmış dağılımı

Modül Yapısı	Sınıflandırma		
	Sağlam	Çatlak	Kırık
Monokristal	1359	1038	594
Polikristal	2703	453	381

3.3. Derin Öğrenme Geliştirme Platformu

Bu çalışma, Google Colaboratory platformunda gerçekleştirilmiştir. Python programlama dilinde geliştirilmiş ve CNN mimarisinde görüntü sınıflandırma uygulamalarında tercih edilen kolay ve hızlı tasarlanabilen Keras kütüphanesi kullanılmıştır. Derin öğrenmede eğitimin gerçekleştirilmesi için yüksek oranda Mib ve Gib desteğine ihtiyaç vardır. Bu platform donanım desteğini ücretsiz şekilde vermektedir. Sistem ekran kartı işlemcisi olarak Tesla P100 16 gb ve 38 gb ram desteği vermektedir.



Şekil 3.1. Google colaboratory platformu

Aynı zamanda veri setindeki görselleri Google Drive depolama birimine yükleyerek, verilere doğrudan erişebilme imkânı bulunmaktadır. Şekil 3.1’de Google Colaboratory platformunun kod yazımı ve Google Drive bölümüne bağlantısı gözükmemektedir. Google Colaboratory platformu, derin öğrenme kütüphanelerinin hazır olarak sunulduğu ücretsiz bir ortamdır. Google Colaboratory’de herhangi bir yapılandırmaya ihtiyaç yoktur. Uygulamaları başkaları ile kolaylıkla paylaşma imkânı sunar. Sağladığı gib desteği ile de yüksek verim sağlayarak derin öğrenme çalışmalarına kolaylık sağlamaktadır


3.4. Derin Öğrenme

Derin öğrenme, YSA’larını kullanan çok katmanlı mimarilerde büyük boyuttaki verileri analiz edebilen, yapay zekanın alanının en alt dalıdır. Derin öğrenme; el yazısı, plaka ve yüz tanıma, nesne ve hareket algılama, görüntü sınıflandırma, ses tanıma, duygu analizi, doğal dil işleme gibi birçok zor problemi analiz edebilmektedir (Çalışkan ve Demir, 2022). Şekil 3.2’de yapay zekâ ve alt dalları yer almaktadır (Tüzün, 2022).



Şekil 3.2. Yapay zekâ, makine öğrenimi ve derin öğrenme ilişkisi

Derin öğrenme, girdi katmanına gelen verilerin çok katmanlı sinir ağlarından geçerek ortaya çıkan sonuç, modelin öğrenme sürecini ifade etmektedir. Girdi, gizli ve çıktı katmanlarından oluşmaktadır. Her katmandaki nöron sayısı değişiklik gösterebilir. Gizli katmanı, öğrenme süreci içerisinde en fazla öneme sahiptir (Kartal ve Duman, 2019). Şekil 3.3’de derin öğrenmenin çalışma mantığı gösterilmiştir (Sönmez, 2018).



Şekil 3.3. Derin öğrenme süreci


Derin öğrenme, kullanıcıların tanımladığı kuralları kullanmadan, ses ve görüntü gibi verilerin içeriklerinden otomatik çıkarımlarla öğrenme yapabilmektedir. Girdi verilerinin çok olması ve normalizasyon işlemlerine göre tahmin doğruluğu artmaktadır (Şeker, Diri ve Balık, 2017).

Derin öğrenme işlemi sırasında analiz için çok fazla matematiksel işlem gücünü kullandığı için Mib mimarisi yeterli olmamaktadır. Son yıllarda derin öğrenme ile yapılan analizlerde grafik işlemci birimi kullanılmaktadır. Gib mimarisi ile büyük veriler eğitim için kullanılabilir. Büyük verilerin kullanılmasıyla yapılan analizlerin başarı oranları yüksek olmaktadır. Bundan dolayı ekran kartı donanım performansı arttıkça, sonuçta pozitif olarak etkilemektedir. Birçok yenilikçi kurumsal teknoloji şirketi, derin öğrenme alanında çalışmalar yapmakta ve bu alana olan yatırımlarını arttırmaktadır.

3.5. Evrişimli Sinir Ağları

CNN, genellikle görsel verilerin işlenmesinde kullanıldığı için doğadaki canlıların gelişmiş görme yeteneklerinden esinlenilerek geliştirilmiş çok katmanlı yapay sinir ağının bir yapısıdır (Hubel ve Wiesel, 1968). Görüntü işleme, ses ve metin analizi gibi birçok alanda başarılı sonuçlar elde etmektedir (Kurt, 2018).

CNN, görüntüyü girdi olarak ele alır. Değişen evrişim ve alt örnekleme katmanları sayesinde, görüntünün yapısına dair tahminler oluşturmak için kullanılmaktadır (Jain ve Seung, 2008). Şekil 3.4'de CNN mimarisine ait bir örnek gösterilmiştir (Ravi ve diğerleri, 2017).



Şekil 3.4. Cnn temel mimarisi

Şekil 3.5'deki şekle ait süreç şu şekilde özetlenebilir (Ravi ve diğerleri, 2017);


- Giriş katmanında verilen görüntü bazı filtrelemeler kullanılarak analiz edilir,
- Filtre uygulanan görüntülerden oluşan çıktı alt örneklenir,
- Alt örnekleme işlemi neticesinde elde edilen çıktı, yeni girdi olarak işleme alınır. Yüksek seviyeli özellikler çıkıncaya kadar evrişim ve alt örnekleme işlemlerinin tekrar edilmesi sağlanır

3.5.1. Giriş katmanı

CNN mimarisinde veri girişinin yapıldığı ilk katmandır. Giriş katmanında ham veriler sisteme verilir ve oluşturulan veri seti ağı yapısına göre tespit edilir (Uysal, Hardalaç ve Koç, 2018). Bu katmandaki nöron değeri, analizin en iyi şekilde olabilmesi için öznitelik sayısı ile eşittir. Bu katmanda değerler kopyalanır ve farklı katmanlara gönderilir. Aktarım sırasında verilere bir işlem yapılmaz (Akdoğan, 2020). Oluşturulan veri setinin boyutuna göre ağ hızı, eğitim ile test süresi ve bellek ihtiyacı değişmektedir (Tan, 2019).

3.5.2. Evrişim katmanı

CNN'in temel katmanıdır. Görüntüler matris şeklinde olmaktadır (Cengil ve Çınar, 2019). Evrişim katmanında, giriş katmanından gelen görüntü bir filtreden geçer ve oluşan değerler öznitelik haritasını meydana getirir (Akdoğan, 2020).




Şekil 3.5. Evrişim işlemi

Evrişim işlemi şekil 3.5'de yer almaktadır. Giriş katmanında 4x4'lük bir matris vardır. Yapılan filtre ise 2x2 boyutundadır. Bu kısımda giriş katmanından gelen matrisin tümünde bu filtre dolaşır. Giriş katmanındaki veriler ile filtre matrisi çarpılarak öznitelik matrisi oluşturulur. Görüntü analizi yapılırken resimler genellikle siyah beyaz hale getirilerek modele giriş olarak gönderilir. Bazı görüntü analizlerinde renklerin etiket üstündeki tesiri fazla olmaktadır. Örneğin bir meyvenin durumu rengiyle direkt ilişkili olduğu için görüntüleri renkli şekilde analiz etmek gerekmektedir (Akdoğan, 2020).

3.5.3. Havuzlama katmanı


Havuzlama katmanının amacı ağ içerisindeki verileri indirgeyerek işleme alınacak veri miktarını azaltmaktır. Bu şekilde ağın hem daha hızlı olması hem de ağdaki hesaplama yoğunluğunun azalmasını sağlanmaktadır (Doğan ve Türkoğlu, 2018). Genellikle Relu katmanından sonra kullanılmaktadır. Havuzlama katmanında bir filtre matrisi, Relu katmanından gelen havuzlama katmanına girdi olarak verilen matris üzerinde gezdirilir. Gezdirme esnasında elde edilecek çıkış değeri, ortalama havuzlama veya en büyük değer havuzlama yöntemi ile bulunur.

Ortalama havuzlama yönteminde Şekil 3.6'da (Tayiz, 2022) gösterildiği gibi matris üzerinde gezdirilen filtre matrisinin içine denk gelen değerlerin ortalaması alınarak yeni matrisin değeri elde edilir.



Şekil 3.6. Ortalama değer havuzlama yöntemi


En büyük değer havuzlama yönteminde ise şekil 3.7’de (Tayız, 2022) görüldüğü gibi filtre matrisinin denk geldiği değerlerden en büyük olan yeni matrise çıkış değeri olarak alınmaktadır.



Şekil 3.7. En büyük değer havuzlama yöntemi

3.5.4. Düzleştirme katmanı


Giriş verilerinin tek boyutlu olması gerektiği için düzleştirme katmanı verileri tek boyutlu bir diziye dönüştürür. Düzleştirme katmanın amacı, havuzlanmış özellik matrisini tek boyutlu bir vektöre çevirerek tam bağlantı katmanının girişine uygun hale getirmektir. Şekil 3.8’de düzleştirme katmanının çalışma yapısı gösterilmiştir (Jeong, 2019).



Şekil 3.8. Örnek bir düzleştirme işlemi

3.5.5. Tam bağı katman


Her nöron kendinden sonra gelen nörona bağlantılı olduğu için bu şekilde isimlendirilmektedir. Havuzlama katmanından sonra kullanılmaktadır (İbrahim, 2020). Kullanılan mimari yapıya göre bu katmanın sayısı değişiklik gösterebilir. Tam bağı katmanda bir önceki katmanda açığa çıkmış özellikler incelenerek nesnenin özelliklerini belirten ağırlıkların bulunduğu nöronlar tespit edilerek nesnenin hangi sınıfa ait olduğunun ortaya çıkması sağlanmış olur. Şekil 3.9’da tam bağı katmanın yapısı yer almaktadır (Doğan ve Türkoğlu, 2019).



Şekil 3.9. Tam bağı katman yapısı

3.5.6. Seyreltme katmanı

CNN uygulamalarında ezberleme veya aşırı öğrenme diye isimlendirilen ağın öğrenmek yerine ezbere hareket ettiği durumlarla karşılaşılabilir. Büyük ağı eğtmek çok fazla hesaplama ve büyük miktarda eğitim verisi gerektirir. Bu verilerin farklı alt kümeleri üzerinde farklı ağı eğtmek için yeterli veri olmayabilir. Oluşturulan mimarilerde genellikle bu sorunların çözümünü sağlamak için seyreltme kullanılmaktadır. Şekil 3.10’da Seyreltme kullanılan ve kullanılmayan ağı örnek verilmiştir (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014). Genellikle tam bağı katmandan önce yer almaktadır. Seyreltme katmanının amacı ağdaki bazı düğümlerin kaldırılmasıdır.



Şekil 3.10. Seyreltme işlemi

3.5.7. Normalizasyon katmanı


CNN eğitimi sırasında katmanlar arası geçişlerde girdi verileri farklılaştığı için eğitim karmaşık hale gelmektedir. Bunu aşabilmek için girdi katmanlarında gerçekleştirilen normalleştirme yönteminin bir de gizli katman girişlerinde uygulanması tavsiye edilmektedir (Ioffe ve Szegedy, 2015). Katmanların normalizasyonu, derin sinir ağının eğitim süresini de azaltacaktır. Ayrıca sinir ağının ezberleme sorunlarını da ortadan kaldırarak seyreltme yöntemine ihtiyaç da azalacaktır.

3.5.8. Aktivasyon fonksiyonları

Aktivasyon fonksiyonu, sinir ağına gerçek hayatta yer alan resim, video, ses ve yazı gibi karmaşık dünya verilerini öğretmek için kullanılmaktadır. Derin sinir ağlarında aktivasyon fonksiyonu kullanımı tercih edilmezse ağın öğrenmesi sınırlı kalacaktır (Kızrak, 2019).

3.5.8.1. Sigmoid fonksiyonu


Geri yayılım algoritmalarında hesaplama karmaşıklığı kapsamında avantaj sağlar. Öğrenme yavaş olduğunda hatayı azaltan optimizasyon algoritması yerel minimum değerlere takılabilir. Bu durumda YSA modelinden verimli bir analiz alınamaz. Sigmoid fonksiyonu, en fazla tercih edilen aktivasyon fonksiyonları arasındadır. Şekil 3.11’de sigmoid fonksiyonunun grafiği verilmiştir (Kızrak, 2019).



Şekil 3.11. Sigmoid fonksiyonu ve türevi

3.5.8.2. ReLu


CNN mimarisinde en çok kullanılan aktivasyon fonksiyonudur. Relu fonksiyonu ile yapılan aktivasyon işlemi sonucu negatif olarak elde edilen değerler 0 değerini alır. Negatif ekseninde 0 değerini alması çok miktarda işlem gerektiren büyük boyutlu sinir ağlarında hesaplamaların hızlı olmasına imkân tanımaktadır (Liu, Li, Sun, Zhang ve Chen, 2017). Bu imkân ile ağda bulunan bazı nöronların 0 değerine çekildikleri için aktif olmayıp ve bazı nöronlar ise aktif şekilde seyreklik sağlayarak verimli bir hesaplama yükü oluşturmaktadır. Şekil 3.12’de Relu fonksiyonunun grafiği verilmiştir. (Kızırak, 2019).



Şekil 3.12. Relu fonksiyonu ve türevi

3.5.8.3. Hiperbolik tanjant fonksiyonu

Yapısal açıdan Sigmoid fonksiyonuna benzemektedir. Fakat fonksiyonun aralığı -1 ile +1 arasında tanımlanmaktadır. Sigmoid fonksiyonuna göre avantajı ise daha çok değere sahip olabilmesidir. Bu sayede hızlı öğrenme gerçekleşir ve sınıflama işlemi daha verimli olur. Şekil 3.13’de hiperbolik tanjant fonksiyonunun grafiği verilmiştir (Kızrak, 2019).



Şekil 3.13. Hiperbolik tanjant fonksiyonu ve türevi

3.5.8.4. Softmax fonksiyonu

Sigmoid fonksiyonuna benzer yapıdadır. Sınıflayıcı olarak kullanıldığında iyi bir performans ortaya çıkarır. En önemli farkı ikiden fazla sınıflamanın yapılacağı durumlarda derin öğrenme modellerinin çıkış katmanında kullanılmaktadır. Girdinin hangi sınıfa ait olduğunu 0 ile 1 arasında değerler üreterek bulmaktadır. Yani tahminsel bir yorumlama yapar (Kızrak, 2019).


3.5.9. Çıkış katmanı

CNN’in son katmanıdır. Ağın çıktısının sunulduğu katmandır. Sınıflandırma katmanındaki ile aynı sayıda eleman bulundurması nedeniyle aslında sınıflandırma katmanı da çıktı katmanı sayılabilmektedir.

3.6. Transfer Öğrenme

Derin öğrenme modelinde veri setlerinin büyük olması çıktı değerlerinin doğruluğu ve özgünlüğü bakımından önemlidir. Öğrenmenin başarılı sayılabilmesi ve tekrar eden öğrenmeleri azaltmak amacıyla büyük veri setleri kullanılmaktadır. Veri setlerinin büyümesiyle analiz için gerekli donanım özellikleri de yükselmektedir. Yapay sinir ağında analiz sırasında kullanılan gizli katmanlar çoğaldıkça, büyük bellek ihtiyaçları ortaya çıkmaktadır.

Transfer öğrenme ile daha önce öğrenilen bilgiler ışığında yeni bilgilerin öğrenilmesi için aktarılabilmesi yönüyle insan öğrenme davranışına benzemektedir (Fan, Lee ve Lee, 2021). Transfer öğrenme benzer problemlerin çözümü için hazırlanmış kalıpların yeni karşılaşılmış sorunlar için iyi performans ve hızlı sonuca ulaşmak amacıyla kullanıldığı bir yöntem olarak tanımlanabilir (Fırıldak ve Talu, 2019). Şekil 3.14’de transfer öğrenme mimarisi gösterilmiştir (Samtaş ve Gülesin, 2012).



Şekil 3.14. Transfer öğrenme mimarisi

Transfer öğrenme işleminde önceden farklı veri setleri ile eğitilmiş model türleri yapılarında birçok farklı kategoriye ait veriye sahiptir. Yeni oluşturulacak modelin daha çabuk eğitime


girebilmesi için ince ayar yöntemini uygulamak daha verimli neticeler elde edilmesini sağlamaktadır (Abdulghani, Fadhil ve Gültekin, 2020).

Bu çalışmada çeşitli transfer öğrenme modellerinden öğrenim aktarımı yapılarak, veri setindeki görüntülerin analizleri transfer öğrenme modelleri ile yapılmıştır. Transfer öğrenme modellerinden Vgg-16, Vgg-19, MobileNet, Xception, ResNet50 ve DenseNet201 kullanılarak eğitim ve sınıflandırma işlemleri yapılmış ve başarı oranları karşılaştırılmıştır

3.6.1. Vgg16

Vgg16 mimarisi Simonyan ve Zisserman tarafından 2014 yılında geliştirilmiştir. Imagenet yarışmasında %7,3 hata oranıyla iyi bir başarı sergilemiş bir derin öğrenme modelidir (Simonyan ve Zisserman, 2015). Vgg16, 6 farklı katman sayısına sahiptir. Bu mimarinin diğerlerinden farkı, evrişim işlemi için 2x2'lik veya 3x3'lük filtre uygulamasıdır. Giriş boyutu 224x224x3'tür. Üç tam bağlantılı katmana sahiptir (Doğan ve Türkoğlu, 2018).


Vgg16 modelinde her bir evrişim katmanının veya tam bağlı katmanın bir blok oluşturduğu modüler bir yapı mevcuttur. Modüllerdeki havuzlama katmanı özellik haritasının boyutunu küçültmek için kullanılmaktadır (Tao, Gu, Sun, Bie ve Wang, 2021). Modelin asıl amacı, ağ karmaşıklığını artırmadan uygun katman derinliği ayarlarını dikkate alan bir model tasarlamaktır. Şekil 3.15'de Vgg16 mimarisi gösterilmektedir.



Şekil 3.15. Vgg16 mimari yapısı

3.6.2. Vgg19

VGG19 modeli, 2014 yılında yapılan ImageNet yarışmasında %9,0'lık hata oranı ile analiz yapmıştır. 16 evrişim katmanı, üç tam bağlı katman ve diğer katmanlarla birlikte toplam 47 adet katman bulunmaktadır. Giriş katmanı görüntüsü 224x224x3 boyutundadır (Simonyan ve Zisserman, 2015). Vgg16 ve Vgg19 arasındaki fark ise Vgg19'da daha fazla evrişim katmanı yer almaktadır. Şekil 3.16'da Vgg19 mimarisinin katman yapıları gösterilmiştir (Zheng, Yang ve Merkulov, 2018)




Şekil 3.16. Vgg19 mimari yapısı

3.6.3. Mobilenet

Bu model, mobil ve gömülü görme uygulamaları için tanıtılmış olup derinlik açısından ayrılabilir konvolüsyonlara dayanmaktadır (Howard ve diğerleri, 2017).


MobileNet, diğer birçok popüler modelden çok daha küçük boyutta ve performans açısından hızlı olan basit bir CNN modelidir. Derinlik bakımından ayrılabilir konvolüsyonlarda her bir girdi kanalına tek bir filtre uygulanır. Ardından nokta bazlı konvolüsyonda 1×1 konvolüsyonlar kullanılarak derinlik bazlı katmanların çıktısının doğrusal kombinasyonu oluşturulur. Şekil 3.17'de MobileNet genel mimarisi gösterilmiştir (Howard ve diğerleri, 2017).



Şekil 3.17. Mobilenet genel mimarisi

3.6.4. Xception


Xception mimarisi 2017 yılında Chollet tarafından geliştirilmiştir (Chollet, 2017). Inception mimarisinin bir yapısıdır. Derinlemesine ayrılabilir evrişim olarak isimlendirilen evrişim işleminin özelleşmiş bir yapısı üzerine kurulmuştur. Xception, Inception ağında bulunan blok yapısını değiştirerek değişik boyutları (1x1, 3x3, 5x5) tek bir boyuta (3x3) dönüştürmüş ve ardından 1x1 boyutunda evrişim işlemi gerçekleştirmiştir. Yenilenen blok mimarisi sayesinde Xception ağı hesaplama bakımından daha verimli bir yapı olmuştur. Şekil 3.18’de Xception mimarisinin katman yapısı gösterilmiştir (Khan, Sohail, Zahoora ve Qureshi, 2020).



Şekil 3.18. Xception mimari yapısı

3.6.5. Resnet50

ResNet mimarisi, tüm mimarilerden daha derin tasarlanmıştır. 152 katman yapısına sahiptir. 2015 yılında gerçekleştirilen ImageNet yarışmasında %3,6 hata oranıyla birinci olmuştur (He, Zhang, Ren ve Sun, 2015). Diğer mimarilere kıyasla en önemli özelliği artık değerlerin sonraki katmanları besleyen blokların modele dahil edilmesiyle oluşmasıdır. Doğrusal ve ReLu aktivasyon kodları arasında iki katmanda bir eklenen bu değer sistem hesabını farklılaştırmaktadır (Kızrak ve Bolat, 2018)




Şekil 3.19. Derin sinir ağı ve resnet modeli

ResNet50 mimarisi 34 katmanlı ağıdaki her iki katman bloğunu 3 katmanlı darboğaz katmanıyla değiştirerek oluşmaktadır. Şekil 3.19’da derin sinir ağı ile Resnet mimarisinin katman yapıları gösterilmiştir. Bu 50 katmanlı CNN ağı 3,8 milyar işlem içermektedir (He, Zhang, Ren ve Sun, 2015).

3.6.6. Densenet201

DenseNet201 mimarisi 201 adet katman içeren derin öğrenme ağıdır. Şekil 3.20’de görüldüğü gibi her katman doğrudan diğer tüm katmanlarla bağlantılıdır. Başka bir deyişle bir katmana kendisinden önceki katman ile birlikte arkasında kalan bütün katmanlardan bilgi girişi bulunmaktadır (Huang, Liu, Maaten ve Weinberger, 2016). DenseNet-201 ağının katmanlar arasındaki direk bağlantıları sayesinde bir özneteliği tekrardan kullanmaya teşvik etme avantajı vardır (İbrahim, 2020). Buna ek olarak, katmanlar arasındaki bu bağlantılar

nedeniyle yüksek sistem gereksinimine ihtiyaç duyulması ağın dezavantajıdır. Ağ yapısında bulunan her katmanın girişi aynı yapıda bulunan önceki bütün katmanların öznetelik haritalarının birleşimidir (Huang, Liu, Maaten ve Weinberger, 2018). Bu yapı öznetelik çeşitliliğini arttırmaktadır.



Şekil 3.20. Densenet201 mimari yapı

3.7. Başarım Ölçütleri

Bir modelin performansını değerlendirmek yapılan çalışmanın en önemli kısımlarından biridir. Model performansını ölçmek için kullanılan çeşitli başarıım ölçütleri bulunmaktadır.

3.7.1. Karışıklık matrisi

Gerçek değerler ve tahmin edilen değerlerin daha net görülebildiği matrislerdir. Matrisin sol tarafı gerçek değerleri verirken üst taraf tahmin edilen değerleri vermektedir. Her sınıf için hangi sınıfın gerçekte ne olması gerektiği fakat ne olarak tahmin edildiğine ilişkin bilgiler matris üzerinden alınabilmektedir. Çizelge 3.1’ de ikili sınıflandırma için gerçek ve tahmin değerlerini gösteren bir karışıklık matrisi yer almaktadır. Bu matristeki;

Doğru Pozitifler (DP), sınıflandırıcı tarafından pozitif olarak sınıflandırılmış ve gerçek değerleri de pozitif olan değerleri,

Yanlış Pozitifler (YP), sınıflandırıcı tarafından pozitif olarak sınıflandırılmamış ancak gerçek değerleri pozitif olan değerleri,

Doğru Negatifler (DN), sınıflandırıcı tarafından negatif olarak sınıflandırılmış ve gerçek değerleri de negatif olan değerleri,

Yanlış Negatifler (YN), sınıflandırıcı tarafından negatif olarak sınıflandırılmamış ancak gerçek değerleri negatif olan değerleri ifade etmektedir.

DP ve DN tahminin doğru yapıldığını, YP ve YN ise tahminin yanlış yapıldığını belirtmektedir (Kutlu, 2019).

Çizelge 3.3. Karışıklık matrisi

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitifler (DP)	Yanlış Negatifler (YN)
	Negatif	Yanlış Pozitifler (YP)	Doğru Negatifler (DN)

3.7.2. Doğruluk

Tüm sınıflar için hesaplanan performans ölçüsüdür. Doğru tahmin edilen sınıfların toplam örnek sayısına oranı şeklinde hesaplanmaktadır. 0 ile 1 arasında değer almaktadır (Öğündür, 2019).

$$\text{Doğruluk} = \frac{DP + DN}{(DP + YP + YN + DN)} \quad (3.1)$$

3.7.3. Kesinlik

Pozitif tahmin değeri olarak da bilinmektedir. Pozitif sınıflandırmaların ne kadarının gerçekten doğru olduğunu tahmin etmeye yarayan, gerçek pozitiflerin pozitif olarak sınıflandırılanlara bölünmesi ile elde edilen, 0 ile 1 arasında değer alan ölçüttür (Öğündür, 2019).

$$Kesinlik = \frac{DP}{DP + YP} \quad (3.2)$$

3.7.4. Duyarlılık

Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini bulmamıza yarar. Yani pozitif tahmin edilmesi gerekenlerin ne kadarının pozitif tahmin edildiğini gösteren, tüm pozitifler arasındaki gerçek pozitiflerin oranı veren, 0 ile 1 arasında değişen ölçüttür (Korkmaz, 2019).

$$Duyarlılık = \frac{DP}{DP + YN} \quad (3.3)$$

3.7.5. F1 skor

Kesinlik ve duyarlılık değerlerinin harmonik ortalaması F1 skoru vermektedir. Eşit dağılım olmayan veri setlerinde daha doğru değerlendirmeler yapabilmek için doğruluk değerinin yerine kullanımı tavsiye edilmektedir (Öğündür, 2019). Hem yanlış negatifleri hem de yanlış pozitifleri hesaba katan, 0 ile 1 arasında değişen bir ölçüttür (Korkmaz, 2019).

$$F1\ Skor = 2x \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (3.4)$$

4. BULGULAR

4.1. MobileNet Analiz Sonuçları

Veri setindeki EL görüntüler MobileNet mimarisi ile eğitilerek sınıflandırma başarı değerleri ortaya koyulmuştur. MobileNet mimarisinde bulunan toplam 3 232 964 görsel içerisinden, kullanılan görüntüler ile eşleşen 4 100 görsel bulunmaktadır. Bu ön eğitilmiş özellikler ile veri setindeki görüntüler MobileNet sinir ağında eğitilmiştir.

Görüntüler 224x224 şeklinde boyutlandırılmış ve. Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler sağlam, çatlak ve kırık şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.

Veri setindeki monokristal ve polikristal EL görüntüleri ayrı ayrı analiz edilmiştir. Her iki güneş hücre çeşidinin yapı olarak birbirinden farklı olması, sistemin kırık ve çatlak tespit etme başarısını düşüreceği için bu şekilde yapılmıştır.

Çizelge 4.1. Monokristal görüntülerde mobilenet modelinin eğitim doğruluğu


Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
MobileNET	%76,05	%77,08	0,5980	0,5496

Monokristal EL görüntülerinin MobileNET sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.1 ve çizelge 4.2’de yer almaktadır. Çizelge 4.1’e göre sistemin genel başarı oranı %76 civarındadır. Çizelge 4.2’deki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan kırık özniteliği olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma sağlam özniteliği olmuştur. F1-skor ölçütüne göre kırık özniteliği en başarılı sınıflandırma olmuştur.

Çizelge 4.2. Monokristal görüntülerde mobilenet modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%74	%91	%82
Çatlak	%80	%50	%62
Kırık	%84	%86	%90

Şekil 4.1’de monokristal EL görüntülerin MobileNet modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.1. Monokristal görüntülerde mobilenet modelinin eğitim ve test doğruluğu

Şekil 4.2’de monokristal EL görüntülerin MobileNet modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.2. Monokristal görüntülerde mobilenet modelinin eğitim ve test kayıp grafiği

Şekil 4.3’de MobileNet modelinin kategorilendirilmiş monokristal EL görüntülerini tahmin değerleri gösterilmiştir. Şekilde gözüktüğü gibi çatlak görüntüleri tahmin oranı çok düşük çıkmıştır. Fakat kırık görüntüleri tahmin oranı çok başarılı çıkmıştır. Sağlam görüntüleri sınıflandırma oranı %90 oranında çıkmıştır.

Gerçek Değer	Çatlak	104	19	83
	Kırık	3	114	2
	Sağlam	23	2	245
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.3. Monokristal görüntülerde mobilenet modelinin karışıklık matrisi

Polikristal EL görüntülerinin Mobilenet sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.3 ve çizelge 4.4’de yer almaktadır. Çizelge 4.3’e göre sistemin genel başarı oranı %85 civarındadır. Çizelge 4.4’deki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan kırık ve sağlam öznitelikleri olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma sağlam özniteliği olmuştur. F1-skor ölçütüne göre sağlam özniteliği en başarılı sınıflandırma olmuştur.


Çizelge 4.3. Polikristal görüntülerde mobilenet modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
MobileNET	%85,00	%90,21	0,4767	0,2924

Çizelge 4.4. Polikristal görüntülerde mobilenet modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%87	%99	%93
Çatlak	%73	%52	%61
Kırık	%86	%67	%76

Şekil 4.4’de polikristal EL görüntülerin MobileNet modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.4. Polikristal görüntülerde mobilenet modelinin eğitim ve test doğruluğu

Şekil 4.5’de polikristal EL görüntülerin MobileNet modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.5. Polikristal görüntülerde mobilenet modelinin eğitim ve test kayıp grafiği

Şekil 4.6’da MobileNet modelinin kategorilendirilmiş polikristal EL görüntülerini tahmin değerleri gösterilmiştir. En başarılı tahmin sağlam özneliğinde olmuştur. Diğer özneliklerin tahmin başarı değerleri çok düşük çıkmıştır.

Gerçek Değer	Çatlak	47	7	36
	Kırık	14	51	11
	Sağlam	3	1	320
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.6. Polikristal görüntülerde mobilenet modelinin karışıklık matrisi

4.2.Xception Analiz Sonuçları

Veri setindeki EL görüntüler Xception mimarisi ile eğitilerek sınıflandırma yapılmıştır. Xception mimarisinde bulunan toplam 20 867 627 görsel içerisinde, kullanılan görüntüler ile eşleşen 6 147 görsel bulunmaktadır. Bu ön eğitilmiş özellikler ile veri setindeki görüntüler sinir ağında eğitilmiştir.

Görüntüler 224x224 şeklinde boyutlandırılmış ve Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler sağlam, çatlak ve kırık şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.

Çizelge 4.5. Monokristal görüntülerde xception modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
Xception	%78,13	%79,65	0,5492	0,4853


Monokristal EL görüntülerinin Xception sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.5 ve çizelge 4.6'da yer almaktadır. Çizelge 4.5'e göre sistemin genel başarı oranı %78 civarındadır. Çizelge 4.6'daki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan öznetelikler çatlak ve kırık olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma

kırık özniteliğinde olmuştur. F1-skor ölçütüne göre kırık özniteliği en başarılı sınıflandırma olmuştur.

Çizelge 4.6. Monokristal görüntülerde xception modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%72	%85	%78
Çatlak	%79	%49	%60
Kırık	%79	%99	%88

Şekil 4.7’de monokristal EL görüntülerin Xception modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.7. Monoskristal görüntülerde xception modelinin eğitim ve test doğruluğu

Şekil 4.8’de monokristal EL görüntülerin Xception modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.8. Monokristal görüntülerde xception modelinin eğitim ve test kayıp grafiği

Şekil 4.9’da Xception modelinin kategorilendirilmiş monokristal EL görüntülerini tahmin değerleri gösterilmiştir. En başarılı tahmin kırık öz niteliğinde olmuştur. Sağlam öz niteliğinin sınıflandırma başarısında %15 civarı bir sapma olmuştur.

Gerçek Değer	Çatlak	101	16	89
	Kırık	1	118	0
	Sağlam	26	15	229
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.9. Monokristal görüntülerde xception modelinin karışıklık matrisi

Polikristal EL görüntülerinin Xception sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.7 ve çizelge 4.8’de yer almaktadır. Çizelge 4.7’ye göre sistemin genel başarı oranı %84 civarındadır. Çizelge 4.8’deki sınıflandırma raporuna göre kesinlik ölçütü üç öznitelikte de eşit oranda çıkmıştır. Duyarlılık ölçütüne göre en başarılı sınıflandırma sağlam özniteliğinde olmuştur. F1-skor ölçütüne göre sağlam özniteliği en başarılı sınıflandırma olmuştur.


Çizelge 4.7. Polikristal görüntülerde xception modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
Xception	%84,16	%90,39	0,4822	0,2654

Çizelge 4.8. Polikristal görüntülerde xception modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%84	%100	%91
Çatlak	%85	%44	%58
Kırık	%86	%67	%76

Şekil 4.10’da polikristal EL görüntülerin Xception modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.10. Polikristal görüntülerde xception modelinin eğitim ve test doğruluğu

Şekil 4.11’de polikristal EL görüntülerin Xception modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.11. Polikristal görüntülerde xception modelinin eğitim ve test kayıp grafiği

Şekil 4.12’de Xception modelinin kategorilendirilmiş polikristal EL görüntülerinin karışıklık matrisi gösterilmiştir. En başarılı tahmin sağlam özneliğinde olmuştur. Diğer özneliklerin tahmin başarısı çok düşük çıkmıştır.

Gerçek Değer	Çatlak	40	7	43
	Kırık	7	51	18
	Sağlam	0	1	323
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.12. Polikristal görüntülerde xception modelinin karışıklık matrisi

4.3. VGG16 Analiz Sonuçları

Veri setindeki EL görüntüler Vgg16 mimarisi ile eğitilerek sınıflandırma yapılmıştır. Vgg16 mimarisinde bulunan toplam 14 716 227 görsel içerisinde, kullanılan görüntüler ile eşleşen 1 539 görsel bulunmaktadır. Bu ön eğitilmiş özellikler ile veri setindeki görüntüler sinir ağına eğitilmiştir.

Görüntüler 224x224 şeklinde boyutlandırılmış ve Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler sağlam, çatlak ve kırık şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.

Çizelge 4.9. Monokristal görüntülerde vgg16 modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
VGG16	%65,45	%68,59	0,8720	0,6856


Monokristal EL görüntülerinin Vgg16 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.9 ve çizelge 4.10'da yer almaktadır. Çizelge 4.9'a göre sistemin genel başarı oranı %65 civarındadır. Çizelge 4.6'deki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan kırık özniteliği olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma çatlak

özniteliğinde olmuştur. F1-skor ölçütüne göre kırık özniteliği en başarılı sınıflandırma olmuştur.

Çizelge 4.10. Monokristal görüntülerde vgg16 modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%64	%11	%19
Çatlak	%58	%93	%71
Kırık	%83	%86	%84

Şekil 4.13’de monokristal EL görüntülerin Vgg16 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.13. Monokristal görüntülerde vgg16 modelinin eğitim ve test doğruluğu

Şekil 4.14’de monokristal EL görüntülerin Vgg16 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.14. Monokristal görüntülerde vgg16 modelinin eğitim ve test kayıp grafiği

Şekil 4.15’de Vgg16 modelinin kategorilendirilmiş monokristal EL görüntülerin karışıklık matrisi gösterilmiştir. En başarılı tahmin kırık özniteliğinde olmuştur. Sağlam özniteliğinin sınıflandırma başarısında %10, çatlak özniteliğinin sınıflandırma başarısında ise %20 civarı bir sapma olmuştur.

Gerçek Değer	Çatlak	23	14	169
	Kırık	1	102	16
	Sağlam	12	7	251
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.15. Monokristal görüntülerde vgg16 modelinin karışıklık matrisi

Polikristal EL görüntülerinin Vgg16 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.11 ve çizelge 4.12’de yer almaktadır. Çizelge 4.11’e göre sistemin genel başarı oranı %72 civarındadır. Çizelge 4.12’deki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan kırık özniteliği olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma sağlam özniteliğinde olmuştur. F1-skor ölçütüne göre sağlam özniteliği en başarılı sınıflandırma olmuştur.


Çizelge 4.11. Polikristal görüntülerde vgg16 modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
VGG16	%72,30	%79,41	0,7572	0,4988

Çizelge 4.12. Polikristal görüntülerde vgg16 modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%74	%100	%85
Çatlak	%50	%10	%17
Kırık	%86	%39	%54

Şekil 4.16’da polikristal EL görüntülerin Vgg16 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.16. Polikristal görüntülerde vgg16 modelinin eğitim ve test doğruluğu

Şekil 4.17’de polikristal EL görüntülerin Vgg16 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.17. Polikristal görüntülerde vgg16 modelinin eğitim ve test kayıp grafiği

Şekil 4.18’de Vgg16 modelinin kategorilendirilmiş polikristal EL görüntülerin karışıklık matrisi gösterilmiştir. En başarılı tahmin sağlam öz niteliğinde olmuştur. Çatlak öz niteliğinin sınıflandırma başarısında %20 civarı bir sapma olmuştur. Kırık öz niteliğinde başarısız bir tahmin yapılmıştır.

Gerçek Değer	Çatlak	9	5	76
	Kırık	9	30	37
	Sağlam	0	0	324
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.18. Polikristal görüntülerde vgg16 modelinin karışıklık matrisi

4.4.Vgg19 Analiz Sonuçları

Veri setindeki EL görüntüler Vgg19 mimarisi ile eğitilerek sınıflandırma yapılmıştır. Vgg16 mimarisinde bulunan toplam 20 026 436 görsel içerisinde, kullanılan görüntüler ile eşleşen 2 052 görsel bulunmaktadır. Bu ön eğitilmiş özellikler ile veri setindeki görüntüler sinir ağına eğitilmiştir.

Görüntüler 224x224 şeklinde boyutlandırılmış ve Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler sağlam, çatlak ve kırık şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.

Çizelge 4.13. Monokristal görüntülerde vgg19 modelinin eğitim doğruluğu


Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
VGG19	%60,92	%61,43	0,7802	0,7407

Monokristal EL görüntülerinin Vgg19 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.13 ve çizelge 4.14’de yer almaktadır. Çizelge 4.13’e göre sistemin genel başarı oranı %61 civarındadır. Çizelge 4.14’deki sınıflandırma raporuna göre kesinlik, duyarlılık ve F1-skor ölçütlerine göre kırık özniteliği en başarılı sınıflandırma olmuştur.

Çizelge 4.14. Monokristal görüntülerde vgg19 modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%61	%54	%58
Çatlak	%40	%48	%44
Kırık	%81	%74	%77

Şekil 4.19’da monokristal EL görüntülerin Vgg19 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.19. Monoskristal görüntülerde vgg19 modelinin eğitim ve test doğruluğu

Şekil 4.20’de monokristal EL görüntülerin Vgg19 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.20. Monokristal görüntülerde vgg19 modelinin eğitim ve test kayıp grafiği

Şekil 4.21’de Vgg19 modelinin kategorilendirilmiş monokristal EL görüntülerin karışıklık matrisi gösterilmiştir. Genel olarak başarısız bir tahmin sonucu ortaya çıkmıştır. Diğer özniteliklere kıyasla kırık özniteliğinin sınıflandırma başarısında %25 oranında bir sapma olmuştur.

Gerçek Değer	Çatlak	99	15	92
	Kırık	29	88	2
	Sağlam	117	6	147
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.21. Monokristal görüntülerde vgg19 modelinin karışıklık matrisi

Polikristal EL görüntülerinin Vgg19 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.15 ve çizelge 4.16’da yer almaktadır. Çizelge 4.15’e göre sistemin genel başarı oranı %72 civarındadır. Çizelge 4.16’daki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan kırık özniteliği olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma sağlam özniteliğinde olmuştur. F1-skor ölçütüne göre sağlam özniteliği en başarılı sınıflandırma olmuştur.


Çizelge 4.15. Polikristal görüntülerde vgg19 modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
VGG19	%72,12	%76,14	0,6290	0,5676

Çizelge 4.16. Polikristal görüntülerde vgg19 modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%71	%99	%83
Çatlak	%23	%03	%06
Kırık	%92	%29	%44

Şekil 4.22’de polikristal EL görüntülerin Vgg19 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.22. Polikristal görüntülerde vgg19 modelinin eğitim ve test doğruluğu

Şekil 4.23’de polikristal EL görüntülerin Vgg19 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.23. Polikristal görüntülerde vgg19 modelinin eğitim ve test kayıp grafiği

Şekil 4.24’de Vgg19 modelinin kategorilendirilmiş polikristal EL görüntülerin karışıklık matrisi gösterilmiştir. En başarılı tahmin sağlam özniteliğinde olmuştur. Daha sonra en başarılı sınıflandırma Çatlak özniteliğinin olmuştur. Kırık özniteliğinde başarısız bir tahmin yapılmıştır.

Gerçek Değer	Çatlak	3	2	85
	Kırık	8	22	46
	Sağlam	2	0	322
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.24. Polikristal görüntülerde vgg19 modelinin karışıklık matrisi

4.5.Resnet50 Analiz Sonuçları

Veri setindeki EL görüntüler Resnet50 mimarisi ile eğitilerek sınıflandırma yapılmıştır. Resnet50 mimarisinde bulunan toplam 23 593 859 görsel içerisinden, kullanılan görüntüler ile eşleşen 6 147 görsel bulunmaktadır. Bu ön eğitilmiş özellikler ile veri setindeki görüntüler sinir ağında eğitilmiştir.

Görüntüler 224x224 şeklinde boyutlandırılmış ve Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler sağlam, çatlak ve kırık şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.

Çizelge 4.17. Monokristal görüntülerde resnet50 modelinin eğitim doğruluğu


Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
Resnet50	%39,06	%47,50	0,9753	0,9779

Monokristal EL görüntülerinin Resnet50 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.17 ve çizelge 4.18’de yer almaktadır. Çizelge 4.17’ye göre sistemin genel başarı oranı %39 civarındadır. Çizelge 4.18’deki sınıflandırma raporuna göre kesinlik ölçütüne göre kırık özniteliği en başarılı olmuştur. Duyarlılık ve F1-skor ölçütlerine göre sağlam özniteliği en başarılı sınıflandırma olmuştur.

Çizelge 4.18. Monokristal görüntülerde resnet50 modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%49	%74	%59
Çatlak	%21	%18	%20
Kırık	%100	%06	%11

Şekil 4.25’de monokristal EL görüntülerin Resnet50 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.25. Monokristal görüntülerde resnet50 modelinin eğitim ve test doğruluğu

Şekil 4.26'da monokristal EL görüntülerin Resnet50 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.26. Monokristal görüntülerde resnet50 modelinin eğitim ve test kayıp grafiği

Şekil 4.27’de Resnet50 modelinin kategorilendirilmiş monokristal EL görüntülerin karışıklık matrisi gösterilmiştir. Genel olarak başarısız bir tahmin sonucu ortaya çıkmıştır. Diğer özniteliklere kıyasla çatlak özniteliğinin sınıflandırma başarısında %25 civarı bir sapma olmuştur.

	Çatlak	Kırık	Sağlam
Gerçek Değer			
Çatlak	38	0	168
Kırık	70	7	42
Sağlam	71	0	199
	Çatlak	Kırık	Sağlam
	Tahmin Değeri		

Şekil 4.27. Monokristal görüntülerde resnet50 modelinin karışıklık matrisi

Polikristal EL görüntülerinin Resnet50 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.19 ve çizelge 4.20’de yer almaktadır. Çizelge 4.19’a göre sistemin genel başarı oranı %77 civarındadır. Çizelge 4.20’deki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan sağlam ve kırık öznitelikleri olmuştur. Duyarlılık ölçütüne göre en başarılı sınıflandırma sağlam özniteliğinde olmuştur. F1-skor ölçütüne göre sağlam özniteliği en başarılı sınıflandırma olmuştur.


Çizelge 4.19. Polikristal görüntülerde resnet50 modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
Resnet50	%77,49	%80,74	0,8552	0,5078

Çizelge 4.20. Polikristal görüntülerde resnet50 modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%79	%100	%88
Çatlak	%69	%38	%49
Kırık	%77	%32	%45

Şekil 4.28’de polikristal EL görüntülerin Resnet50 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.



Şekil 4.28. Polikristal görüntülerde resnet50 modelinin eğitim ve test doğruluğu

Şekil 4.29’da polikristal EL görüntülerin Resnet50 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.29. Polikristal görüntülerde resnet50 modelinin eğitim ve test kayıp grafiği

Şekil 4.30’da Resnet50 modelinin kategorilendirilmiş polikristal EL görüntülerin karışıklık matrisi gösterilmiştir. Sağlam özniteliği başarılı şekilde sınıflandırılmıştır. Diğer öznitelikler için başarısız bir tahmin sonucu ortaya çıkmıştır.

Gerçek Değer	Çatlak	34	7	49
	Kırık	15	24	37
	Sağlam	0	0	324
		Çatlak	Kırık	Sağlam
		Tahmin Değeri		

Şekil 4.30. Polikristal görüntülerde resnet50 modelinin karışıklık matrisi

4.6.DenseNet201 Analiz Sonuçları

Veri setindeki EL görüntüler DenseNet201 mimarisi ile eğitilerek sınıflandırma yapılmıştır. DenseNet201 mimarisinde bulunan toplam 18 327 747 görsel içerisinde, kullanılan görüntüler ile eşleşen 5 763 görsel bulunmaktadır. Bu ön eğitilmiş özellikler ile veri setindeki görüntüler sinir ağında eğitilmiştir.

Görüntüler 224x224 şeklinde boyutlandırılmış ve Softmax aktivasyon fonksiyonu kullanılmıştır. Görüntüler sağlam, çatlak ve kırık şeklinde kategorilere ayrılarak analiz işlemi yapılmıştır.

Çizelge 4.21. Monokristal görüntülerde densenet modelinin eğitim doğruluğu


Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
DenseNet201	%76,56	%80,83	0,4980	0,4387

Monokristal EL görüntülerinin DenseNet201 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.21 ve çizelge 4.22’de yer almaktadır. Çizelge 4.21’e göre sistemin genel başarı oranı %77 civarındadır. Çizelge 4.22’deki sınıflandırma raporuna göre kesinlik ölçütüne göre kırık ve sağlam öznitelikleri başarılı olmuştur. Duyarlılık ve F1-skor ölçütlerine göre kırık özniteliği en başarılı sınıflandırma olmuştur.

Çizelge 4.22. Monokristal görüntülerde densenet modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%83	%65	%73
Çatlak	%64	%79	%70
Kırık	%90	%97	%94

Şekil 4.31’de monokristal EL görüntülerin DenseNet201 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.




Şekil 4.31. Monoskristal görüntülerde densenet modelinin eğitim ve test doğruluğu

Şekil 4.32’de monokristal EL görüntülerin DenseNet201 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.32. Monokristal görüntülerde densenet modelinin eğitim ve test kayıp grafiği

Şekil 4.33’de DenseNet201 modelinin kategorilendirilmiş monokristal EL görüntülerin karışıklık matrisi gösterilmiştir. Kırık özniteliği başarılı bir şekilde tahmin edilmiştir. Çatlak özniteliğinin sınıflandırma başarısında %20 civarı sapma olmuştur. Sağlam özniteliği başarısız bir sınıflandırma gerçekleşmiştir.



Şekil 4.33. Monokristal görüntülerde densenet modelinin karışıklık matrisi

Polikristal EL görüntülerinin DenseNet201 sinir ağı ile eğitilmesinden sonra çıkan başarı oranı çizelge 4.23 ve çizelge 4.24’de yer almaktadır. Çizelge 4.23’e göre sistemin genel başarı oranı %83 civarındadır. Çizelge 4.24’deki sınıflandırma raporuna göre kesinlik ölçütü en başarılı olan kırık özniteliği olmuştur. Duyarlılık ve F1-skor ölçütüne göre sağlam özniteliği en başarılı sınıflandırma olmuştur.


Çizelge 4.23. Polikristal görüntülerde densenet modelinin eğitim doğruluğu

Model	Test Doğruluğu	Eğitim Doğruluğu	Test Kaybı	Eğitim Kaybı
DenseNet201	%82,91	%90,85	0,7113	0,2609

Çizelge 4.24. Polikristal görüntülerde densenet modelinin sınıflandırma raporu


	Kesinlik	Duyarlılık	F1-Skor
Sağlam	%83	%100	%90
Çatlak	%76	%49	%59
Kırık	%98	%54	%69

Şekil 4.34’de polikristal EL görüntülerin DenseNet201 modeli ile analizi esnasında ortaya çıkan doğruluk grafiği yer almaktadır.




Şekil 4.34. Polikristal görüntülerde densenet modelinin eğitim ve test doğruluğu

Şekil 4.35’de polikristal EL görüntülerin DenseNet201 modeli ile analizi yapılırken meydana gelen kayıp grafiği yer almaktadır.



Şekil 4.35. Polikristal görüntülerde densenet modelinin eğitim ve test kayıp grafiği

Şekil 4.36’da DenseNet201 modelinin kategorilendirilmiş polikristal EL görüntülerin karışıklık matrisi gösterilmiştir. En başarılı sınıflandırma sağlam özneliğinde olmuştur. Diğer öznelikler için başarısız bir tahmin sonucu ortaya çıkmıştır.



Şekil 4.36. Polikristal görüntülerde densenet modelinin karışıklık matrisi

4.7. Monokristal EL Görüntülerin Analiz Sonuçları

Veri setindeki monokristal elektrolüminans görüntülerin evrişimli sinir ağlarında göstermiş oldukları doğruluk raporu çizelge 4.25’de yer almaktadır. Yapılan analiz sonucunda monokristal görüntüler içerisinde eğitim doğruluğu en başarılı model %81 ile Densenet201 olmuştur. Test doğruluğu en başarılı model %78 ile Xception olmuştur. Densenet201 modelin en az test ve eğitim kaybına sahiptir.

Çizelge 4.25. Monokristal görüntülerde modellerin doğruluk raporu

Model	Test Doğruluğu	Eğitim Doğruluğu	Eğitim Kaybı	Test Kaybı
Xception	%78,13	%79,65	0,5492	0,4853
Vgg16	%65,45	%68,59	0,8720	0,6856
Vgg19	%60,92	%61,43	0,7802	0,7407
Resnet50	%39,06	%47,50	0,9753	0,9779
DenseNet201	%76,56	%80,83	0,4980	0,4387
MobileNet	%76,05	%77,08	0,5980	0,5496

Çizelge 4.26’de monokristal elektrolüminans sağlam görüntülerin sınıflandırma raporu yer almaktadır. Kesinlik ölçütünde %83 ile DenseNet201 modeli en iyi sınıflandırma yapmıştır. MobileNet modeli, duyarlılık ölçütünde %91 ile en başarılı model olmuştur. F1-skor ölçütünde %82 ile MobileNet modeli en iyi performansı sergilemiştir.

Çizelge 4.26. Monokristal sağlam görüntülerde modellerin sınıflandırma raporu

	Kesinlik	Duyarlılık	F1-Skor
Xception	%72	%85	%78
Vgg16	%64	%11	%19
Vgg19	%61	%54	%58
Resnet50	%49	%74	%59
DenseNet201	%83	%65	%73
MobileNet	%74	%91	%82

Çizelge 4.27’de monokristal elektrolüminans çatlak görüntülerin sınıflandırma raporu yer almaktadır. Kesinlik ölçütünde %80 ile MobileNet modeli en iyi sınıflandırma yapmıştır. Vgg16 modeli, duyarlılık ölçütünde %93, F1-skor ölçütünde %71 ile en iyi performansı sergilemiştir. F1-skor değeri düşük çıktığı için bu ölçütte sağlıklı değerler çıkmamıştır.

Çizelge 4.27. Monokristal çatlak görüntülerde modellerin sınıflandırma raporu

	Kesinlik	Duyarlılık	F1-Skor
Xception	%79	%49	%60
Vgg16	%58	%93	%71
Vgg19	%40	%48	%44
Resnet50	%21	%18	%20
DenseNet201	%64	%79	%70
MobileNet	%80	%50	%62

Çizelge 4.28’de monokristal elektrolüminans kırık görüntülerin sınıflandırma raporu yer almaktadır. Kesinlik ölçütünde %100 ile Resnet50 modeli en iyi sınıflandırma yapmıştır. Xception modeli, duyarlılık ölçütünde %99 ile en başarılı model olmuştur. F1-skor ölçütünde %94 ile Densenet201 modeli en iyi performansı sergilemiştir.

Çizelge 4.28. Monokristal kırık görüntülerde modellerin sınıflandırma raporu

	Kesinlik	Duyarlılık	F1-Skor
Xception	%79	%99	%88
Vgg16	%83	%86	%84
Vgg19	%81	%74	%77
Resnet50	%100	%06	%11
DenseNet201	%90	%97	%94
MobileNet	%84	%86	%90

4.8.Polikristal EL Görüntülerin Analiz Sonuçları

Veri setindeki polikristal elektrolüminans görüntülerin evrişimli sinir ağlarında göstermiş oldukları doğruluk raporu çizelge 4.29’da yer almaktadır. Yapılan analiz sonucunda polikristal görüntüler içerisinde eğitim doğruluğu en başarılı model %91 ile Densenet201 olmuştur. Test doğruluğu en başarılı model %85 ile MobileNet olmuştur. Eğitim kaybı en düşük modeller MobileNet ile Xception olmuştur. Xception ve Densenet201 modelleri en az test kaybına sahiptir.

Çizelge 4.29. Polikristal görüntülerde modellerin doğruluk raporu

Model	Test Doğruluğu	Eğitim Doğruluğu	Eğitim Kaybı	Test Kaybı
Xception	%84,16	%90,39	0,4822	0,2654
Vgg16	%72,30	%79,41	0,7572	0,4988
Vgg19	%72,12	%76,14	0,6290	0,5676
Resnet50	%77,49	%80,74	0,8552	0,5078
DenseNet201	%82,91	%90,85	0,7113	0,2609
MobileNet	%85,00	%90,21	0,4767	0,2924

Çizelge 4.30'da polikristal elektrolüminans sağlam görüntülerin sınıflandırma raporu yer almaktadır. Kesinlik ölçütünde %87 ile MobileNet modeli en iyi sınıflandırma yapmıştır. Duyarlılık ölçütünde tüm modeller başarılı performans göstermiştir. F1-skor ölçütünde %93 ile MobileNet modeli en iyi performansı sergilemiştir.

Çizelge 4.30. Polikristal sağlam görüntülerde modellerin sınıflandırma raporu

	Kesinlik	Duyarlılık	F1-Skor
Xception	%84	%100	%91
Vgg16	%74	%100	%85
Vgg19	%71	%99	%83
Resnet50	%79	%100	%88
DenseNet201	%83	%100	%90
MobileNet	%87	%99	%93

Çizelge 4.31'de polikristal elektrolüminans çatlak görüntülerin sınıflandırma raporu yer almaktadır. Kesinlik ölçütünde %85 ile Xception modeli en iyi sınıflandırma yapmıştır. Duyarlılık ölçütünde tüm modellerin genel olarak performansı düşük çıkmıştır. Duyarlılık ölçütünde en başarılı model %52 ile MobileNet olmuştur. F1-skor ölçütünde de tüm modellerin performansları düşük çıkmıştır. F1-skorunda %61 ile MobileNet modeli en iyi performansı sergilemiştir.

Çizelge 4.31. Polikristal çatlak görüntülerde modellerin sınıflandırma raporu

	Kesinlik	Duyarlılık	F1-Skor
Xception	%85	%44	%58
Vgg16	%50	%10	%17
Vgg19	%23	%03	%06
Resnet50	%69	%38	%49

Çizelge 4.31. (Devamı)

	Kesinlik	Duyarlılık	F1-Skor
DenseNet201	%76	%49	%59
MobileNet	%73	%52	%61

Çizelge 4.32’de polikristal elektrolüminans kırık görüntülerin sınıflandırma raporu yer almaktadır. Kesinlik ölçütünde %98 ile DenseNet201 modeli en iyi sınıflandırma yapmıştır. Duyarlılık ölçütünde %67 ile Xception ve MobileNet modelleri en iyi sınıflandırma yapmıştır. F1-skor ölçütünde de %76 ile Xception ve MobileNet modelleri en iyi performansı sergilemiştir.

Çizelge 4.32. Polikristal kırık görüntülerde modellerin sınıflandırma raporu

	Kesinlik	Duyarlılık	F1-Skor
Xception	%86	%67	%76
Vgg16	%86	%39	%54
Vgg19	%92	%29	%44
Resnet50	%77	%32	%45
DenseNet201	%98	%54	%69
MobileNet	%86	%67	%76

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında güneş panel hücrelerinde meydana gelen hasarlar, evrişimli sinir ağı modelleri sayesinde tespit edilmeye çalışılmıştır. Veri setindeki FV hücreler monokristal ve polikristal şeklinde ayrı ayrı değerlendirilmiştir. FV hücrelere ait elektrolüminans görüntüler sağlam, çatlak ve kırık şeklinde sınıflandırılmıştır. Elde edilen görüntü sayısı az olduğu için başarılı sınıflandırma yapabilmek için evrişimli sinir ağı modelleri kullanılmıştır. Sınıflandırılan görüntüler CNN modellerinde ayrı ayrı eğitilerek, sınıflandırma oranları incelenmiştir.

Çalışmada, öz niteliklere ait sınıflandırma yöntemlerinin başarı değerleri istatistiksel olarak analiz edilmiştir. Analiz sonucunda monokristal panel hücrelerinin sınıflandırma başarısı %78, polikristal panel hücrelerinin sınıflandırma başarısı %85 çıkmıştır. Fakat genel sınıflandırma başarısına göre monokristal panel hücreleri daha iyi sınıflandırılmıştır. Veri setindeki sağlam polikristal hücre sayısının fazla olması nedeniyle sınıflandırma başarısı daha yüksek gözükmemektedir.

Sağlam panel hücrelerinin sınıflandırılmasında; monokristal hücrelerinin başarısı %91, polikristal hücrelerin ise %100 oranındadır. Kırık panel hücrelerinin sınıflandırılmasında; monokristal hücrelerin başarısı %99, polikristal hücrelerin ise %76 oranındadır. Çatlak panel hücrelerinin sınıflandırılmasında; monokristal hücrelerin sınıflandırma başarısı %79, polikristal hücrelerin ise %76 oranındadır.

Literatür çalışmalarına bakıldığında sınıflandırma için genellikle derin öğrenme algoritmalarının kullanıldığı gözükmemektedir. Yapmış olduğum çalışmada; monokristal yapıdaki sağlam panel hücrelerini sınıflandırma başarısı, yapılan çalışmalar ile benzer oranlarda çıkmıştır. Polikristal yapıdaki sağlam panel hücrelerini sınıflandırma başarısı, benzer çalışmalara göre daha başarılı sonuç ortaya koymuştur. Polikristal yapıdaki kırık panel hücrelerini sınıflandırma başarısı, yapılan birçok çalışma ile benzer oranda çıkmıştır. Monokristal ve polikristal çatlak panel hücrelerin sınıflandırma başarısı, benzer çalışmalara göre daha düşük sınıflandırma oranına sahiptir.

Elde edilen doğruluk ve sınıflandırma raporlarına göre monokristal güneş hücrelerinin, polikristal güneş hücrelerine göre daha başarılı sınıflandırıldığı tespit edilmiştir. Polikristal güneş hücrelerinin üretildiği malzemeden dolayı heterojen bir yapıya sahip olması, görüntü analizi esnasında modellerin sınıflandırma başarı oranının azalmasına neden olmuştur. Monokristal güneş hücreleri homojen bir yapıya sahip olduğu için görüntülerin sınıflandırma başarı oranının arttırdığı görülmüştür. Güneş panel hücrelerinin CNN modelleri ile analiz sürelerine bakıldığında polikristal EL güneş hücrelerinin, monokristal EL güneş hücrelerine göre daha fazla zaman aldığı tespit edilmiştir.

Monokristal ve polikristal güneş hücrelerinde, kırık durumdaki güneş hücrelerinin CNN modelleri ile tespit oranının yüksek olduğu görülmüştür. Çatlak durumdaki güneş hücrelerinin başarılı sınıflandırma oranı, kırık güneş hücrelerine göre daha düşük çıkmıştır. Modelleme sonrası, sağlam polikristal güneş hücrelerinin sınıflandırma başarısı, monokristal güneş hücrelerine göre daha yüksek olduğu görülmüştür. Buna karşılık kırık ve çatlak monokristal güneş hücrelerinin sınıflandırma başarısı, polikristal güneş hücrelerine göre daha yüksek çıktığı tespit edilmiştir.

Güneş panel hücrelerindeki mikro kırıkların sınıflandırılması genel başarı oranını düşürmektedir. Görüntüler sağlam ve hasarlı şeklinde kategorilere ayrılarak analiz yapılırsa sınıflandırma başarısı daha da yükselecektir. Hazır görüntüleri kullanmak yerine teknik ekipman sağlanarak, güneş panel santrallerinden daha net görüntüler alınabilir. Bu görüntüleri analiz etmek daha özgün çalışmaların ortaya çıkmasını sağlayacaktır.

Geliştirilen model ile güneş enerji santrallerindeki panellerden elde edilen EL görüntüler bulut teknolojisi sayesinde depolama birimine yüklenerek, görüntüler anında analiz edilerek başarılı sınıflandırma gerçekleştirilebilir.

KAYNAKLAR

- Abdulghani, S., Fadhil, A., & Gültekin, S. S. (2020). Transfer Learning using Alexnet with Support Vector Machine for Breast Cancer Detection. *Avrupa Bilim ve Teknoloji Dergisi*, 423-430. doi:10.31590/ejosat.806679
- Acharya, A. K., Sahu, P. K., & Jena, S. R. (2021). Deep Neural Network Based Approach for Detection of Defective Solar Cell. *Materials Today: Proceedings*, 39(5), 2009-2014.
- Bahtiyar, B. (2006). *Fotovoltaik Sistemler İçin Gerçek Zamanlı Bir İzleme Merkezi Tasarım ve Uygulaması*. Yayımlanmamış Yüksek Lisans Tezi, Muğla Üniversitesi, Fen Bilimleri Enstitüsü, Muğla.
- Bothe, K., Pohl, P., Schmidt, J., Weber, T., Altermatt, P., Fischer, B., & Brendel, R. (2006). Electroluminescence Imaging as an In-Line Characterisation Tool For Solar Cell Production. *In 21st European Photovoltaic Solae Energy Conference*, (pp. 597-600). Germany.
- Breitenstein, O., Bauer, J., Bothe, K., Hinken, D., Müller, J., Kwapil, W., & Schubert, M. C. (2011). Can Luminescence Imaging Replace Lock-In Thermography On Solar Cells And Wafers? *37th IEEE Photovoltaic Specialists Conference* (pp. 159-167). USA: IEEE. doi:10.1109/PVSC.2011.6185846
- Buerhop-Lutz, C., Deitsch, S., Maier, A., Gallwitz, F., Berger, S., & Doll, B. (2018). A benchmark for visual identification of defective solar cells in electroluminescence imagery. *In 35th European PV Solar Energy Conference and Exhibition*. Belgium.
- Cengil, E., & Çınar, A. (2019). Classification of Human Driving Behaviour Images Using Convolutional Neural Network Architecture. *In International Conference on Hybrid Artificial Intelligence Systems*, 11734, pp. 264-274. doi:10.1007/978-3-030-29859-3_23
- Chindarkkar, A., Priyadarshi, S., Shiradkar, N. S., Kottantharayil, A., & Velmurugan, R. (2020). Deep Learning Based Detection of Cracks in Electroluminescence Images of Fielded PV modules. *In 2020 47th IEEE Photovoltaic Specialists Conference* (pp. 1612-1616). Canada: IEEE. doi:10.1109/PVSC45281.2020.9300615
- Chollet, F. (2017). Xception: Deep Learning With Depthwise Separable Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (pp. 1251-1258).
- Çalışkan, D., & Demir, Ö. (2022). Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti. *International Periodical of Recent Technologies in Applied Engineering*, 3(1), 28-43.
- Deitsch, S., Christlein, V., Berger, S., Buerhop-Lutz, C., Maier, A., Gallwitz, F., & Riess, C. (2019). Automatic Classification of Defective Photovoltaic Module Cells in

- Electroluminescence Images. *Solar Energy*, 185, 455-468. doi:10.1016/j.solener.2019.02.067
- Demirci, M. Y., Bešli, N., & Gümüşçü, A. (2019). Defective PV Cell Detection Using Deep Transfer Learning and EL Imaging. *International Conference on Data Science, Machine Learning and Statistics - 2019*, (pp. 311-314). Van.
- Doğan, F., & Türkoğlu, İ. (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Doğan, F., & Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Fan, J., Lee, J. H., & Lee, Y. (2021). Application of Transfer Learning for Image Classification on Dataset with Not Mutually Exclusive Classes. In *2021 36th International Technical Conference on Circuits/Systems, Computers and Communications* (pp. 1-4). South Korea: IEEE. doi:10.1109/ITC-CSCC52171.2021.9501424
- Fan, T., Sun, T., Xie, X., Liu, H., & Na, Z. (2022). Automatic Micro-Crack Detection of Polycrystalline Solar Cells in Industrial Scene. *IEEE Access*, 10, 16269-16282. doi:10.1109/access.2022.3145980
- Fırıldak, K., & Talu, M. F. (2019). Evrimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Anatolian Journal of Computer Science*, 4(2), 8895.
- Grunow, P., Clemens, P., Hoffmann, V., Litzenburger, B., & Podlowski, L. (2005). Influence Of Micro Cracks in Multi-Crystalline Silicon Solar Cells on The Reliability of Pv Modules. *20th European Photovoltaic Solar Energy Conference*, (pp. 2380-2383). Spain.
- Gürbüz, D. (2018). *Kir Ve Tozlanmanın Fotovoltaik Sistem Verimi Üzerindeki Etkisi*. Yayımlanmamış Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning For Image Recognition. In *Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition*, (pp. 770-778).
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., & Andreetto, M. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *Computer Vision and Pattern Recognition*, (pp. 1-9). doi:10.48550/arxiv.1704.04861
- Huang, G., Liu, S., Van Der Maaten, L., & Weinberger, K. Q. (2016). Densely Connected Convolutional Networks. In *Proceedings of The IEEE Conference On Computer Vision And Pattern Recognition*, (pp. 4700-4708). doi:10.48550/arxiv.1608.06993

- Huang, G., Liu, S., Van Der Maaten, L., & Weinberger, K. Q. (2018). Condensenet: An Efficient Densenet Using Learned Group Convolutions. *In Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition*, (pp. 2752-2761). doi:10.48550/arxiv.1711.09224
- Hubel, D. H., & Wiesel, T. N. (1968). Receptive Fields and Functional Architecture of Monkey Striate Cortex. *The Journal of Physiology*, 195(1), 215-243.
- İbrahim, M. S. (2020). *Evrişimsel Sinir Ağları Tabanlı Gürültü Giderici Otomatik Kodlayıcı Kullanarak Görüntüyü Gürültüden Arındırma*. Yayımlanmamış Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Proceedings of the 32nd International Conference on Machine Learning*, (pp. 448-456).
- İnternet: Akdoğan, A. (Haziran, 2020). *Uygulamalı Evrişimsel Sinir Ağları*. URL: <https://medium.com/bilisim-hareketi/uygulamali-evrisimsel-sinir-aglari-convolutional-neural-network-7d643eae6a7>. Son Erişim Tarihi: 10.05.2022.
- İnternet: Çolakoğlu, M., Aslan, S., İyikul, E., & Özenbaş, M. (Aralık, 2021). *Türkiye’de Güneş Enerjisi ve Panel Üretim Faaliyetleri*. URL: <https://www.pwc.com.tr/tr/sektorler/enerji/turkiye-ve-dunyada-gunes-enerjisi-sektoru-raporu.pdf>. Son Erişim Tarihi: 12.05.2022.
- İnternet: Deniz, E. (Mayıs, 2013). *Güneş Enerjisi Santrallerinde Kayıplar*. URL: https://www.emo.org.tr/ekler/38f0038bf09a40b_ek.pdf. Son Erişim Tarihi: 04.05.2022.
- İnternet: Elektrikport. (Şubat, 2021). *Güneş Panellerinde En Sık Yaşanan 8 Sorun*. URL: <https://www.elektrikport.com/haber-roportaj/gunes-panellerinde-en-sik-yasanan-8-sorun/23071>. Son Erişim Tarihi: 20.05.2022.
- İnternet: ETKB. (Mayıs, 2021). *Güneş*. URL: <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes>. Son Erişim Tarihi: 12.05.2022.
- İnternet: Jeong, J. (January, 2019). *The Most Intuitive and Easiest Guide for Convolutional Neural Network*. URL: <https://towardsdatascience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>. Son Erişim Tarihi: 20.04.2022.
- İnternet: Kaz, A. İ. (Aralık, 2021). *Güneş Panellerinde Hotspot (Sıcak Nokta) Sorunu*. URL: <https://muhendistan.com/gunes-panellerinde-hotspot-sicak-nokta-sorunu>. Son Erişim Tarihi: 21.04.2022.
- İnternet: Kızrak, M. A. (Şubat, 2019). *Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması*. URL: <https://ayyucekizrak.medium.com/derin-ogrenme-icin-aktivasyon-fonksiyonlarinin-karsilastirilmasi-cee17fd1d9cd>. Son Erişim Tarihi: 12.05.2022.

- İnternet: Öğündür, G. (Kasım, 2019). *Doğruluk (Accuracy) , Kesinlik(Precision) , Duyarlılık(Recall) ya da F1 Score?*. URL: <https://medium.com/@gulcanogundur/dogruluk-accuracy-kesinlik-precision-duyarlilik-recall-ya-da-f1-score-300c925feb38>. Son Erişim Tarihi: 22.05.2022.
- İnternet: Solar Çatı. (Nisan, 2021). *Gölge Etkenlerinin Olumsuz Etkileri ve Kaçınma Yolları*. URL: <https://solarcati.com/golge-etkenlerinin-olumsuz-etkileri-ve-kacinma-yollari>. Son Erişim Tarihi: 10.04.2022.
- İnternet: Sönmez, D. (Haziran, 2018). *Geri Yayılım Algoritmasına Matematiksel Yaklaşım*. URL: <https://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasına-matematiksel-yaklasim>. Son Erişim Tarihi: 12.04.2022.
- İnternet: Uyar, F. (Kasım, 2015). *Güneş Panelleri ve Hot Spot Etkisi*. URL: <https://www.enerjibes.com/gunes-panelleri-ve-hot-spot-etkisi>. Son Erişim Tarihi: 21.03.2022.
- İnternet: Yılmaz, E. (Nisan, 2021). *Monokristal ve Polikristal Güneş Panelleri Arasındaki Fark Nedir?*. URL: <https://www.aydinlatma.org/monokristal-ve-polikristal-gunes-panelleri-arasindaki-fark-nedir.html>. Son Erişim Tarihi: 20.03.2022.
- Jain, V., & Seung, H. S. (2008). Natural Image Denoising With Convolutional Networks. *Advances in Neural Information Processing Systems*, (p. 21).
- Karimi, A. M., Fada, J. S., Hossain, M. A., Yang, S., Peshek, T. J., Braid, J. L., & French, R. H. (2019). Automated Pipeline for Photovoltaic Module Electroluminescence Image Processing and Degradation Feature Classification. *IEEE Journal of Photovoltaics*, 9(5), 1324-1335. doi:10.1109/jphotov.2019.2920732
- Kartal, M., & Duman, O. (2019). Ship Detection From Optical Satellite Images With Deep Learning. *2019 9th International Conference on Recent Advances in Space Technologies (RAST)* (pp. 479-484). İstanbul: IEEE. doi:10.1109/rast.2019.8767844
- Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455-5516. doi:10.1007/s10462-020-09825-6
- Kızrak, M. A., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286. doi:10.17671/gazibtd.419205
- Koch, S., Weber, T., Fladung, A., & Sobottka, C. (2016). Outdoor electroluminescence imaging of crystalline photovoltaic modules: Comparative study between manual ground-level inspections and drone-based aerial surveys. In *32nd European Photovoltaic Solar Energy Conference and Exhibition*, (pp. 1736-1740).
- Korkmaz, S. (2019). Small Drug Molecule Classification Using Deep Neural Networks. *Türkiye Klinikleri Journal of Biostatistics*, 11(2), 93-101. doi:10.5336/biostatic.2019-64948

- Köntges, M., Kurtz, S., Packard, C., Jahn, U., Berger, K. A., Kato, K., & Friesen, T. (2014). *Review of Failures of Photovoltaic Modules*. IEA - International Energy Agency.
- Köroğlu, T., Teke, A., Bayındır, K. Ç., & Tümay, M. (2010). Güneş Paneli Sistemlerinin Tasarımı. *Elektrik Mühendisliği*(439), 98-104.
- Kurt, M. S. (2018). *Derin Öğrenme Modelleri ile Web Sayfası Sınıflandırma*. Yayımlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Kutlu, Ö. (2019). *İnsansız Hava Aracı ile Elde Edilen Görüntülerin Derin Öğrenme Yöntemleri ile Analizi*. Yayımlanmamış Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Laronde, R., Charki, A., & Bigaud, D. (2010). Reliability of Photovoltaic Modules Based On Climatic Measurement Data. *International Journal of Metrology and Quality Engineering*, 1(1), 45-49.
- Li, D. H., & Lam, T. N. (2007). Determining The Optimum Tilt Angle and Orientation for Solar Energy Collection Based on Measured Solar Radiance Data. *International Journal of Photoenergy*, 1-9.
- Li, Y. (2011). Photovoltaic Systems for Solar Electricity Production. *The Ohio University Extension, Agriculture and Natural Resources*, 1-3.
- Liu, W., Li, W., Sun, L., Zhang, L., & Chen, P. (2017). Finger vein recognition based on deep learning. *12th IEEE Conference on Industrial Electronics and Applications (ICIEA)* (pp. 205-210). Cambodia: IEEE. doi:10.1109/ICIEA.2017.8282842
- Maghami, M. R., Hizam, H., Gomes, C., Radzi, M. A., Rezaded, M. I., & Hajighorbani, S. (2016). Power Loss Due to Soiling on Solar Panel: A Review. *Renewable and Sustainable Energy Reviews*, 59, 1307-1316. doi:10.1016/j.rser.2016.01.044
- Mantel, C., Villebro, F., Benatto, G. A., Parikh, H. R., Wendlandt, S., Hossain, K., & Forchhammer, S. (2019). Machine Learning Prediction of Defect Types For Electroluminescence Images of Photovoltaic Panels. *Applications of Machine Learning*, 11139, 1113904. doi:doi.org/10.1117/12.2528440
- Mathias, N., Shaikh, F., Thakur, C., Shetty, S., Dumane, P., & Chavan, D. (2020). Detection of Micro-Cracks in Electroluminescence Images of Photovoltaic Modules. *In Proceedings of the 3rd International Conference on Advances in Science & Technology (ICAST)*, (pp. 342-347). Ethiopia. doi:10.2139/ssrn.3563821
- Özçelik, S. (2016). *Fotovoltaik (PV) Teknolojileri*. Ankara: Gazi Üniversitesi, Fotonik Uygulama ve Araştırma Merkezi.
- Patel, M. R. (1999). *Wind and Solar Power Systems*. USA: CRC Press LLC.

- Pingel, S., Zemen, Y., Frank, O., Geipel, T., & Berghold, J. (2009). Mechanical stability of solar cells within solar panels. In *Proceedings of the 24th EUPVSEC*, (pp. 3459-3464). Germany.
- Qian, X., Li, J., Cao, J., Wu, Y., & Wang, W. (2020). Micro-cracks detection of solar cells surface via combining short-term and long-term deep features. *Neural Networks*, 127, 132-140. doi:10.1016/j.neunet.2020.04.012
- Rahman, M. R., Tabassum, S., Haque, E., Nishat, M. M., Faisal, F., & Hossain, E. (2021). CNN-based Deep Learning Approach for Micro-crack Detection of Solar Panels. In *2021 3rd International Conference on Sustainable Technologies for Industry 4.0 (STI)* (pp. 1-6). Bangladesh: IEEE. doi:10.1109/STI53101.2021.9732592
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2017). Deep Learning for Health Informatics. *IEEE journal of Biomedical and Health Informatics*, 21(1), 4-21. doi:10.1109/JBHI.2016.2636665
- Salvadores, C., & Francisco, J. (2015). *Shadowing effect on the performance in solar PV-cells*. Master's Thesis, Gävle University, Faculty of Engineering and Sustainable Development, Sweden.
- Samtaş, G., & Gülesin, M. (2012). Sayısal Görüntü İşleme Ve Farklı Alanlardaki Uygulamaları. *Electronic Journal of Vocational Colleges (Ejovoc)*, 2(1), 85-97.
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *International Conference on Learning Representations (ICLR 2015)*, (pp. 1-6). Canada.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929-1958.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Taherbaneh, M., Rezaie, A. H., Ghafoorifard, H., Rahimi, K., & Menhaj, M. B. (2010). Maximizing Output Power of a Solar Panel via Combination of Sun Tracking and Maximum Power Point Tracking by Fuzzy Controllers. *International Journal of Photoenergy*, 1-13. doi:10.1155/2010/312580
- Tan, Z. (2019). *Derin öğrenme yardımıyla araç sınıflandırma*. Yayımlanmamış Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Tao, J., Gu, Y., Sun, J., Bie, Y., & Wang, H. (2021). Research on vgg16 convolutional neural network feature classification algorithm based on Transfer Learning. *2021 2nd China International SAR Symposium (CISS)* (pp. 1-3). China: IEEE. doi:10.23919/CISS51089.2021.9652277

- Tayiz, M. M. (2022). *Derin Öğrenme ve Ses İşleme Yöntemleri ile Türkçe Videolardaki Küfürlü Seslerin Tespit Edilmesi ve Sansürlenmesi*. Yayınlanmamış Yüksek Lisans Tezi, Van Yüzüncü Yıl Üniversitesi, Fen Bilimleri Enstitüsü, Van.
- Teo, T. W., & Abdullah, M. Z. (2018). Solar cell micro-crack detection using localised texture analysis. *Journal of Image and Graphics*, 6(1), 54-58.
- Tsai, D. M., & Luo, J. Y. (2010). Mean Shift-Based Defect Detection in Multicrystalline Solar Wafer Surfaces. *IEEE Transactions on Industrial Informatics*, 7(1), 125-135. doi:10.1109/TII.2010.2092783
- Tsai, D. M., Wu, S. C., & Li, W. C. (2012). Defect detection of solar cells in electroluminescence images using Fourier image reconstruction. *Solar Energy Materials and Solar Cells*, 99, 250-262. doi:10.1016/j.solmat.2011.12.007
- Tüzün, B. N. (2022). *Derin Öğrenme Modelleri Kullanılarak Beyin ve Beyne Etki Eden Bazı Tümörlerin Sınıflandırılması*. Yayınlanmamış Yüksek lisans tezi, Kütahya Dumlupınar Üniversitesi, Lisansüstü Eğitim Enstitüsü, Kütahya.
- Uysal, F., Hardalaç, F., & Koç, M. (2018). Classification of T1 and T2 weighted magnetic resonance prostate images using convolutional neural networks. *2018 Medical Technologies National Congress (TIPTEKNO)* (pp. 1-4). Cyprus: IEEE. doi:10.1109/TIPTEKNO.2018.8596792
- Winston, D. P., Murugan, M. S., Elavarasan, R. M., Pugazhendhi, R., Singh, O. J., & Murugesan, P. (2021). Solar PV's Micro Crack and Hotspots Detection Technique Using NN and SVM. *IEEE Access*, 9, 127259 - 127269. doi:10.1109/ACCESS.2021.3111904
- Yılmaz, M. (2012). Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. *Ankara Üniversitesi, Çevre Bilimleri Dergisi*, 4(2), 33-54. doi:10.1501/Csaum_0000000064
- Zhang, N., Shan, S., Wei, H., & Zhang, K. (2020). Micro-cracks Detection of Polycrystalline Solar Cells with Transfer Learning. *Journal of Physics: Conference Series, ICAITA 2020*, 1651, p. 15. China. doi:10.1088/1742-6596/1651/1/012118
- Zheng, Y., Yang, C., & Merkulov, A. (2018). Breast cancer screening using convolutional neural network and follow-up digital mammography. *Computational Imaging III*, 10669, pp. 1-13. San Francisco. doi:10.1117/12.2304564

ÖZGEÇMİŞ

Adı-Soyadı : Yücel KOÇ

Eğitim Derecesi	Okul/Program	Mezuniyet Yılı
Lisans	Selçuk Üni., Bilgisayar Öğrt.	2002 – 2006

İş Deneyimi/Yıl	Çalıştığı Yer
2007-2010	Eziler Mustafa Kaçmaz İlköğretim Okulu
2010-2011	Güney Çok Programlı Lisesi
2011 - Halen	Toruntay Mesleki ve Teknik Anadolu Lisesi

Yabancı Dil

İngilizce

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

1-) Koç, Y., Ünal, Y. (2021). Classification of Electroluminescence Images of Solar Cells Using Mobilenet, International Conference on Engineering Technologies, ICENTE'21 Konya, Turkey, November 18-20, 2021, 40-42. E-ISBN: 978-625-44427-7-3