

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÜNEŞ PANELİ KUSURLARININ DERİN ÖĞRENME TABANLI
SINIFLANDIRILMASI

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

SEBAHATTİN YİĞİT LERMİ

TEMMUZ 2024

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÜNEŞ PANELİ KUSURLARININ DERİN ÖĞRENME TABANLI
SINIFLANDIRILMASI

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Sebahattin Yiğit LERMİ

DANIŞMAN: Dr. Öğr. Üyesi Tuğba Özge ONUR

ZONGULDAK

Temmuz 2024

KABUL:

Sebahattin Yiğit LERMİ tarafından hazırlanan “Güneş Paneli Kusurlarının Derin Öğrenme Tabanlı Sınıflandırılması” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 24/07/2024

Danışman: Dr. Öğr. Üyesi Tuğba Özge ONUR
Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-
Elektronik Mühendisliği Bölümü

Üye: Doç. Dr. Rukiye Uzun ARSLAN
Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-
Elektronik Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Kenan ÖZEL
Ankara Üniversitesi, Gama Meslek Yüksekokulu, Elektrik ve Enerji Bölümü

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım./....../20....

Prof. Dr. Fikret GÖLGELEYEN
Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Sebahattin Yiğit LERMİ

ÖZET

Yüksek Lisans Tezi

GÜNEŞ PANELİ KUSURLARININ DERİN ÖĞRENME TABANLI SINIFLANDIRILMASI

Sebahattin Yiğit LERMİ

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Tuğba Özge ONUR

Temmuz 2024,75 sayfa

Yenilenemez enerji kaynaklarının çevreye ve ekolojiye verdiği zararlar, yenilenebilir enerji kaynaklarına olan ilginin artmasına neden olmaktadır. Fotovoltaik (FV) enerji üretimi, temiz ve sürdürülebilir enerji üretimi için mükemmel enerji alternatiflerinden biridir. FV paneller üzerindeki kar, toz, kuş pisliği, mekaniksel hasar, fiziksel hasar ve gölgelenme gibi etkenler enerji üretimindeki verimi azaltmaktadır ve bu yüzden panel bakımı düzenli olarak yapılmalıdır. Bakımlar manuel olarak yapıldığında hatalar olmakta ve uzun zaman almaktadır. Bu nedenle güneş paneli kusurları son zamanlarda geliştirilen görüntü işleme ve derin öğrenme algoritmaları kullanılarak tespit edilebilmektedir.

Bu çalışmada, derin öğrenme tekniği kullanılarak güneş panelleri üzerinde hasar tespiti sınıflandırması yapılmıştır. Çalışma iki aşamadan oluşmaktadır. İlk aşama, ön işleme aşamasıdır ve bu aşamada veri setinin yetersiz olması nedeniyle veri seti görüntüyü döndürme, görüntünün simetriğini alma ve görüntüye gürültü ekleme gibi veri çoğaltma teknikleri kullanılarak arttırılmıştır. İkinci aşama olan eğitim aşamasında ise çoğaltılan veri seti önerilen

ÖZET (devam ediyor)

derin öğrenme modeliyle eğitilmiştir. Ayrıca veri seti önceden eğitilmiş VGG-19, InceptionV3 ve Resnet101 modelleriyle de eğitilmiş ve sonuçlar önerilen modelle karşılaştırılmıştır. Eğitim sonucunda önerilen modelin 7 farklı kusurun sınıflandırılmasında %97,19 başarıyla sınıflandırma yapabildiği gözlenmiştir.

Anahtar Kelimeler: Evrişimli sinir ağları, derin öğrenme, güneş panelleri, fotovoltaiik, veri çoğaltma, sınıflandırma.

Bilim Kodu: 608.05.00, 608.05.02



ABSTRACT

M. Sc. Thesis

CLASSIFICATION OF SOLAR PANELS DEFECTS BASED ON DEEP LEARNING

Sebahattin Yiğit LERMİ

Zonguldak Bülent Ecevit University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Thesis Advisor: Assist. Prof. Dr. Tuğba Özge ONUR

July 2024, 75 pages

The damage caused by non-renewable energy sources to the environment and ecology causes an increase in interest in renewable energy sources. Photovoltaic (PV) energy production is one of the excellent energy alternatives for clean and sustainable energy production. Factors such as snow, dust, bird droppings, mechanical damage, physical damage and shading on PV panels reduce the efficiency in energy production, and therefore panel maintenance should be done regularly. When maintenance is done manually, errors occur and it takes a long time. Therefore, solar panel defects can be detected using recently developed image processing and deep learning algorithms.

In this study, damage detection classification was made on solar panels using the deep learning technique. The study consists of two stages. The first stage is the pre-processing stage, and at this stage, due to insufficient data set, it is increased by using data augmentation techniques such as rotating the image, taking the symmetry of the image and adding noise to the image. In the second stage, the training stage, the replicated data set was trained with the proposed deep learning model. In addition, the dataset was trained with pre-trained VGG-19, InceptionV3 and

ABSTRACT (continued)

Resnet101 models and the results were compared with the proposed model. As a result of the training, it was observed that the proposed model was able to classify 7 different defects with a success rate of 97,19%.

Keywords: Convolutional neural networks, deep learning, solar panels, Photovoltaic, data augmentation, classification.

Science Code: 608.05.00, 608.05.02



TEŞEKKÜR

Tez çalışma süresi boyunca yardım ve katkılarıyla beni yönlendiren saygıdeğer hocam Dr. Öğr. Üyesi Tuğba Özge ONUR’a teşekkürlerimi sunarım.

Her daim eşsiz sevgi ve desteklerini hissettiren, tüm fedakarlıklarıyla başarımda en büyük payı olan değerli aileme teşekkürlerimi sunarım.





İÇİNDEKİLER

	<u>Sayfa</u>
KABUL:	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xv
SİMGELER VE KISALTMALAR DİZİNİ	xvii
BÖLÜM 1 GİRİŞ	1
BÖLÜM 2 GÜNEŞ ENERJİSİ VE PANELLERİ	7
2.1 GÜNEŞ ENERJİSİ	7
2.2 GÜNEŞ PANELLERİ	8
2.3 GÜNEŞ PANELİ SİSTEMİ ELEMANLARI	9
2.3.1 Güneş Panelleri	9
2.3.2 Dönüştürücü	9
2.3.3 Solar Şarj Kontrol Cihazı	9
2.3.4 Akü	9
2.4 FV HÜCRELERİN YAPISI VE ÇALIŞMA PRENSİBİ	9
2.4.1 FV Hücrelerin Yapısı	10
2.4.2 FV Hücrelerin Çalışma Prensibi	11
2.5 FV HÜCRE, MODÜL VE DİZİ	12
2.5.1 FV Hücre	12
2.5.2 FV Modül	12

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
2.5.3 FV Dizi.....	12
2.6 GÜNEŞ PANELİ TÜRLERİ.....	13
2.6.1 Kristal Silikon Güneş Panelleri.....	13
2.6.2 İnce Film Teknolojileri	14
2.7 GÜNEŞ PANELLERİNİN AVANTAJLARI VE DEZAVANTAJLARI	15
2.7.1 Güneş Panellerinin Avantajları	15
2.7.2 Güneş Panellerinin Dezavantajları.....	16
2.8 GÜNEŞ PANELİ SİSTEMLERİNDE OLABİLECEK KUSURLAR.....	17
2.8.1 Gölgeleme	17
2.8.2 Kuş Pisliği.....	18
2.8.3 Tozlanma.....	18
2.8.4 Elektriksel Hasar	19
2.8.5 Fiziksel Hasar.....	19
2.8.6 Karlanma.....	20
BÖLÜM 3 DERİN ÖĞRENME TABANLI GÜNEŞ PANELİ KUSURLARI	
SINIFLANDIRILMASI	21
3.1 DERİN ÖĞRENME	21
3.2 EVRİŞİMLİ SINIR AĞLARI	23
3.2.1. ESA'yı Oluşturan Katmanlar	24
3.2.1.1 Giriş Katmanı	24
3.2.1.2 Konvolüsyon Katmanı (Evrışim Katmanı)	24
3.2.1.3 Aktivasyon Katmanı.....	27
3.2.1.3.1 Sigmoid Fonksiyonu.....	27
3.2.1.3.2 ReLU	28
3.2.1.3.3 Hiperbolik Tanjant Fonksiyonu.....	29
3.2.1.4 Havuzlama Katmanı.....	30
3.2.1.5 Düzleştirme Katmanı.....	31
3.2.1.6 Tam Bağlantılı Katman	31
3.2.1.7 Seyreltme Katmanı	32
3.2.1.8 Sınıflandırma Katmanı	33

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
3.2.2 Batch Boyutu	34
3.2.3 Kayıp Fonksiyonu	34
3.2.3.1 Kategorik Çapraz Entropi (Categorical Crossentropy)	34
3.2.3.2 İkili Çapraz Entropi (Binary Cross-Entropy)	35
3.2.3.3 Seyrek Kategorik Çapraz Entropi (Sparse Categorical Cross-Entropy)	35
3.2.3.4 Ortalama Karesel Hata (Mean Squared Error -MSE)	35
3.2.4 Eğitim Tur (Epok) Sayısı	36
3.2.5 Modelin Öğrenme Oranı	36
3.2.6 Optimizasyon Çeşitleri.....	36
3.2.6.1 Gradyan Azalması (Gradient Descent-GD)	36
3.2.6.1.1 Toplu Gradyan Azalması (Batch Gradient Descent-BGD)	37
3.2.6.1.2 Stokastik Gradyan Azalması (Stochastic Gradient Descent-SGD)	37
3.2.6.1.3 Mini Toplu Gradyan Azalması (Mini-Batch Gradient Descent)	38
3.2.6.2 Uyarlanabilir Gradyan Azalması (Adaptive Gradient Descent-AdaGrad)	38
3.2.6.3 Uyarlanabilir Delta (Adaptive Delta-AdaDelta)	38
3.2.6.4 Karekök Ortalama Yayılımı (Root Mean Square Propagation-RMSProp).....	38
3.2.6.5 Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation-Adam)	39
3.2.6.6 Maksimum Uyarlanabilir Moment Tahmini (Maximum Adaptive Moment Estimation-AdaMax).....	39
3.2.7 Transfer Öğrenme	39
3.2.7.1 Görsel Geometri Grubu (Visual Geometry Group-VGG).....	40
3.2.7.2 ResNet	40
3.2.7.3 InceptionV3 (GoogLeNet)	41
3.2.7.4 Xception	41
3.2.7.5 DenseNet	41
BÖLÜM 4 BULGULAR.....	43
4.1 GÜNEŞ PANELİ VERİ SETİ.....	43
4.2 ÖN İŞLEM ADIMLARI	45

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
4.2.1 Görüntüyü Döndürme	45
4.2.2 Görüntünün x ve y Eksenlerine Göre Simetriğini Alma.....	46
4.2.3 Görüntüye Gürültü Ekleme	47
4.3 PERFORMANS METRİKLERİ	48
4.3.1 Karışıklık Matrisi	48
4.4 ÖNERİLEN MODEL	49
4.5 DENEYSEL SONUÇLAR	51
4.5.1 VGG-19 Modeli Sonuçları.....	51
4.5.2 InceptionV3 Modeli Sonuçları.....	54
4.5.3 Resnet101 Modeli Sonuçları.....	57
4.5.3 Önerilen Modelin Sonuçları.....	60
BÖLÜM 5 SONUÇLAR.....	65
KAYNAKLAR.....	67
ÖZGEÇMİŞ	75

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Yakın geçmişte ve gelecekte güneş enerjisi kullanımının evrimi	7
Şekil 2.2 FV sistemin çalışma yapısı	8
Şekil 2.3 FV hücrenin basit yapısı	10
Şekil 2.4 FV hücrelerin çalışma prensibi	11
Şekil 2.5 FV Hücre, Modül ve Dizi	12
Şekil 2.6 Monokristal ve Polikristal Güneş paneli	13
Şekil 2.7 İnce film güneş paneli	14
Şekil 2.8 Gölgelemiş güneş paneli	17
Şekil 2.9 Kuş pisliği olan güneş paneli	18
Şekil 2.10 Tozlanmış güneş paneli	18
Şekil 2.11 Elektriksel hasarlı güneş paneli	19
Şekil 2.12 Fiziksel hasarlı güneş paneli	19
Şekil 2.13 Karla kaplanmış güneş paneli	20
Şekil 3.1 YSA modeli	22
Şekil 3.2 ESA bileşenleri	23
Şekil 3.3 Özellik haritası	24
Şekil 3.4 Konvolüsyon işlemi uygulanma örneği	25
Şekil 3.5 Sigmoid fonksiyonu grafiği	27
Şekil 3.6 ReLU fonksiyonunun çıkış verisi üzerinde gösterdiği etki	28
Şekil 3.7 ESA modelinde ReLU katmanının görüntüye yapmış olduğu etki	29
Şekil 3.8 Tanh fonksiyonu grafiği	29
Şekil 3.9 Maksimum ve Ortalama havuzlama örneği	30
Şekil 3.10 Giriş görseline konvolüsyon ve maksimum havuzlama uygulanması sonrası oluşan görüntüler	30
Şekil 3.11 Düzleştirme katmanı örneği	31
Şekil 3.12 Tam bağlantılı katman yapısı	32

ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Şekil 3.13 Standart bir ESA ağına seyreltme katmanının uygulanması	33
Şekil 3.14 GD Algoritması	37
Şekil 3.15 VGG-16 mimarisi	40
Şekil 4.1 Veri setinden örnekler	44
Şekil 4.2 Veri seti üzerinde görüntü işleme tekniklerinden döndürme örneği.....	46
Şekil 4.3 Veri seti üzerinde görüntü işleme tekniklerinden simetriğini alma örneği.....	47
Şekil 4.4 Veri seti üzerinde görüntü işleme tekniklerinden gürültü ekleme örneği.....	48
Şekil 4.5 Önerilen modelin yapısı.....	50
Şekil 4.6 VGG-19 modelinin eğitim ve doğrulama kaybı grafiği.....	52
Şekil 4.7 VGG-19 modelinin eğitim ve doğrulama başarıları grafiği	52
Şekil 4.8 VGG-19 modelinin karışıklık matrisi	53
Şekil 4.9 InceptionV3 modelinin eğitim ve doğrulama kaybı grafiği.....	54
Şekil 4.10 InceptionV3 modelinin eğitim ve doğrulama başarıları grafiği	55
Şekil 4.11 InceptionV3 modelinin karışıklık matrisi	56
Şekil 4.12 Resnet101 modelinin eğitim ve doğrulama kaybı grafiği.....	57
Şekil 4.13 Resnet101 modelinin eğitim ve doğrulama başarıları grafiği	58
Şekil 4.14 Resnet101 modelinin karışıklık matrisi	59
Şekil 4.15 Önerilen modelin eğitim ve doğrulama kaybı grafiği.....	60
Şekil 4.16 Önerilen modelin eğitim ve doğrulama başarıları grafiği	61
Şekil 4.17 Önerilen modelinin karışıklık matrisi	62

ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 4.1 Orijinal veri seti	43
Çizelge 4.2 Çoğaltılmış veri seti	45
Çizelge 4.3 Karışıklık matrisi parametreleri	49
Çizelge 4.4 Önerilen modelde kullanılan parametreler	50
Çizelge 4.5 VGG-19 modelinin performansı	54
Çizelge 4.6 InceptionV3 modelinin performansı	56
Çizelge 4.7 Resnet101 modelinin performansı	59
Çizelge 4.8 Önerilen modelinin performansı	62
Çizelge 4.9 Önerilen modelin diğer modellerle karşılaştırılması	63



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

W	: Giriş görseli genişliği
H	: Giriş görseli yüksekliği
C	: Giriş görseli kanal sayısı
F	: Filtre boyutları
S	: Adım
K	: Filtre sayısı
n	: Girdi görselinin boyutu
p	: Sıfır doldurma değeri
z	: Sigmoid fonksiyona giriş değeri
x	: Tanh fonksiyona giriş değeri
y	: Gerçek etiket
$\hat{y}_i$	: Modelin tahmin ettiği etiket
c	: Modelin tahmin ettiği toplam sınıf sayısı
a	: Ortalama kare hata örnek sayısı

KISALTMALAR

AA	: Alternatif Akım
AdaDelta	: Uyarlanabilir Delta-Adaptive Delta
AdaGrad	: Uyarlanabilir Gradyan Azalması-Adaptive Gradient Descent
Adam	: Uyarlanabilir Moment Tahmini-Adaptive Moment Estimation
AdaMax	: Maks. Uyarlanabilir Moment Tahmini-Maximum Adaptive Moment Estimation
a-Si	: Amorf silikon

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

BGD	: Toplu Gradyan Azalması-Batch Gradient Descent
ÇÜA	: Çekişmeli Üretici Ağ
DA	: Doğru Akım
DESA	: Derin Evrişimli Sinir Ağları
DVM	: Destek Vektör Makinesi
EL	: Elektrolüminesans
ESA	: Evrişimli Sinir Ağı
FN	: Tahmin Negatif-False Negative
FP	: Tahmin Pozitif-False Positive
FV	: Fotovoltaik
GD	: Gradyan İnişi-Gradient Azalması
İHA	: İnsansız Hava Aracı
MATLAB	: Matrix Laboratory
MGN	: Maksimum Güç Noktası
Mono-Si	: Monokristalin Silikon
Multi-Si	: Çok Kristalli Silikon
MSE	: Ortalama Karesel Hata-Mean Squared Error
RMSProp	: Karekök Ortalama Yayılımı-Root Mean Square Propagation
SGD	: Stokastik Gradyan Azalması-Stochastic Gradient Descent
Si	: Silikon
TN	: Doğru Negatif-True Negative
TP	: Doğru Pozitif-True Positive
VGG	: Görsel Geometri Grubu-Visual Geometry Group
YSA	: Yapay Sinir Ağı

BÖLÜM 1

GİRİŞ

Yenilenemez enerji kaynaklarının tükenmesi ve çevreye verdikleri zarar, başta güneş enerjisi olmak üzere yenilenebilir enerji kaynaklarına olan ilginin artmasına neden olmuştur. Uluslararası Enerji Ajansı (UEA), 2030 ve 2040 yılına kadar dünyanın elektrik üretiminde yenilenebilir enerji oranının sırasıyla %30 ve %50'ye ulaşabileceğini, FV gücünün ise bu payın %10 ve %20'sini oluşturacağını öngörmektedir [1]. FV teknolojisi son yıllarda hızlı bir şekilde büyümüştür. 2008'den 2011'e kadar yalnızca Kanada'da güneş FV elektriği kurulu kapasitesi yıllık yaklaşık %150 artış göstererek 2011'de 495 Megawatt 'a ulaşmıştır [2]. FV sistemler genellikle güneş enerjisi üretimi sağlar. FV sistemlerinin ucuz kurulum maliyetleri, güvenli enerji üretimi, sessiz çalışması ve çevre dostu olması gibi faydaları da dikkat çekmektedir [3,4].

Son yıllarda FV sistemlerine olan ilginin artması FV üreticilerinin sayısında artışa yol açmıştır. Bu nedenle FV güç üreten sistemlerin dayanıklılığının üretici tarafından garanti edilmesi gerekmektedir. Her ne kadar üretici 25 yıl sonra FV sisteminin çıkış gücünün %80'ini Maksimum Güç Noktasında (MGN) garanti etse de FV sisteminin çıkış performansı zamanla kademeli olarak düşmektedir [5]. FV sistemlerdeki verim düşüşü bozulmalara ve çevresel etkenlere bağlıdır. Tozlanma, karlanma, kuş pisliği, gölgelenme, mekaniksel ve fiziksel hasarlar gibi etkenler panellerin performansını ciddi ölçüde olumsuz etkilemektedir ve bu yüzden panel bakımları düzenli olarak yaptırılmalıdır. Panel kusurunu insan gözüyle saptamak hatalara neden olabildiği gibi zaman ve maliyet açısından da kayıplara yol açmaktadır. Bu sorunların giderilebilmesi için günümüzde kullanımı giderek artan derin öğrenme ve görüntü işleme teknolojileri önerilmektedir.

Güneş panelleri üzerindeki kusurları saptama ve sınıflandırma konusunda çalışmalar FV modüllerin verimliliği için büyük önem taşımaktadır. Son yıllarda FV panel arızalarının anomalilerini sınıflandırmak için çeşitli çalışmalar yapılmıştır.

Korkmaz ve Açıkgöz FV paneller üzerindeki anormallikleri tespit edebilmek ve sınıflandırmak için önerdikleri yöntemi transfer öğrenme stratejisine bağlı çok ölçekli bir Evrişimli Sinir Ağı (ESA) olarak tasarlamışlardır. Veri kümesindeki dengesiz sınıf dağılımı sorununu çözmek için veri büyütme ve aşırı örnekleme tekniği kullanarak ağ performansını arttırmışlardır. Çalışmalarında 11 farklı FV panel kusuru (çatlama, sıcak nokta gibi) kullanarak 11 anormali türünü sınıflandırmada %93,51 doğruluk elde etmişlerdir. Elde edilen sonuçların FV panellerdeki kusurları bulmak ve sınıflandırmak için yeterli olduğu gözlenmiştir [6].

Espinosa ve arkadaşları yaptıkları çalışmalarda, FV kusurları tespit etmek için anlamsal bölümlendirme ve görüntüleri sınıflandırmak için ESA' ları kullanan otomatik hata sınıflandırma yöntemi önermektedir. Bu çalışma kusurlu ve kusursuz tanımlanan 2 çıkış sınıfı ve kolayca tespit edilemeyen arıza, çatlak, gölge ve toz yok şeklinde 4 çıkış sınıfı için deneysel sonuçları göstermektedir. Önerilen yöntemle 2 çıkış sınıfı için %75 ve 4 sınıf için %70 doğruluk oranına ulaşılmıştır [7].

Kaycı ve arkadaşları çalışmalarında güneş panellerinden termal kamera yerleştirilmiş dronla elde edilen termal görüntüleri hücre, modül ve panel arızalarının tespitinde kullanmışlardır. Edinilen görüntüler ile modül kusuru, hücre kusuru ve panel kusuru içeren veri seti hazırlanmıştır. Veri seti YOLOv3 derin öğrenme tabanlı Yapay Sinir Ağıyla (YSA) eğitilmiştir. Eğitim sonucunda panel arızaları %95 başarıyla sınıflandırılmıştır. [8].

Pierdicca ve arkadaşları çalışmalarında, FV hücresi bozulmasını tahmin etmek için Derin Evrişimli Sinir Ağları (DESA) kullanmaya yönelik yeni bir yöntem önermişlerdir. Bu araştırmada ilk kez termal kızılötesi sensöre sahip bir drondan alınan bilgiler kullanılmıştır. Bozulma sorununu göstermek ve bu çalışmada önerilen çözümü kapsamlı bir şekilde değerlendirmek için, toplanan FV görüntüler veri kümesi üzerinde deneyler yapılmıştır. Eğitilen ağın başarı oranı %70 olarak bulunmuştur [9].

Li ve arkadaşları tarafından yapılan çalışmada büyük boyutlu FV paneli alanlarının denetimi sırasında panellerin durumunu gözlemleyebilmek için derin öğrenme tabanlı kusur tespiti kullanan bir yöntem oluşturulmuştur. Oluşturulan bu sistemde kullanılan derin öğrenme tekniği ESA tabanlı bir yapıdır. Çalışma sonucunda toz, kapsülleme, delaminasyon, ızgara hattı aşınması, salyangoz izleri ve sararma hataları tespit edilmiş ve ortalama %97,9 doğruluk oranı

elde edilmiştir. Önerilen yöntemin Visual Geometry Group (VGG)-16 ve geleneksel yöntemlerden daha başarılı olduğu gözlenmiştir [10].

Wei ve arkadaşları tarafından güneş panellerinde sıcak nokta ve yansıtıcı bölge arızalarının teşhis edilebilmesi için iki yaklaşım önerilmiştir. Sıcak noktaların algılanması için Hough çizgi dönüşümünü ve Canny operatörünü, reflektör arızalarının tespit edilmesinde ise derin öğrenme yöntemini kullanmışlardır. Çalışma sonucunda geleneksel görüntü işleme ve daha hızlı bölge tabanlı evrişimli sinir ağları başarı oranları sırasıyla %89,96 ve %95,15 olarak elde edilmiştir [11].

Herraiz ve arkadaşları çalışmalarında, güneş panellerindeki kusurları bulmak için insansız hava aracına monte edilen termografik kameradan yararlanan yeni bir teknik önermişlerdir. Yapılan çalışmada sıcak noktaların tespit edilmesinde ve yeniden konumlandırılmasında kullanılabilecek panellerin yerinin tespit edilmesi amacıyla yeni bir yöntem sunulmuştur. İki yeni bölge tabanlı ESA'nın birleştirilmesiyle güçlü bir tespit çerçevesi geliştirmişlerdir. Otomatik veri toplama ve işleme, denetim sırasında kusurların tespit edilmesini sağlamaktadır. Elde edilen sonuçlar, yaklaşımın %91,67 hassasiyetle ve %99,02'den fazla doğrulukla güneş takip cihazlarının ve göreceli sıcak bölgelerinin otomatik lokalizasyonu için uygun olduğunu göstermektedir [12].

Venkatesh ve arkadaşları İnsansız Hava Araçlarından (İHA) elde edilen hava görüntülerinin yardımıyla derin öğrenmeye dayalı FV modüllerdeki arıza tespitini sunmaktadır. Veri setlerini VGG16 ile eğitmişler ve yanık izleri, delaminasyon, renk bozulması, fiziksel hasar, sağlam ve salyangoz izi gibi kusurları sınıflandırmada başarılı olduğu gözlenmiştir. Sonuçlar, modelin tüm FV kusurlarını sınıflandırmada %95,40 gibi yüksek bir sınıflandırma doğruluğuna ulaştığını göstermektedir [13].

Xie ve arkadaşları FV kızılötesi hedef anomali tespit sistemi önermektedir. FV panel kusurlarının İHA tarafından tespitinin doğruluğunu arttırmak için Sobel ve Canny operatörlerini birleştirdiler. Yatay ve dikey özellikleri çıkarmak için Sobel operatörünü, dikey ve yatay kenar özelliklerini hesaplamak ve doldurmak için Canny operatörü kullandılar. Eş zamanlı olarak görüntünün ayırt edici özelliklerini öğrenmek için algoritmaya derin öğrenme uygulanmıştır. Çalışmalar sonucunda model %90,91 oranında sınıflandırma başarısı elde etmiştir [14].

Díaz ve arkadaşları İHA üzerine monte edilmiş termal kamerayla FV'ler için otomatik bir kusur tespit yöntemi önermektedir. Güneş paneli arızalarının tespitinde klasik ve derin öğrenmeye dayalı iki yöntem kullanılmaktadır. Öncelikle, bazı ön işleme teknikleri kullanılarak termal görüntünün düşük kontrastını düzeltilir. Daha sonra, kenar algılama, segmentasyon ve segment sınıflandırması uygulanır. İkinci yöntem, üç farklı ön işleme işlemine tabi tutulmuş görüntülerle eğitilmiş derin öğrenmeye dayanmaktadır. İlk yöntem sonucu %98,3, ikinci yöntem sonucu %98,9 doğruluğa ulaşmıştır [15].

Akram ve arkadaşları izole edilmiş derin öğrenme ve model geliştirme-transfer derin öğrenme teknikleriyle kızılötesi görüntülerdeki FV modül kusurlarının otomatik olarak tespit edilmesi üzerine çalışmışlardır. Veri setleri normal çalışan ve arızalı modüllerin kızılötesi görüntülerini içermektedir. Başlangıçta transfer öğrenimi için FV hücrelerin Elektrolüminesans (EL) görüntülerinden oluşan bir veri kümesi oluşturmuşlar ve ardından kızılötesi görüntülerden oluşan bir veri kümesi kullanmışlardır. Önerilen yaklaşımla ortalama %99,23'lük bir doğruluk elde edilmiştir [16].

Kurukuru ve arkadaşları termografi ve makine öğrenimi tabanlı FV modülü arıza sınıflandırması üzerine çalışmışlardır. Hasar görmüş panellerden alınan çeşitli termal görüntülerin özelliklerini, doku özelliği analizinin değiştirilmiş bir versiyonu kullanılarak incelemişlerdir. Kusur sınıflandırıcısını oluşturulmak için, alınan özellikler bir YSA sınıflandırıcısı kullanılarak eğitilmiştir. Oluşturulan yöntem %93,4 eğitim verimliliği ve %91,7 test verimliliği göstermiştir [17].

Zaki ve arkadaşları derin öğrenme tabanlı FV sistem için hata sınıflandırma çalışması yapmışlardır. Yaptıkları çalışmada öncelikle FV modelin en uygun beş özelliğini çıkarmak için bir algoritma önermişler ve bunun Matrix Laboratory (MATLAB) simülasyon modeline yardımcı olacağını düşünmüşlerdir. İkinci olarak, derin öğrenme kullanılarak FV sistemlerdeki hataların sınıflandırılmasına yönelik yeni bir yaklaşım sağlamışlardır. Bu yöntem, bilgisayardaki performansı ve sınıflandırma doğruluğunu artıran otomatik özellik çıkarma özelliğine sahiptir. Son olarak, kullanılan ESA modelinin teorik ve pratik doğrulaması için çeşitli atmosferik koşullara dayalı olarak normal ve altı arıza örneği seçmişlerdir. Önerilen ESA modeli, eğitim ve test süreçlerinde simülasyon testlerinde sırasıyla %98,3 ve %98,9, deneysel testlerde ise %96,76 ve %97,41 civarında ortalama sınıflandırma doğruluğu elde etmiştir [18].

Deutsch ve arkadaşları EL görüntülerinde arızalı FV modül hücrelerinin otomatik sınıflandırılması adlı çalışmalarında FV hücrelerdeki sorunları tespit edebilmek adına 2 farklı yaklaşım ortaya sunmuşlardır. Yaklaşımlar donanım gereksinimleri nedeniyle farklılık göstermektedir. Donanım açısından verimli olan Destek Vektör Makinesinde (DVM) sınıflandırılmaya dayanmaktadır. Daha fazla donanım isteyen yöntem ise ESA'yı kullanmaktır. Her iki yaklaşımda 1968 farklı hücre üzerinde eğitilmiştir. ESA başarı oranı %88,42 ve DVM başarı oranı %82,44'tür [19].

Tang ve arkadaşları EL görüntüleri kullanılarak FV modülün derin öğrenme tabanlı otomatik kusur tespiti isimli çalışmalarında 2 farklı adımla EL görüntülerini derin öğrenmeye dayalı kusur tespitini sunmuşlardır. Birinci adım kısıtlı sayıdaki EL görüntüyü yüksek kalitede arttırmak, ikinci adım elde edilen görüntüler ile otomatik sınıflandırma yapan bir model ortaya koymaktır. EL görüntü oluşturma yöntemi, Çekişmeli Üretici Ağ (ÇÜA) özelliklerini geleneksel görüntü işleme teknolojileriyle birleştirmektedir. EL görüntülerinden derin özelliği çıkarmak için ESA kullanılmaktadır. Önerilen model diğer çözümlerle karşılaştırıldığında, FV modülü denetiminin doğruluğunu ve verimliliğini önemli ölçüde artırabilir. Önerilen model %83'lük başarı oranına sahiptir [20].

Güneş panellerindeki hasarların tespiti için son dönemde birçok çalışma yapılmıştır, ancak yapılan çalışmalardaki yaklaşımların hiçbiri yüksek doğrulukta çok sınıflı hasarları kısa bir sürede sınıflandıramamaktadır. Güneş panelleri üzerindeki hasarların erken tespiti ve müdahale edilmesi veriminin artması için çok önemlidir.

Bu tez çalışması ile güneş panelleri üzerindeki hasarların hızlı ve otomatik bir şekilde tespit edilebilmesi amacıyla görüntü işleme ve derin öğrenme tabanlı arıza tespit yöntemi önerilmiştir. Önerilen işlem 2 aşamadan oluşmaktadır. Bu aşamalar ön işlem ve ESA tabanlı oluşturulan derin öğrenme mimarisiyle sınıflandırmasıdır.

Bu tez kapsamında farklı iklim şartlarında çekilmiş görüntüler, modelin daha iyi performans vermesi ve veri setinin yetersiz olması nedeniyle veri artırma teknikleri ile (simetrisini alma, görüntüyü belirli açılarla döndürme, gürültü ekleme) artırılmıştır. Sınıflandırma aşamasının temel hedefinde ise artırılmış olan veri setinin ESA tabanlı oluşturulan derin öğrenme mimarisiyle modelin yüksek doğrulukta 7 sınıflı eğitebilmesidir. Ayrıca önerilen model daha


BÖLÜM 2

GÜNEŞ ENERJİSİ VE GÜNEŞ PANELLERİ

Bu bölüm güneş enerjisinin önemi, güneş panellerinin önemi, yapısı, çalışma mantığı, türleri, avantaj ve dezavantajları ve güneş panellerinde oluşabilecek hasarları içermektedir.

2.1 GÜNEŞ ENERJİSİ

Küresel sorunlara çözüm olabilecek en önemli yenilenebilir enerji kaynaklarından biri güneş enerjisidir. Güneş enerjisi temiz ve çevreci bir enerji kaynağı olduğundan dolayı fosil enerji kaynaklarına göre daha çok avantajlıdır [21]. Güneşten bir dakika içerisinde dünyaya ulaşan enerji, bir yıl içerisinde tüketilen enerjiye eşittir [22]. Dört önemli alanda (elektrik üretimi, sıcak su üretimi, kırsal enerji tedariki ve araç yakıtı) yenilenebilir kaynaklar geleneksel yakıtların yerini alabilir [23]. Termal toplayıcılar ve FV hücreler, güneş enerjisinin doğrudan ısı ve elektriğe dönüştürülmesine olanak tanır [24]. Şekil 2.1’ de yakın geçmişte ve gelecekte güneş enerjisi kullanımının evrimi görülmektedir




Şekil 2.1 Yakın geçmişte ve gelecekte güneş enerjisi kullanımının evrimi [25]

2.2 GÜNEŞ PANELLERİ

Güneş panelleri güneş enerjisini elektrik enerjisine çeviren sistemlerdir. Hücreler, genellikle FV paneller olarak bilinen güneş panellerini oluşturur. Yaygın olarak güneş pili olarak adlandırılan FV hücre, yarı iletken diyota benzer şekilde çalışarak güneş ışığını elektrik enerjisine dönüştürür.

FV panellerin çıkışı Doğru Akım (DA) olarak kabul edilir. DA ile çalışan yüklerin doğrudan beslenmesi mümkündür. Gün boyunca güneş radyasyonunun yoğunluğu periyodik olarak değişir. Mevsimsel durumlarda da oldukça etkilidir. Bu nedenle üretilen güç miktarı yeterli olamayabilir veya gereğinden fazla olabilir. Piller ekstra elektrik enerjisini depolamak için kullanılabilir. Güneş panellerinin ürettiği elektrik enerjisi miktarı gerekenden az ise akülerdeki enerji boşluğu doldurmak için kullanılır. Alternatif Akım (AA) tarafından desteklenen bir yük beslendiğinde DA' yı AA'ya dönüştürmek için bir invertör kullanılır [26]. Şekil 2.2'de FV sistemin çalışma yapısı görülmektedir.



Şekil 2.2 FV sistemin çalışma yapısı

2.3 GÜNEŞ PANELİ SİSTEMİ ELEMANLARI

Güneş paneli sistemleri; güneş panelleri, dönüştürücü, solar şarj kontrol cihazı ve aküden oluşur.

2.3.1 Güneş Panelleri

Bunlar bir FV sisteminin en tanınabilir bileşenleridir. Güneş panelleri, güneş ışığını yakalayan ve onu FV etki yoluyla DA'a dönüştüren birçok güneş hücresinden oluşur.

2.3.2 Dönüştürücü

Çoğu evde ve işyerinde kullanılan AA gücünün, bir invertör kullanılarak güneş panellerinin ürettiği DA elektriğinden dönüştürülmesi gerekir. Bu dönüşüm invertörler aracılığıyla yapılır.

2.3.3 Solar Şarj Kontrol Cihazı

Güneş enerjisi şarj kontrolörü, bulutlu günlerde veya gece kullanım için ekstra enerji depolamak üzere şebekeden bağımsız FV sistemlerde akülerin şarj edilmesini ve boşaltılmasını kontrol eder.

2.3.4 Akü

Şebekeden bağımsız veya hibrit FV sistemlerde, güneşli günlerde üretilen ekstra enerjiyi daha sonra kullanmak üzere depolamak için akü kullanılır. Güneşin olmadığı durumlarda bu elektrik sağlar.

2.4 FV HÜCRELERİN YAPISI VE ÇALIŞMA PRENSİBİ

Genellikle güneş pilleri olarak bilinen FV hücreler, güneş panellerinin ve güneş ışığını enerjiye dönüştüren cihazların temel yapı taşlarıdır.

2.4.1 FV Hücrelerin Yapısı

Yarı İletken Malzemeler: FV hücreler yarı iletken malzemeden yapılır. Silikon, FV hücreler için en sık kullanılan malzemedir ve farklı türlerde olabilir:


-n-tipi Silikon: Bu tip silikonda fazla miktarda serbest elektron bulunur.

-p tipi Silikon: Bu tip silikonda "delikler" veya elektronların eksik olduğu yerler bulunur.

p-n Bağlantısı: p-n bağlantısı bir FV hücrenin kalbidir. n-tipi ve p-tipi silikon alanların birleşimidir. Hücrenin aktivitesi için gereklidir ve dahili elektrik alanının oluşumunda önemli bir rol oynar.

Metal Kontaklar: Hücrenin ön ve arka yüzeylerine ince metal kontaklar yerleştirilmiştir. Bu bağlantılar, foton Emilimi sayesinde üretilen elektronların toplanmasına ve elektron akışı için harici bir elektrik devresinin oluşmasına yardımcı olur.


Yansıtıcı Olmayan Kaplama: Güneş ışığının yansımalarını azaltmak ve ışık Emilimini artırmak için hücrenin ön yüzeyine sıklıkla ince bir yansıma önleyici kaplama eklenir. Şekil 2.3'te FV sistemin yapısı görülmektedir.



Şekil 2.3 FV hücrenin basit yapısı [27]

2.4.2 FV Hücrelerin Çalışma Prensibi

Güneş ışığından gelen fotonlar bir FV hücrenin yüzeyine ulaştığında, bunların bir kısmı yarı iletken malzeme tarafından emilir. Her foton, kendi dalga boyuna bağlı enerjiyi içerir. Emilen fotonlardan gelen enerji, yarı iletken malzemedeki elektronları uyararak onların normal atomik konumlarından kaçmalarını sağlar. Bu, bir elektronun enerji kazandığı ve geride pozitif yüklü bir delik bırakıldığı elektron-delik çiftleri üretir. Hücre içinde p-n bağlantısının bir sonucu olarak bir iç elektrik alanı oluşur. Bu elektrik alanı elektronları ve delikleri ayırır. Elektronlar n-tipi alana, delikler ise p-tipi bölgeye çekilir. Yük ayrımının bir sonucu olarak hücre boyunca bir voltaj farkı (elektrik potansiyeli) yaratılır. Hücreye metal kontaklar aracılığıyla harici bir elektrik devresi bağlandığında, elektronlar devre boyunca n-tipi taraftan p-tipi tarafa doğru akmaya itilir ve bu da bir elektrik akımının oluşmasına neden olur. Elektrikli ekipmanlara güç sağlamak, pilleri şarj etmek ve invertörler aracılığıyla elektrik şebekesine besleme dahil olmak üzere çeşitli amaçlarla kullanılabilir. Hücreye ne kadar çok güneş ışığı çarparsa, o kadar çok elektron deliği çifti oluşur ve bu da güç çıkışının artmasına neden olur. Şekil 2.4'te FV hücrelerin çalışma prensibi görülmektedir.



Şekil 2.4 FV hücrelerin çalışma prensibi [28]

2.5 FV HÜCRE, MODÜL VE DİZİ

FV sistemlerde 3 çeşit hücre tipi vardır. Bunlar FV hücre, FV modül ve FV dizi 'dir.

2.5.1 FV Hücre


FV hücreler güneş ışığını elektriğe dönüştürmekten sorumlu temel bileşenlerdir. Her modül içerisinde seri olarak bağlanarak toplu olarak güç üretmelerine olanak tanırırlar. Her pil normalde 0,5-0,6 volt üretir.

2.5.2 FV Modül

Gerilimi ve akım üretimini artırmak için birden fazla güneş pili seri ve bazen de paralel olarak bağlanır. Çatılara yerleştirilen veya güneş panellerine entegre edilen en tipik bileşenler modüllerdir.

2.5.3 FV Dizi

FV modüllerin birleştirilmesiyle bir dizi oluşturulur. Diziler gerekli sistem voltajı ve akım seviyelerine ulaşacak şekilde tasarlanabilir. Binaların üzerine kurulurlar ve alan için en fazla güneş ışığını toplayacak şekilde açılırlar. Şekil 2.5' te sırasıyla FV Hücre, Modül ve Dizi görülmektedir.



Şekil 2.5 FV Hücre, Modül ve Dizi [29]


2.6 GÜNEŞ PANELİ TÜRLERİ

FV hücrenin birincil rolü, güneş enerjisini saf ışık biçiminde kabul etmek ve onu, FV etki olarak bilinen bir dönüşüm süreci yoluyla elektriğe dönüştürmektir [30].

FV hücrelerinin üretiminde çeşitli teknolojiler kullanılmıştır. Bu hücrelerin yapısal bileşeninde, poli ve monokristalin silikon teknolojileri gibi, fotoelektrik dönüşüm verimleri değişen çeşitli malzemeler kullanılmaktadır.

2.6.1 Kristal Silikon Güneş Panelleri

Onlarca yıldır silikonun (Si) kristal düzenlemeleri onu kullanımda olan birincil yarı iletken malzeme haline getirmiştir. Güneş pili üretiminin geçmişi, diğer seçeneklerle karşılaştırıldığında üstün verimliliği, güvenilirliği ve kullanılabilirliği nedeniyle Si'ye güçlü bir bağımlılık göstermektedir. Güneş pillerinin üretiminde kristalin Si, çok kristalli Si (Multi-Si) veya monokristalin Si (Mono-Si) olarak bilinir [31]. Multi-Si ayrıca çok kristalli Si (Poli-Si) veya yarı kristalli Si olarak da sınıflandırılır; bunların her ikisi de küçük ve çok sayıda kristalit içerir. Bu çeşitlilik, güneş pili yapısında belirgin bir tanecik oluşmasına neden olur. Mono-Si ise tane sınırları olmayan sürekli bir kristaldır [31]. Sonuç olarak Mono-Si veya tek kristalli Si'nin, Multi-Si veya Poli-Si'den daha verimli olduğu düşünülmektedir. Şekil 2.6' da Monokristal ve Polikristal güneş paneli görülmektedir.



Şekil 2.6 Monokristal ve Polikristal Güneş paneli [32]

2.6.2 İnce Film Teknolojileri

İnce film teknolojileri, enerji (özellikle güneş enerjisi) alanında spesifik imalat, iletkenlik, verimli enerji dönüşümü ve muhafazası, foto iletkenlik özellikleri ve güneş kontrol özellikleri ile istenilen ve başarılı modelleri sunmaktadır [33].

Amorf Si (a-Si), en köklü ince film güneş paneli teknolojisidir. Güneş panelleri genellikle ön ve arka şeffaf iletken oksitlerden oluşan ince film katmanlarına sahip bir cam alt tabakadan, p-i-n konfigürasyonunda katkılı ve katkısız a-Si'den oluşan bir FV katmandan ve bir arka metal kontakten oluşur [34].

İnce film güneş panelleri, mevcut kristal panellere göre çok daha az Si kullanmaları ve çok sayıda üretilip seri olarak bağlanabilmeleri sayesinde az maliyetli ve yaygın kullanıma sahiptir. Devasa panellerin belirli boyut ve şekillerde işlenmesi ve işlemiden sonra hatasız bir şekilde birleştirilmesi durumunda, ticari ürünler olarak daha fazla fayda ve kullanılabilirlik elde edilebilecektir. Bu durum, mekanik ve elektriksel bütünlüğü korurken güneş panellerinin verimli bir şekilde çalışmasını sağlayacaktır. İnce film güneş panellerindeki cam, Si ve seramik katmanlarının kırılğan doğasından dolayı, geleneksel işleme süreçlerini kullanarak hem kalite hem de üretkenlik açısından zorlu gereksinimleri karşılamak son derece zahmetlidir [34]. Şekil 2.7'de ince film güneş paneli görülmektedir.



Şekil 2.7 İnce film güneş paneli [35]

2.7 GÜNEŞ PANELLERİNİN AVANTAJLARI VE DEZAVANTAJLARI

Yaygın olarak FV paneller olarak bilinen güneş panellerinin çeşitli avantajları ve dezavantajları vardır. Güneş panellerinin kullanıcının enerji taleplerine ve koşullarına uygun olup olmadığı belirlenirken bu unsurlar incelenmelidir.

2.7.1 Güneş Panellerinin Avantajları

1. Yenilenebilir ve Sürdürülebilir: Güneş enerjisi yenilenebilir bir kaynaktır, yani güneş parladığı sürece neredeyse sınırsızdır. Güneş, fosil yakıtlara olan bağımlılığımızı en aza indirmeye yardımcı olabilecek yenilenebilir bir enerji kaynağıdır.
2. Temiz ve Çevre Dostu: Güneş panelleri sera gazı veya hava kirliliği yaratmadan enerji üretir. Bu, karbon ayak izinizi azaltır ve daha temiz bir çevreye katkıda bulunur, bu da iklim değişikliğiyle mücadelede yardımcı olur.
3. Elektrik Faturası Tasarrufu: Güneş panelleri güneş ışığından elektrik üretir ve bu elektrik, evlere veya şirketlere güç sağlamak için kullanılabilir. Tüketici kendi elektriğini üreterek uzun vadede tasarruf sağlayabilir.
4. Parasal Teşvikler: Birçok ülke ve belediye hükümeti, güneş panellerinin kurulumunu teşvik etmek için vergi kredileri, indirimler ve tarife garantileri gibi mali teşvikler sağlamaktadır. Bu sübvansiyonlar bir güneş enerjisi sisteminin başlangıç maliyetini büyük ölçüde azaltabilir.
5. Enerji Bağımsızlığı: Güneş panelleri bir miktar enerji bağımsızlığı sağlar. Tüketici kendi elektriğini üretirse, kamu hizmeti sağlayıcılarına daha az bağımlı olur ve enerji fiyatlarındaki dalgalanmalara daha az maruz kalır.
6. Düşük İşletme Giderleri: Güneş panelleri düşük işletme ve bakım giderleri sunar. Rutin temizlik ve muayene gerektirirler ancak yakıt giderleri yoktur.

7. Uzun Ömür: Güneş panelleri genellikle 25 yıl veya daha fazla garantiye sahiptir ve oldukça uzun bir ömre sahiptir. İlk harcamadan sonra onlarca yıl boyunca enerji üretebilirler.
8. Şebekenin Kararlılığı: Dağıtılmış güneş enerjisi üretimi, talebin en yüksek olduğu dönemlerde basıncı düşürerek ve kesintiler sırasında yedek güç sağlayarak şebeke stabilitesini artırabilir.

2.7.2 Güneş Panellerinin Dezavantajları

1. Yüksek Başlangıç Maliyeti: Güneş panellerini edinmenin ve kurmanın ilk maliyeti yüksek olabilir. Devlet sübvansiyonları bu giderlerin bir kısmının karşılanmasına yardımcı olsa da başlangıçtaki harcamalar bazı hane halkı veya şirketler için hâlâ engel teşkil edebilmektedir.
2. Düzensiz Enerji Kaynağı: Güneş panelleri yalnızca güneş parladığında güç üretir. Bulutlu günlerde veya geceleri enerji üretimi büyük ölçüde azalabilir. Bu tutarsızlık, daha fazla enerji depolama seçeneğini veya şebekeye güvenmeyi gerektirmektedir.
3. Yer Gereksinimleri: Özellikle çok fazla güç üretmek isteniyorsa, güneş panellerinin kurulumu çok fazla alan gerektirir. Çatı üstü kurulumlar mevcut çatı alanıyla sınırlı olabilir.
4. Estetik Kaygılar: Bazı kişiler, özellikle çatıya yerleştirildiklerinde güneş panellerini çekici bulmamaktadır. Bu, bazı durumlarda emlak fiyatlarını etkileyebilecek subjektif bir sorundur.
5. Hava Durumuna Bağlılık: Yoğun kar yağışı, dolu veya yüksek sıcaklık gibi hava koşullarının tümü güneş panellerinin etkinliğini etkileyebilir. Her ne kadar çeşitli hava koşullarında hayatta kalabilecek şekilde inşa edilmiş olsalar da şiddetli olaylar zarara neden olabilir.

6. Enerji Depolama Maliyetleri: Güneş enerjisinin kesintili doğasını çözmek için aküler gibi enerji depolama teknolojilerine yatırım yapılması gerekebilir. Bunlar bir güneş enerjisi sisteminin genel maliyetini artırabilir.
7. Coğrafi Sınırlamalar: Güneş enerjisi üretimi, bol güneş ışığı alan bölgelerde en verimlidir. Sık bulutlu veya yetersiz güneş ışığı olan yerlerde enerji verimi daha düşük olabilir, bu da güneş enerjisi sistemlerinin finansal fizibilitesini azaltabilir.
8. Üretimin Çevresel Etkisi: Güneş panelleri çeşitli malzemeler ve enerji yoğun üretim teknikleri kullanılarak yapılır. Çevresel etkisi fosil yakıtlara göre daha küçük olsa da tamamen sıfır değildir.

2.8 GÜNEŞ PANELİ SİSTEMLERİNDE OLABİLECEK KUSURLAR

2.8.1 Gölgeleme

Bir FV paneli seri olarak bağlanan FV hücrelerinden oluşur. FV paneli seri bağlı hücrelerin sayısına eşit bir çıkış voltajı üretir. Yeterli bir akım mevcut olduğunda ancak daha yüksek bir voltaj seviyesi istendiğinde, FV panellerin seri bağlanmasıyla çıkış voltajı artırılır. Seri bağlı FV paneller her zaman eşit miktarda güneş ışınımı almayabilir. Bulut, bina, direk, baca, ağaç vb. çeşitli nedenlerden dolayı FV panelinin/hücrelerinin bir kısmı gölgeleme olabilir. Buna kısmi gölgeleme denir [36]. Şekil 2.8’de gölgeleme güneş paneli görülmektedir.



Şekil 2.8 Gölgeleme güneş paneli [37]

2.8.2 Kuş Pisliği

Kuş pisliklerinin güneş panellerinizin verimliliği üzerinde önemli bir etkisi olabilir. Dışkılardaki ürik asit, güneş panellerindeki FV modüller için özellikle tehlikeli olabilir. Bu, güneş pillerinin enerjiyi üretmek yerine emdiği sıcak noktalar gibi sorunlara yol açabilir. Diğer bir sorun ise temizlikten sonra bile devam edebilecek damlamanın ana hatları olan aşındırmadır. Kalıcı hasarı önlemek için kuş pisliklerinin kısa sürede temizlenmesi gerekir, ancak düzenli temizlik pahalı olabilir. Şekil 2.9’ da kuş pisliği olan güneş paneli görülmektedir.



Şekil 2.9 Kuş pisliği olan güneş paneli [37]

2.8.3 Tozlanma

Toz birikmesi nedeniyle FV sistem performansının bozulması sorunu ciddi bir sorun haline geldi. FV hücreler üzerinde toz birikmesi, kaplama camı üzerinde zararlı bir etkiye sahiptir ve spektral geçirgenliği ve FV güç üretim verimliliğini azaltır [38]. Uzun süreli toz birikmesi, panel katmanını bozarak daha düşük çıktıya ve daha kısa bir kullanım ömrüne yol açar [39]. Şekil 2.10’ da tozlanmış güneş paneli görülmektedir.



Şekil 2.10 Tozlanmış güneş paneli [37]

2.8.4 Elektriksel Hasar


Güneş panellerindeki elektrik hasarının, performansı ve ömrü üzerinde çeşitli zararlı etkileri olabilir. Yıldırım çarpmaları, güneş paneli sistemindeki elektrik arızaları veya hatalı kurulum, elektriksel zarara neden olabilir. Şekil 2.11’ de elektriksel hasarlı güneş paneli görülmektedir.



Şekil 2.11 Elektriksel hasarlı güneş paneli [37]

2.8.5 Fiziksel Hasar

Güneş panellerindeki fiziksel hasar, performansları ve dayanıklılıkları üzerinde olumsuz bir etkiye sahip olabilir. Güneş panelleri çeşitli çevresel koşullara ve olası risklere maruz kalır ve çeşitli şekillerde fiziksel hasar (cam kırılması, mikro çatlak vb.) meydana gelebilir. Şekil 2.12 de fiziksel hasarlı güneş paneli görülmektedir.



Şekil 2.12 Fiziksel hasarlı güneş paneli [37]

2.8.6 Karlanma

Hafif bir kar tabakasının güneş panelleri üzerindeki etkisi minimum düzeydedir, çünkü rüzgâr onu kolayca uçurur. Işık, yetersiz bir kaplama yoluyla iletilebilir, panele ulaşabilir ve güç üretebilir. Yoğun kar yağdığında FV paneller elektrik üretmez. Karın ağırlığının FV sisteminin destek yapısı üzerinde baskı oluşturması nedeniyle yoğun kar yağışı sorun yaratabilir. Kar kaymaya başladığında panel kısmen açığa çıksa bile elektrik üretimi devam edebilir. Şekil 2.13'te karla kaplanmış güneş paneli görülmektedir.



Şekil 2.13 Karla kaplanmış güneş paneli [37]

BÖLÜM 3

DERİN ÖĞRENME TABANLI GÜNEŞ PANELİ KUSURLARI SINIFLANDIRMASI

Tezin bu aşamasında hasarlı güneş panellerinin sınıflandırılması için kullanılan derin öğrenme yöntemi ve temelleri açıklanacaktır. Hasarlı güneş panellerinin sınıflandırılması için önerilen model, esas olarak güneş paneli görüntülerinin ön işleme tabi tutulması, önerilen ESA algoritmasının eğitilmesi ve ortaya çıkan modelin test için belirlenen güneş paneli veri seti üzerinde test edilmesi süreçlerinden oluşur. Önerilen modelin ön işleme adımında güneş paneli görsellerini ölçeklendirme, gürültü ekleme, simetriğini alma ve belirli açılarla döndürme tekniklerinden yararlanılarak veri artırma teknikleri kullanılmıştır. Ön işlem kısmı tamamlandıktan sonra önerilen ESA modeli ile eğitim gerçekleştirilmiştir. Eğitim aşamasında veri seti %80 eğitim, %10 doğrulama ve %10 test için kullanılmıştır. Veri seti işlem yükünü azaltmak ve performansı arttırmak adına 32'li kümeler halinde eğitilmiştir. Eğitim ve test aşamalarından sonra çizdirilen doğrulama ve hata grafikleri, karışıklık matrisi ile modelin performansı gözlenmiştir. Veri seti önceden eğitilmiş modellerde eğitilerek karşılaştırmalar yapılmıştır.


3.1 DERİN ÖĞRENME

Modern toplum, web aramaları, sosyal ağlarda içerik filtreleme ve e-ticaret platformlarındaki öneriler dahil olmak üzere çeşitli alanlarda kullanılan makine öğrenimi teknolojilerinden büyük ölçüde faydalananıyır. Makine öğrenimi sistemleri, görüntülerde nesne tanımlama, konuşmanın metne dönüştürülmesi, haber ve gönderilerin kullanıcı ilgi alanlarıyla eşleştirilmesi ve ilgili arama sonuçlarının sağlanması gibi görevlerde çok önemli bir rol oynamaktadır. Belirli bir yöntem sınıfı olan derin öğrenme teknikleri, bu uygulamalarda giderek daha yaygın hale gelmektedir [40].

Derin öğrenme, makine öğreniminin bir alt dalıdır ve 3 veya daha fazla katmanlı sinir ağlarını içerir. Bu ağlar insan beynindeki sinirlere benzer ve onları taklit eder. Tek katmanlı kabaca tah-

min yapabilse de optimizasyon ve doğruluğu arttırabilmek için gizli katmanlar dahil edilmelidir. Derin öğrenme veri biliminin önemli bir elemanıdır. Veri bilimciler büyük miktarda veriyi toplamak, analiz etmek ve yorumlamakla ilgilenirler. Derin öğrenme bu işlemi hızlı ve kolay hale getirir. Ses tanıma, görsel nesne tanımlama, nesne algılama ve daha pek çok alanda bu teknik sayesinde son teknoloji önemli ölçüde geliştirilmiştir [40].


Derin öğrenmenin temeli yapay sinir katmanlarından oluşan bir ağıdır. Çoklu nöron bağlantıları birleşerek katmanları oluşturur. Derin sinir ağları, katmanların üst üste istiflenmesiyle oluşturulan YSA'nın diğer adıdır. Burada oluşan ağın derinliği katman sayısının az veya çok olmasıyla belirtilir. Katman sayısı arttıkça ağ yapısı derinleşmektedir. Benzer şekilde katman sayısının azalması, ağ yapısının ya derin olmadığını ya da derinleştiğini gösterir. Şekil 3.1' de basit yapılı bir YSA modeli görülmektedir.



Şekil 3.1 YSA modeli

3.2 EVRİŞİMLİ SİNİR AĞLARI

ESA, en sık kullanılan derin sinir ağıları arasındadır. Evrişim terimin ortaya çıkmasına neden olan matrisler arasındaki matematiksel doğrusal bir eylemdir. ESA'lar evrişim katmanı, lineer olmayan katman, havuzlama katmanı ve tamamen bağlantılı katmanlardan oluşur. Havuzlama ve doğrusal olmayan katmanlarda parametreler yoktur, ancak evrişimli ve tamamen bağlantılı katmanlarda parametreler vardır [41]. Şekil 3.2' de bu tez çalışmasındaki probleme yönelik bir ESA modeli örneği görülmektedir.



Şekil 3.2 ESA bileşenleri

ESA'ların en faydalı yönü YSA'daki parametre sayısının azaltılmasıdır. ESA'ların kullanımı YSA'lar ile çözümü mümkün olmayan problemleri çözebilmeleri nedeniyle artmıştır. ESA'lar da problemlerle ilgili en önemli varsayım, mekânsal bağımlılığın olmamasıdır. Örneğin mimikleri sınıflandıran bir modelde insan yüzünün görseldeki konumunun önemli olmaksızın modelin yüzü tanımlayabilmesidir [41]. ESA'ları oluşturmak için birden fazla eğitilebilir bölüm ardışık olarak sıralanır. Giriş verileri ESA tarafından alındıktan sonra eğitim prosedürü katman katman süreçler kullanılarak gerçekleştirilir. Final çıktısı, doğru sonuçla karşılaştırma için sağlanır. Final çıktısıyla beklenen sonuç arasındaki tutarsızlık, bu tutara eşit bir hataya neden olur. Bu hatayı tüm ağırlıklara yaymak için geri yayılım mekanizması kullanılır. Ağırlıklar her yinelemeden sonra güncellenir, bu da yanlışlığı azaltır. Görüntü, müzik veya video gibi herhangi bir sinyal, ESA giriş verileri olarak kullanılabilir. Özellikle görsel sınıflandırma üzerine yoğunlaşan ESA'lar, son yıllarda çeşitli alanlarda yaygın olarak kullanılmaya başlandı [41].

3.2.1. ESA'yı Oluşturan Katmanlar


ESA mimarisi; giriş katmanı, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, tam bağlantılı katmanı, seyreltme katmanı ve sınıflandırma katmanından oluşmaktadır. Bu katmanların sayısı farklı ESA modellerini oluşturur.

3.2.1.1 Giriş Katmanı

Bu katman, adından da anlaşılacağı gibi ESA'nın en üst katmanıdır. Bu katmanda ağa ham veriler sağlanır. Giriş görselinin büyük boyutu, her görüntü için daha uzun eğitim ve test oturumlarının yanı sıra daha yüksek bellek ihtiyacına da yol açabilir. Ayrıca ağ performansını da artırabilir. Küçük bir giriş görseli boyutu seçilerek daha hızlı ve daha az hafıza kullanımıyla eğitim yapılabilir. Ağın performansı ortalamanın altında olabilir ve sonuç olarak derinliği azalacaktır. Görüntü analizinde ağ derinliği, donanım hesaplama maliyeti ve ağ başarısı için doğru giriş görsel boyutunun kullanılması gerekir.


3.2.1.2 Konvolüsyon Katmanı (Evrişim Katmanı)

Evrişim katmanı ESA'ların temel yapı taşıdır [42]. Bu katman dönüşüm katmanı olarak da bilinir bu dönüşüm filtrenin bütün görüntü üzerinde dolaştırılmasıdır [43]. Filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilir. Filtreler, önceki katmandaki görüntüler üzerinde evrişim işlemini kullanarak çıktı verilerini üretir. Bu işlem sonucu Özellik Haritası oluşur. Şekil 3.3'te konvolüsyon işlemleri sonucu oluşturulan özellik haritası örneği gösterilmiştir.



Şekil 3.3 Özellik haritası

Giriş görüntüsündeki veya özellik haritasındaki belirli özellikleri temsil eden evrişimli bir katman, ESA'larda bir özellik haritası üretir. Giriş görüntüsü, bir ESA'nın ileri geçişi sırasında çeşitli özellik haritaları oluşturmak için bir veya daha fazla filtreyle evrilir. Her özellik haritası, belirli bir filtrenin giriş resmine nasıl tepki verdiğini ve bu filtreyle nasıl ilişkilendirildiğini gösterir. Özellik haritasındaki her ögenin değeri, ilgili özelliğin giriş görüntüsünde mevcut olma derecesini belirtir ve özellik haritasındaki her öge, ağdaki belirli bir nöronun aktivasyonunu yansıtır. Örneğin, bir ESA'nın ilk katmanlarındaki özellik haritaları kenarlar, çizgiler ve köşeler gibi düşük seviyeli özellikleri temsil edebilir. Ağın derinliklerine doğru ilerledikçe, formlar, dokular ve hatta nesnelerin tamamı gibi daha karmaşık özellikler, özellik haritaları ile temsil edilebilir. Ağ tasarım süreci sırasında, evrişimli bir katmandaki özellik eşlemelerinin sayısı ayarlanabilir. Ağ, daha fazla özellik haritası kullanarak daha karmaşık ve soyut özellikleri öğrenebilir, ancak bunu yapmak daha yüksek hesaplama maliyetine neden olur ve ağ çok büyükse aşırı uyumla sonuçlanabilir.



Şekil 3.4 Konvolüsyon işlemi uygulanma örneği

Şekil 3.4'te 5x5 bir görsele 3x3 bir filtre uygulanarak 3x3 lük bir özellik haritası oluşturulmuştur. İşlemler filtre görselin bütün pikselleri üzerinde dolaşacak şekilde adım adım devam eder ve sonuç olarak 3x3 lük bir özellik haritası elde edilir.

Giriş verilerindeki çeşitli modelleri veya özellikleri vurgulayarak, çeşitli filtreler bir ESA'da çeşitli özellik haritaları üretebilir. Filtre, giriş verilerini tarayan ve filtredeki değerler ile giriş verilerindeki karşılık gelen değerler arasındaki nokta çarpımı hesaplayan küçük bir pencere olarak düşünülebilir. Çeşitli değerlere sahip birkaç filtre uygulanarak giriş verisinden farklı özellikler elde edilebilir.

Giriş verileri üzerinde çeşitli filtreler kullanılarak çeşitli özellikler çıkarılabilir. Giriş verilerinin birçok yönünü yakalayan son bir özellik haritası, her filtrenin ürettiği farklı özellik haritalarının birleştirilmesiyle yapılabilir.

Giriş veya özellik haritasının boyutu, filtrenin boyutu ve evrişim işleminin adımı, ESA'lardaki çıkış özellik haritasının boyutunu etkileyen değişkenlerden yalnızca birkaçıdır.

Giriş boyutları $W \times H \times C$ (W = genişlik, H = yükseklik, C = kanal sayısı) ve filtre olarak $F \times F \times C$ kullanılırsa (F = filtre boyutları) ve S adım olarak düşünülürse çıktı özelliği haritası şu boyutlara sahip olacaktır:

$$[(W - F)/(S + 1) \times (H - F)/(S + 1)] \times K \quad (3.1)$$

Burada K kullanılacak filtre sayısını belirtir.

Örneğin $256 \times 256 \times 3$ bir görsele $5 \times 5 \times 3$ filtre adım adım uygulandığında çıktı özellik haritasının boyutu $252 \times 252 \times K$ olacaktır. 2 filtre uygulandığında çıktı özellik haritasının boyutları $252 \times 252 \times 2$ olacaktır.

Çıktılarının optimizasyonu sayesinde evrişimli katmanlar, modelin karmaşıklığını da önemli ölçüde azaltabilir. Bunları optimize etmek için derinlik, adım ve sıfır dolgu ayarından oluşan üç hiper parametre kullanılır.

Girişin aynı alanına göre her katmandaki nöronların sayısı ayarlanarak, evrişimli katmanlar tarafından üretilen çıkış hacminin derinliği manuel olarak ayarlanabilir. Bu, gizli katmandaki her nöronun, gizli katman ortaya çıkmadan önce diğer nöronlara doğrudan bağlandığı diğer YSA türlerinde de açıkça görülmektedir. Bu hiper parametrenin düşürülmesi ağı genel nöron sayısını önemli ölçüde azaltabilirken, aynı zamanda modelin örüntü tanıma kapasitesini de önemli ölçüde azaltabilir [44].

Girişin sınırlarını doldurmanın basit bir işlemi olan sıfır doldurma, çıkış hacimlerinin boyutluluğu üzerinde daha fazla kontrol sağlamanın etkili bir yoludur. Bu teknik kullanılarak evrişimin uzaysal boyutu değiştirilebilir.

Sıfır doldurma işlemi 0 kullanılarak yapılır. 0 sayısı kullanılarak piksel ekleme işlemi yapıldığında görüntünün orijinali korunmuş olur. Yani girdi ile çıktı boyutu aynı olur. Sıfır doldurma işlemi sonucu çıktı boyutu;

$$(n - 2p - F + 1) \times (n + 2p - F + 1) \quad (3.2)$$


ifadesi ile hesaplanabilir. Burada n girdi görselinin boyutu, p sıfır doldurma değerini ve F filtre boyutunu temsil etmektedir [45].

3.2.1.3 Aktivasyon Katmanı

ESA' da doğrusal olmayan dönüşümlere olanak sağlayarak ağıın eğitimini tamamlayabilmeyi kolaylaştırır.

3.2.1.3.1 Sigmoid Fonksiyonu

Grafikleri S şeklinde eğrilere benzeyen sigmoid fonksiyonu lojistik fonksiyon olarak da bilinir ve ESA' da kullanılan transfer fonksiyonlarından biridir. İkili sınıflandırma problemlerinde oldukça kullanışlıdır. Grafiği şekil 3.5'te görüldüğü gibidir.



Şekil 3.5 Sigmoid fonksiyonu grafiği

$$f(z) = \frac{1}{1+e^{-z}} \quad (3.3)$$


Burada $f(z)$ sigmoid fonksiyonun çıkışı, z ise fonksiyona giriştir.

3.2.1.3.2 ReLU

Evrişim katmanında üretilen her özellik haritası, bir ESA'ya doğrusal olmama sağlamak amacıyla ayrı ayrı düzeltilmiş doğrusal birim (ReLU) işlevi aracılığıyla çalıştırılır. ReLU fonksiyonu şu şekilde tanımlanır:


$$f(z) = \max(0, z) \quad (3.4)$$

Burada z , ReLU fonksiyonunun girişidir. ReLU, genelleme doğruluğundan önemli ölçüde ödün vermeden ağların daha hızlı eğitilmesine olanak tanıdığı için sıklıkla diğer aktivasyon fonksiyonları (sigmoid veya tanh gibi) yerine seçilir. Şekil 3.6' da ReLU fonksiyonu grafiği görülmektedir.




Şekil 3.6 ReLU fonksiyonunun çıkış verisi üzerinde gösterdiği etki

Şekil 3.7' de ReLU katmanının görüntüye yapmış olduğu katkı görülmektedir. Şekil 3.7 (a)'da ReLU katmanı öncesi görselin durumu gösterilirken, (b)'de ReLU katmanı sonrası görselin durumu gösterilmiştir. Şekilde de görüldüğü üzere ReLU katmanına giren görüntünün parlaklığı ve keskinliği artmıştır.



(a) ReLU öncesi



(b) ReLU sonrası


Şekil 3.7 ESA modelinde ReLU katmanının görüntüye yapmış olduğu etki

3.2.1.3.3 Hiperbolik Tanjant Fonksiyonu

Hiperbolik tanjant fonksiyonu sigmoid fonksiyonuna benzer ama sınırları farklıdır. Sigmoid fonksiyonunda sınırlar 0 ile 1 arasındayken hiperbolik tanjant fonksiyonunda -1 ile 1 arasındadır. Tanh fonksiyonu olarak da bilinir. Tanh fonksiyonu şu şekilde gösterilmektedir:

$$\tanh(x) = \frac{2}{1+e^{-2x}} - 1 \quad (3.5)$$


Burada $\tanh(x)$ tanh fonksiyonunun çıkış değeri ve x , fonksiyonun giriş değeridir. Şekil 3.8 'de tanh fonksiyonu grafiği görülmektedir.



Şekil 3.8 Tanh fonksiyonu grafiği


3.2.1.4 Havuzlama Katmanı

Bir ESA tasarımında, havuzlama katmanı evrişim katmanları arasına sıkıştırılmıştır. Havuzlama katmanının temel amacı, ağırlık hesaplamasını ve parametre sayısını azaltmak için düzeltilmiş özellik haritalarının boyutunu azaltmaktır, bu da eğitim süresini kısaltır ve aşırı uyumu önler. Havuzlamayı gerçekleştirmek için sıklıkla ortalama veya maksimum havuzlama gibi basit bir yöntem kullanılır. Maksimum havuzlamayı diğer havuzlama yöntemleriyle karşılaştırıldığında, maksimum havuzlama daha yüksek performans ve daha hızlı yakınsama göstermiştir [46]. Şekil 3.9’da maksimum ve ortalama havuzlama örneği görülmektedir.



Şekil 3.9 Maksimum ve ortalama havuzlama örneği

Şekil 3.10 (a)’da giriş görseli, (b)’de giriş görselinin konvolüsyon katmanı sonrası görselin durumu, (c)’ de giriş görselinin maksimum havuzlama katmanı sonrası görselin durumu gösterilmiştir.




Şekil 3.10 Giriş görseline konvolüsyon ve maksimum havuzlama uygulanması sonrası oluşan görüntüler

Şekilde de görüldüğü üzere konvolüsyon sonrası görüntünün kenarları belirginleştirilmiş ve maksimum havuzlama katmanı sonrası görselin gürültüsü azaltılmış ve boyutu küçültülmüştür.

3.2.1.5 Düzleştirme Katmanı

ESA'lar ve ileri beslemeli sinir ağlarının her ikisi de topolojilerinde ortak bir katman olarak düzleştirilmiş katmanı kullanır. 2 boyutlu veya 3 boyutlu gibi çok boyutlu formattaki veriler bu amaçla tek boyutlu bir vektöre dönüştürülür. Bir ESA'daki tamamen bağlı katmanlar, girişinin 1 boyutlu bir vektör olmasını beklediklerinden, bu yeniden şekillendirme, evrişimli ve havuzlama katmanlarından tamamen bağlı katmanlara geçerken gereklidir. Şekil 3.11' de Düzleştirme katmanı örneği görülmektedir.




Şekil 3.11 Düzleştirme katmanı örneği

3.2.1.6 Tam Bağlantılı Katman

Bir ESA tasarımında tam bağlantılı katman genellikle en sonda bulunur. Tam bağlantılı katmanda nöronlar, geleneksel sinir ağlarındakine benzer şekilde gruplandırılır. Önceki evrişimli veya havuzlama katmanının çıktısından elde edilen düzleştirilmiş bir vektör, girdi olarak kullanır. Bu nedenle, Şekil 3.12' de gösterildiği gibi, tamamen bağlantılı bir katmandaki her düğüm, önceki ve sonraki katmanlardaki her düğüme doğrudan bağlanır. Bunlar, ESA'nın

bu katmanların içinde kullandığı parametrelerin çoğu olduğundan, çok fazla eğitim süresi gerektirir [47].




Şekil 3.12 Tam bağlantılı katman yapısı

3.2.1.7 Seyreltme Katmanı

Aşırı uyumu azaltmak için derin öğrenmede ve sinir ağlarında seyreltme katmanı adı verilen bir düzenleme yöntemi kullanılır. Bir model, eğitim verileri üzerinde iyi performans göstermeyi öğrendiğinde ancak yeni, denenmemiş verilere genelleme yapmakta zorlandığında, modelin aşırı uyumlu olduğu söylenir. Seyreltme, bu soruna basit ama etkili bir çözümdür. Seyreltme katmanındaki nöronların (birimlerin) rastgele bir alt kümesi, her eğitim döngüsü sırasında anlık olarak "bırakılır" veya kapatılır. Bu durum bu nöronların sıfır çıktıya sahip olduğunu ve söz konusu yineleme için ağın ileri veya geri geçişine dahil edilmediklerini gösterir. Bir nöronun devre dışı bırakılma olasılığı, genellikle 0,2 ile 0,5 arasında ayarlanan bir hiper parametre olan ayrılma oranıyla belirlenir.

Seyreltme, eğitim sırasında nöronları rastgele devre dışı bırakarak ağı belirli nöronlara aşırı derecede bağımlı olmasını veya eğitim verilerinden gürültü almasını önler. Ağı daha dayanıklı ve yaygın özellikler kazanmaya motive eder.

Seyreltme normalde devre dışıdır ve çıkarım sırasında tüm nöronlar kullanılır (taze verilere dayalı tahminler üretilirken). Bu, modelin eğitim sırasında geliştirilen çeşitli alt ağlardan edinilen bilgileri başarılı bir şekilde entegre ettiğini ve daha fazla genellemeye yol açtığını gösterir. Şekil 3.13 (a)'da standart bir ESA yapısı gösterilirken, (b)'de seyreltme katmanından sonraki hali gösterilmiştir.



Şekil 3.13 Standart bir ESA ağına seyreltme katmanının uygulanması [48]

3.2.1.8 Sınıflandırma Katmanı

Tamamen bağlantılı katmanın ardından bu katman gelir. Derin öğrenme mimarisinin bu katmanında sınıflandırma gerçekleşir. Bu katmanın çıkış değeri sınıflandırılacak nesne sayısı kadardır. Örneğin 7 farklı sınıf varsa çıkış sayısı 7'dir. Farklı sınıflandırıcılar olsa da başarısından dolayı genellikle softmax kullanılır. Softmax olarak bilinen, bazen "softmax işlevi" veya "softmax aktivasyonu" olarak da bilinen bir matematiksel işlev, özellikle çok sınıflı sınıflandırma sorunları ve sinir ağları bağlamında derin öğrenme ve makine öğreniminde sıklıkla kullanılır. Gerçek değerlerin bir vektöründen olasılık dağılımı oluşturmak için uygulanır. Bir sınıflandırma sorununda birden fazla sınıfa olasılık vermek için softmax işlevi,

bir giriş vektörünü toplamı 1 olan bir olasılık vektörüne dönüştürür. Sınıflandırılacak nesneler 0-1 arasında bir çıkış değeri verir ve en büyük değer ağıın tahmin ettiği sınıf anlamına gelir.

3.2.2 Batch Boyutu

ESA' da görüntüleri doğru bir şekilde sınıflandırabilmenin yanında modelin performansına etki eden hiperparametreler de önemlidir. Bu hiperparametrelerin en önemlilerinden biri Batch boyutudur. Batch boyutunun yüksek ayarlanması ağıın yakınsamaya ulaşma süresini arttırırken, düşük ayarlanması istenilen performansa ulaşmadan ağıın ileri geri sıçramasına neden olur. Batch boyutu veri setinin büyüklüğüne ve türüne göre genellikle 2'nin katları olacak şekilde (16,32,64,128) ayarlanır. Batch boyutunda veri setindeki verileri tek tek eğitmek yerine veri setini tasarımcının belirlediği küme sayısına ayırıp bu parçalar üzerinde eğitim gerçekleştirilir [49].

3.2.3 Kayıp Fonksiyonu

Kayıp Fonksiyonları derin öğrenmede modelin tahmini ile gerçek sonuç arasındaki farkı hesaplayan hiperparemetredir. Bu fonksiyonlar modelin doğruluğunu değerlendirir ve eğitim sürecinde ağırlık güncellemelerinde yardımcı olur [50].

3.2.3.1 Kategorik Çapraz Entropi (Categorical Crossentropy)

ESA' da sınıflandırma içeren verilerde kullanılan bir kayıp fonksiyondur. Kategorik çapraz entropi şu şekilde gösterilmektedir.

$$H(y, \hat{y}) = - \sum_{i=1}^c y_i \cdot \log(\hat{y}_i) \quad (3.6)$$

Burada;

$H(y, \hat{y})$ kategorik çapraz entropi, y gerçek etiket (0 veya 1), $\hat{y}_i$ modelin tahmin ettiği etiket, c sınıf sayısıdır.

3.2.3.2 İkili Çapraz Entropi (Binary Cross-Entropy)

İkili çapraz entropi genellikle ikili sınıflandırmalarda kullanılır. Her bir sınıfın bağımsız ele alındığı durumlarda kullanılır. Şu şekilde gösterilir.

$$H(y, \hat{y}) = -[y \cdot \log(\hat{y}) + (1 - y) \cdot \log(1 - \hat{y})] \quad (3.7)$$

Burada;

$H(y, \hat{y})$ ikili çapraz entropi, y gerçek etiket (0 veya 1), $\hat{y}$ modelin tahmin ettiği etikettir.

3.2.3.3 Seyrek Kategorik Çapraz Entropi (Sparse Categorical Cross-Entropy)

Etiketlerin tek sıcak kodlanmış (one hot encoded) yerine tamsayılar olarak sağlandığı çok sınıflı sınıflandırmalar için kullanılır. Seyrek kategorik çapraz entropi şu şekilde gösterilir.

$$H(y, \hat{y}) = -\sum_{i=1}^c II(y = i) \cdot \log(\hat{y}_i) \quad (3.8)$$

Burada;

$H(y, \hat{y})$ seyrek kategorik çapraz entropi, y gerçek etiket (0 veya 1), $\hat{y}_i$ modelin tahmin ettiği etiket, c sınıf sayısı, $II(y = i)$ $y = i$ olduğunda 1'e aksi durumda 0'a eşit olan gösterge fonksiyonudur.

3.2.3.4 Ortalama Karesel Hata (Mean Squared Error -MSE)

Modelin tahminlerini gerçek değerlerle karşılaştırır ve her hata değerinin karesini alır. MSE şu şekilde gösterilir.

$$MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^a (y_i - \hat{y}_i)^2 \quad (3.9)$$

Burada;

$MSE(y, \hat{y})$ Ortalama kare hata, y_i gerçek etiket, $\hat{y}_i$ modelin tahmin ettiği etiket ve a örnek sayısıdır.

3.2.4 Eğitim Tur (Epok) Sayısı

Epok sayısı, eğitim sırasında veri setinin modelden kaç kez geçirildiğini belirleyen parametredir. Tur sayısı, karmaşık ve büyük veri setlerinde fazla olabilirken küçük veri setlerinde daha azdır. Modelin başarı oranı her turda ağırlıklar yenilendikçe artmaktadır. Belirli bir tur sayısından sonra modelin başarı oranı daha da artmamaya başlar ve böyle durumlarda eğitim sonlandırılabilir.

3.2.5 Modelin Öğrenme Oranı

Model öğrenme oranı, modelin eğitimi sırasında ağırlıkların güncellenme miktarını belirleyen faktördür. Bu değer her iterasyon işleminden sonra güncellenir. Öğrenme oranı modelin ne kadar hızlı ve yavaş eğitileceği konusunda önemli bir parametredir. Yüksek öğrenme oranı modeli hızlı eğitirken atlamalara neden olabilir. Düşük öğrenme oranı modelin yavaş öğrenmesini sağlar ve eğitim süresini uzatır. İdeal öğrenme oranı deneme yanılma yöntemiyle bulunabilir. Doğru öğrenme modeli seçilerek model hızlı ve iyi bir performansla eğitilebilir.


3.2.6 Optimizasyon Çeşitleri

Optimizasyon metotları, sinir ağlarını düzgün ve etkili bir şekilde eğitmek için kullanılan algoritmalarlardır. Temel amaç sinir ağlarının ağırlık ve sapma parametrelerini ayarlayarak maliyet ve kaybı en aza indirmektir.

3.2.6.1 Gradyan Azalması (Gradient Descent-GD)

En popüler optimizasyon metotlarından olan GD bir diferansiyel denklemin yerel minimumunu bulmada 1.dereceden yinelemeli bir algoritmadır. GD da teori fonksiyonun rastgele bir yerinde başlanarak eğimin tersi yönünde adımlar atılmasıdır ve bu dik iniş yönü olarak kabul edilir.

Gradyan yönünde adım atmak ise yerel maksimum ile sonuçlanacaktır [51]. Şekil 3.14’ de GD algoritması gösterilmektedir.



Şekil 3.14 GD algoritması [52]

Veri miktarına bağlı olarak değişen 3 farklı GD algoritması vardır. Bunlar Batch Gradient Descent, Stochastic Gradient Descent ve Mini-Batch Gradient Descent.

3.2.6.1.1 Toplu Gradyan Azalması (Batch Gradient Descent-BGD)

Bazı yerlerde Vanilla GD olarak da bilenen BGD eğitim veri setindeki (training data set) her bir örnek için hatayı hesaplar [53]. Ancak model, tüm eğitim örnekleri değerlendirildikten sonra revize edilir Tüm bu süreç eğitim dönemi denir. Doğru hesaplama, dengeli bir hata eğilimi ve kararlı bir yakınsama BGD’nin yararlarındandır. Tüm veri setinin algoritmada hazır ve kullanılabilir durumda olması ise zararlarındandır. BGD en hassas performansı sunar ancak verilerin tam taranması gerekir [54].

3.2.6.1.2 Stokastik Gradyan Azalması (Stochastic Gradient Descent-SGD)

BGD’nin aksine SGD veri kümesindeki her eğitim örneği için yapar. Eğitim örneğinin parametrelerini tek tek günceller. Bu yaklaşım, tüm veri kümesinin eğimini bulmak yerine rastgele seçilen bir bölümünün eğimini yaklaşık olarak hesaplayarak hatayı azaltır. Sık sık yapılan güncellemelerle hesaplama açısından BGD ‘den karmaşıktır. Ayrıca güncellemelerin sıklığı gürültülü eğimlere neden olabilir ve bu gürültülü eğimler hata oranının yavaş yavaş azalması yerine atlamalara neden olabilir [55].

3.2.6.1.3 Mini Toplu Gradyan Azalması (Mini-Batch Gradient Descent)

Mini-batch gradient descent SGD ile BGD'nin birleşimi sonucu ortaya çıkarılmıştır. Eğitim veri kümesini küçük parçalara ayırır ve her parça için güncellemeler yapılır. Mini-batch boyutları 2'nin katları (32, 64,128,256) arasında değişir ve modele göre uygulandığı için sabit bir kuralı yoktur [56].

3.2.6.2 Uyarlanabilir Gradyan Azalması (Adaptive Gradient Descent-AdaGrad)

AdaGrad duruma göre öğrenme oranını seçen bir algoritmadır. Adagrad'ın arkasındaki temel fikir, parametrelerin öğrenme oranlarını tarihsel değişimlerine göre ölçeklendirmektir. Sık ve büyük gradyanlar alan parametrelerin öğrenme oranları daha hızlı azalırken, seyrek veya küçük gradyanlar alan parametrelerin öğrenme oranları daha yavaş azalır. Seyrek gradyanlarla çalışırken veya özelliklerin oldukça farklı boyutlara sahip olduğu senaryolarda Adagrad'ın öğrenme oranlarını verilerin özelliklerine göre dinamik olarak ayarlama kapasitesi yararlı olabilir. Eğitim sırasında AdaGrad optimizasyon yaklaşımına eklenen her terim pozitif olduğundan toplam birikir. Bu durumda modelin öğrenme hızı azalır ve sonunda sonsuz hale gelir, bu da algoritmanın daha fazla veri toplamasını imkânsız hale getirir [57].

3.2.6.3 Uyarlanabilir Delta (Adaptive Delta-AdaDelta)

AdaDelta, Adagrad'ın bir eklentisidir. Adagrad'ın bazı dezavantajlarını, özellikle de zamanla monoton bir şekilde azalan ve son derece küçük güncellemelere ve yavaş yakınsamaya neden olabilen öğrenme oranları sorununu çözmek için 2012 yılında Matthew Zeiler tarafından tanıtılmıştır. SGD manuel öğrenme hızı seçimi gerektirdiğinden dolayı seçilen öğrenme hızı düşük tahmin doğruluğuna neden olacaktır. AdaDelta öğrenme hızını otomatik bir şekilde ayarlayarak yüksek tahmin doğruluğu sonucuna ulaşılabilir [58].

3.2.6.4 Karekök Ortalama Yayılımı (Root Mean Square Propagation-RMSProp)

RMSProp öğrenme oranını gradyanların büyüklüğüne göre optimize eden bir algoritmadır. Büyük gradyanlara sahip parametrelerin öğrenme oranı küçülürken, küçük gradyanlara sahip parametrelerin öğrenme oranı büyür ve bu durum daha etkili optimizasyon için değerlidir. RMSprop'un AdaGrad'a göre avantajı öğrenme oranlarının azalma sorununu çözmesidir.

RMSProp, kare gradyanların üstel ağırlıklı hareketli ortalamasını birleştirerek öğrenme oranlarının çok hızlı azalması sorununu önler ve böylece yavaş yakınsama ile ilgili potansiyel zorlukların önüne geçer [59].

3.2.6.5 Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation-Adam)

Adam her parametre için öğrenme oranlarını ölçen bir optimizasyon yöntemidir. RMSProp ve Momentum birleştirilerek oluşturulmuştur. Adam, RMSProp da olduğu gibi kare bir gradyan kullanır ve Momentum gibi gradyanın hareketli ortalamasını izler [60]. Bu Adam'ı anlara göre uyarlanabilen bir algoritma haline getirir. Adam kullanmanın avantajlarından biri, nispeten düşük bellek ihtiyaçları ve gradyanların birinci ve ikinci anlarına dayalı olarak parametre güncellemelerini yeniden ölçeklendirme yeteneği nedeniyle gürültülü ve seyrek gradyanlarla ilgili problemlere uygulanabilmesidir.

3.2.6.6 Maksimum Uyarlanabilir Moment Tahmini (Maximum Adaptive Moment Estimation-AdaMax)

AdaMax, Adam'ın maksimum mutlak değerini kullanarak uyarlanabilir öğrenme oranı yaklaşımını genişleten bir türüdür. AdaMax daha istikrarlı ve tutarlı bir güncelleme kuralı sağlamak için tasarlanmıştır.ve SGD'ye göre daha az hassas hiperparametre seçimi sunar [61].

3.2.7 Transfer Öğrenme

ESA'larda yüksek başarı oranına ulaşmak amacıyla büyük veri setleri kullanılır. Veri setinin büyük olması modelin daha fazla örnekle karşılaşması ve daha spesifik özellikleri saptayabilmesi adına önemlidir. Veri seti büyüdükçe modelde kullanılacak donanım artmaktadır. Bunun neticesinde daha fazla katman kullanılacak ve maliyet de artacaktır.


İnsanlar geçmişlerinde edindikleri bilgiler sayesinde karşısına çıkan yeni problemlere çözümler üretebilmektedir. Tıpkı insanlar gibi yapay zekâ da aynı durum geçerlidir. Transfer öğrenmesi YSA' da eğitim aşamalarında öğrenilen bilgileri farklı sorunları çözmede de kullanma yöntemidir bu da maliyet, donanım ve zaman aşamasından pozitif etki etmektedir. Transfer Öğrenme iki aşamadan oluşur. İlk aşama, belirli bir görev için hazırlanmış veri kümesi bir model yardımıyla eğitilir. Bu model verilerden özellik haritaları çıkarır ve bilgileri yakalar.

Önceden eğitilmiş model daha sonra farklı bir veri seti için uyarlanır ve ince ayarlamaları (özellik çıkarma, hedef göreve adaptasyon) yapılır. Sonuç olarak model sıfırdan eğitilmek yerine daha önceden öğrendiği bilgiyi kullanır ve bu da daha az veri ve hesaplama gerektirir [62].

3.2.7.1 Görsel Geometri Grubu (Visual Geometry Group-VGG)

Adını Oxford Üniversitesi Görsel Geometri grubundan alan VGG, görüntü sınıflandırma görevleri için tasarlanmış bir transfer öğrenme modelidir. VGG-16 ve VGG-19 olmak üzere 2 farklı modeli vardır. Model yanlarındaki sayılar katman sayısını ifade eder. VGG-16 da 16 katman (13 evrişimli katman + 3 tam bağlantılı katman) ve VGG-19 da 19 katman (16 evrişimli katman + 3 tam bağlantılı katman) vardır. VGG de giriş görseli boyutu 224x224'tür.

Tüm evrişimli katmanlar 3x3 filtreler kullanır. Parametre ve hesap sayısını azaltmak amacıyla 2x2 filtre boyutunda maksimum havuzlama katmanları kullanır. Aktivasyon fonksiyonu olarak ReLU kullanılır ve Evrişimli katmanlar sınıflandırma için 3 adet tam bağlantılı katman ile bağlanır. Tam bağlantılı katmanların ilk ikisi 4096 boyutunda sonuncusu ise ImageNet veri seti yarışması için 1000 katmanlıdır [63]. Şekil 3.15' te VGG-16 mimarisi gösterilmektedir.



Şekil 3.15 VGG-16 mimarisi

3.2.7.2 ResNet

Derin Ağlarda kaybolan gradyan sorunu çözmek adına 2016 yılında Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından tanıtılmıştır. ResNet ile birlikte gelen en büyük

yenilik, bir veya daha fazla katmanı atlayan bağlantıların veya kısayolların atlanmasını sağlayan artık blokların kullanılmasıdır. Bu atlama bağlantıları eğimin ağ üzerinden daha kolay akmasını sağlayarak performans düşüşü olmadan ağı derin ağların eğitilmesini sağlar [64]. ResNet katman sayısına bağlı olarak değişen farklı türlere sahiptir. (ResNet-18, ResNet-34, ResNet-50, ResNet-101 ve ResNet-152) Yüksek katman sayısına sahip türler daha karmaşık problemlerin çözümünde kullanılır. Her bir blok darboğaz olarak bilinen 3 evrişimli katmandan oluşur (1x1, 3x3 ve 1x1). Bu durum verimlilik açısından önemlidir.

3.2.7.3 InceptionV3 (GoogLeNet)

2014 yılında Christian Szegedy ve arkadaşları tarafından geliştirildi. Bu mimarinin en büyük yeniliği aynı katmanda paralel olarak birden fazla filtre boyutunu birleştiren modüllerin kullanılmasıdır. Bu durum çeşitli ölçeklerde ve karmaşıklıklarda özelliklerin çıkarılmasına olanak tanır. Mimarisi geleneksel katmanlardan daha karmaşıktır. Verimlilik için tasarlanmasına rağmen çok sayıda işlem nedeniyle kaynak kullanımı fazladır [65].

3.2.7.4 Xception

Inception mimarisinin genişletilmiş ve geliştirilmiş versiyonudur. 2017 yılında François Chollet tarafından oluşturulmuştur. Xception mimarisinin en büyük yeniliği derinlemesine ayrılabilir evrişimlerin kullanılmasıdır. ESA'nın özellik haritalarındaki kanallar arası korelasyonlar ve uzaysal korelasyonlar tamamen ayrıştırılabilir şekildedir [66]. Bu, mimarinin tanımlanmasını ve değiştirilmesini çok kolaylaştırır. Xception'da filtreler önce mekânsal ardından da kanal tabanlı işlenir ve bu Inception'a göre daha az parametre ve hesaplama maliyeti anlamına gelir.

3.2.7.5 DenseNet

Yoğun Bağlantılı Evrişimli Ağlar yani kısaca DenseNet 2017 yılında Gao Huang, Zhuang Liu ve Kilian Q. Weinberger tarafından tanıtıldı. DenseNet te temel amaç katmanlar arası yoğun bağlantılar oluşturularak ağ boyunca bilgi akışı ve gradyanları iyileştirmektir. Geleneksel ESA lardan farklı olarak her katman önceki katmandan girdi alır. Bu durum yok olan gradyan sorununu çözmeye çalışır ve ağı bilgileri ağ üzerinden daha iyi yakalayıp yaymasını sağlar. Geleneksel mimarilere kıyasla daha az parametre içermesi daha az hesaplama sağlar ve maliyeti

düşürür. DenseNet'ler, parametreleri verimli bir şekilde kullanarak diğer mimarilerden daha iyi performans göstererek, görüntü sınıflandırmada olağanüstü performans sergilemiştir [67].



BÖLÜM 4

BULGULAR

4.1 GÜNEŞ PANELİ VERİ SETİ

Çalışma kapsamında kullanılan veri seti açık erişimli kaggle web sitesinden elde edilmiştir [37]. Veri setinde Tablo 4.1 'de görüldüğü üzere toplam 988 adet farklı görüntü vardır. Görüntülerin boyutları 196 x 110 piksel ile 6240 x 4160 piksel aralığındadır. Her görüntü 0-6 arası sınıflandırılmıştır. Kuş pisliği olan paneller 0, temiz olan paneller 1, tozlu olan paneller 2, elektriksel hasarlı paneller 3, fiziksel hasarlı paneller 4, karla kaplı paneller 5, gölgelenmiş paneller 6 olarak sınıflandırılmıştır.

Çizelge 4.1 Orijinal veri seti

Sınıf	Panel Durumu	Görüntü Sayısı
0	Kuş pisliği	200
1	Temiz	202
2	Tozlu	220
3	Elektriksel hasarlı	98
4	Fiziksel hasarlı	66
5	Karlı	122
6	Gölgelenmiş	80

Çizelge 4.1 'de görüldüğü üzere veri setinde 200 adet kuş pisliği, 202 adet temiz, 220 adet tozlu 98 adet elektriksel hasarlı 66 adet fiziksel hasarlı, 122 adet karlı ve 80 adet gölgelenmiş panel görüntüsü vardır. Bu çalışmada kullanılan veri setindeki panel görüntüsü örnekleri Şekil 4.1 'de gösterilmiştir.



Şekil 4.1 Veri setinden örnekler

Çizelge 4.1’ de görüldüğü üzere veri setinin görüntü sayısı açısından yetersiz olması ve sınıflandırma elemanları arasındaki sayı dengesizliği dikkat çekmektedir. Ayrıca, .png ve .jpg olarak bulunan görüntülerin çözünürlükleri farklılık göstermektedir. Bunun önüne geçmek için veri seti çözünürlükleri 256x256 hale getirilmiş ve farklı veri çoğaltma metotları (ölçeklendirme, döndürme, yakınlaştırma, gürültü ekleme) kullanılarak veri setinin her sınıfı için yaklaşık 1000’er ve toplamda 6097 adet görüntü elde edilmiştir. Çoğaltılan veri seti ile modelin aşırı öğrenmesinin önüne geçilmiştir. Yeni veri setinin görüntü sayısı Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2 Çoğaltılmış veri seti

Sınıf	Panel Durumu	Görüntü Sayısı
0	Kuş pisliği	820
1	Temiz	1040
2	Tozlu	920
3	Elektriksel Hasarlı	850
4	Fiziksel Hasarlı	830
5	Karlı	917
6	Gölgelenmiş	720

4.2 ÖN İŞLEM ADIMLARI

Ön işlem adımında veri setindeki anormallikler ve eksiklikler giderilerek veri seti eğitim için hazır hale getirilmiştir. Ön işleme adımı iki aşamadan oluşmaktadır.


İlk aşamada veri setindeki görüntülerin piksellerinin değişkenliğinin giderilmesi için her görüntü 256*256 piksel boyutuna düzenlenmiştir. Böylece hem görüntü boyutlarındaki tutarsızlık düzenlenmiş oldu hem de modelin işlem yükü azaltılmış oldu. Görüntü boyutunun büyük olması modelin daha fazla sayıyla uğraşmasına neden olur ve bu da maliyeti arttırır.

İkinci aşamada veri setindeki görüntü sayısının yetersiz oluşu ve veri setindeki sınıflardaki elemanların sayı dengesizliği veri çoğaltma tekniklerini kullanmayı zorunlu kılmıştır. Veri çoğaltma teknikleri veri seti sayısındaki eksikleri gidermek için kullanılan (Görüntüyü 90° 180° ve 270 ° döndürme, x eksenine göre simetriğini alma ve y eksenine göre simetriğini alma, görüntüye gürültü ekleme vb.) görüntü işleme metotlarını içermektedir. Sonuç olarak 980 olan veri sayısı 6097' ye çıkarılmıştır.

4.2.1 Görüntüyü Döndürme

Görüntüyü döndürme tekniği mevcut görüntünün belirli açılarla döndürülerek yeni görüntüler elde edilmesi işlemidir. Bu işlem veri setindeki eleman sayısını arttırarak modelin çeşitli veri örnekleriyle karşılaşmasını sağlar ve aşırı uyumu önler. Şekil 4.2'de veri setinden, görüntü döndürme tekniği kullanılan örnek bir görüntü gösterilmektedir. Şekil 4.2 (a)' da orijinal güneş paneli görüntüsü, (b)' de Orijinal görüntünün 90° döndürülmesi sonucu oluşan görüntü, (c)' de


Orijinal görüntünün 180° döndürülmesi sonucu oluşan görüntü, (d)' de Orijinal görüntünün 270° döndürülmesi sonucu oluşan görüntü görülmektedir.



Şekil 4.2 Veri seti üzerinde görüntü işleme tekniklerinden döndürme örneği

4.2.2 Görüntünün x ve y Eksenlerine Göre Simetriğini Alma


Görüntünün x eksenine göre simetriğini alma işlemi görüntüyü yatay olarak yansıtmak anlamına gelmektedir. Yani görüntünün sağ ve sol taraflarının değişmesidir. Görüntünün y eksenine göre simetriğini alma işlemi de görüntünün dikey olarak yansıtılmasıdır. Yani görüntünün üst ve alt taraflarının değişmesidir. Şekil 4.3'te simetriği alma işlemi uygulanmış örnek bir görüntü görülmektedir. Şekil 4.3 (a)' da orijinal güneş paneli görüntüsü, (b)' de orijinal görüntünün x eksenine göre simetriği alınması sonucu oluşan görüntü, (c)' de orijinal görüntünün y eksenine göre simetriği alınması sonucu oluşan görüntü görülmektedir.



Şekil 4.3 Veri seti üzerinde görüntü işleme tekniklerinden simetriğini alma örneği

4.2.3 Görüntüye Gürültü Ekleme

Görüntü çeşitliliğini arttırmak ve modelin dayanıklılığını yani bozulma yaşamış görüntülere karşı da performans vermesini sağlamak amacıyla orijinal görüntülere gürültü eklenmiştir. Bir görüntünün gürültüsü, görüntünün içindeki piksel değerlerinde kasıtsız, rastgele bozulmalara veya ayarlamalara neden olan bir tür yanlışlıktır. Gürültü çeşitli kaynaklardan ortaya çıkabilir ve görüntünün kalitesini düşürebilir. Gürültü, görüntüde rastgele bir oranla dağılır [68]. Şekil 4.4’ te gürültü eklenmiş bir görsel örneği görülmektedir. Şekil 4.4 (a)’ da orijinal güneş paneli görüntüsü, (b)’ de orijinal görüntüye %20 oranında gürültü eklenmesi sonucu oluşan yeni görüntü gösterilmektedir.



Şekil 4.4 Veri seti üzerinde görüntü işleme tekniklerinden gürültü ekleme örneği

4.3 PERFORMANS METRİKLERİ

Derin öğrenmede modelin ne kadar doğru bir şekilde eğitildiğini test etmek için test veri seti kullanılır. Test verisi modelin eğitim aşamasına dahil olmaz. Bu durum modelin başarısını görebilmek adına oldukça önemlidir. Çünkü model eğitim aşamasında işlem yaptığı görüntüyü daha kolay bir şekilde tanır. Modelin performansının değerlendirilmesi için bazı performans teknikleri kullanılır. Bu çalışmada modelin performansı görülmesi için karışıklık matrisi ve bu matrisle hesaplanan kesinlik, geri çağırma, doğruluk ve f-1 skoru performans metrikleri kullanılmıştır.

4.3.1 Karışıklık Matrisi

Karışıklık matrisi model performansını değerlendirmek için kullanılan araçlardan biridir. Karışıklık matrisi modelin doğru ve yanlış sınıflandırmalarını özet bir şekilde görülmesini sağlar. Karışıklık matrisine göre kesinlik, geri çağırma, doğruluk ve f1 skoru gibi performans metrikleri hesaplanabilir.

Kesinlik: Gerçek pozitiflerin tahmin edilen toplam pozitiflere oranıdır [69]. Eşitlik (4.1)'de TP gerçek pozitif (True Positive- TP), FP tahmin pozitif (False Positive- FP) değerleri göstermektedir.

$$\frac{TP}{TP+FP} \quad (4.1)$$

Geri Çağırma: Veri kümesindeki tüm olumlu örnekler arasında model tarafından doğru şekilde tahmin edilen gerçek olumlu örneklerin oranını gösterir [69]. Eşitlik (4.2)' de TN gerçek negatif (True Negative- TN) değeri gösterilmektedir.

$$\frac{TP}{TP+FN} \quad (4.2)$$

Doğruluk: Tüm tahminler içinden doğru tahmin edilen örneklerin oranıdır [70]. Eşitlik (4.3)' de FN tahmin negatif (False Negative- FN) değeri gösterilmektedir.

$$\frac{TP+TN}{TP+TN+FP+FN} \quad (4.3)$$

F1-Skoru: İki ölçüm arasında denge sağlayan hassaslık ve hatırlamanın harmonik ortalamasıdır [69].

$$\frac{2*Geri\ Çağırma*Kesinlik}{(Kesinlik+Geri\ Çağırma)} \quad (4.4)$$

Eşitlik (1), (2) (3) ve (4) 'te TP modelin pozitif bir sınıfın bir örneğini pozitif olarak doğru bir şekilde tanımladığı örnekleri gösteren gerçek pozitifler; TN modelin negatif sınıfın bir örneğini negatif olarak doğru bir şekilde tanımladığı örnekleri gösteren gerçek negatifler; FP modelin negatif bir sınıf örneğini hatalı olarak pozitif olarak yansıttığı örnekleri gösteren yanlış pozitifler; FN modelin pozitif bir sınıf örneğini olumsuz olarak yanlış yorumladığı örnekleri gösteren yanlış negatifler anlamına gelmektedir. Çizelge 4.3'te sınıflandırma işlemi için karışıklık matrisi gösterilmiştir.

Çizelge 4.3 Karışıklık matrisi parametreleri

	Tahmin Pozitif	Tahmin Negatif
Gerçek Pozitif	TP	FP
Gerçek Negatif	FN	TN


4.4 ÖNERİLEN MODEL

Bu tez çalışmasında güneş paneli kusurlarının sınıflandırılması için oluşturulan model kullanılmıştır. Modelin performansı belirli ayarlamalar ile arttırılmaya çalışılmıştır.

Önerilen modelin öğrenme oranı 10⁻⁵, epok sayısı 50 ve kümeleme sayısı modelin eğitim süresini ve işlem sayısını azaltmak için 32 olarak belirlenmiştir. En hızlı şekilde en iyi yakınsamayı yaptığı için “Adam” optimizasyonu ve kayıp fonksiyonu olarak “Seyrek Kategorik Çapraz Entropi” kullanılmıştır. Veri seti %80 eğitim, %10 doğrulama ve %10 test olarak 3 parçaya bölünmüştür. Çizelge 4.4’ te önerilen modelde kullanılan parametreler görülmektedir.

Çizelge 4.4 Önerilen modelde kullanılan parametreler

Epok sayısı	50
Kümeleme(batch)	32
Öğrenme oranı	10 ⁻⁵
Görsel boyutları	256x256
Evrişim Aktivasyon fonksiyonu	ReLU
Optimizasyon	Adam
Sınıflandırma Aktivasyon fonksiyonu	Softmax
Kayıp fonksiyonu	Seyrek Kategorik Çapraz Entropi
Seyreltme katsayısı	0,5



Şekil 4.5 Önerilen modelin yapısı


Şekil 4.5'te önerilen modelin yapısı görülmektedir. Önerilen modelin giriş katmanı 256x256 pikseli görüntülerden oluşmaktadır. Giriş katmanının ardından 6 adet evrişim katmanı içermektedir. Evrişim katmanları sırasıyla (32,64,64,64,64,64) derinliklerini içermektedir. Evrişim katmanında işlemler ReLU aktivasyon fonksiyonuyla tamamlanır bu durum eğitimin tamamlanmasını kolaylaştırır. Her evrişim katmanından sonra 2x2'lik maksimum havuzlama katmanı kullanılmıştır. Havuzlama katmanı ağırlık hesaplama miktarını azaltarak eğitim süresini azaltma görevini üstlenmektedir. Üste üste gelen evrişim ve havuzlama katmanlarından sonra modele düzleştirme katmanı eklenmiştir. Düzleştirme katmanına 64 derinlikli tam bağlantılı katman bağlanmıştır. Modelde aşırı uyumu azaltmak için 0,5 değerinde seyreltme katmanı kullanılmıştır. Tamamen bağlantılı katmanın hemen ardından sınıflandırma katmanı bağlanmıştır. Sınıflandırma katmanı; “kuş pisliği, temiz, tozlu, elektriksel hasarlı, fiziksel hasarlı, karlı ve gölgelenmiş” olarak 7 sınıftan oluştuğu için 7 nöronludur.

4.5 DENEYSEL SONUÇLAR

Güneş paneli kusurlarının sınıflandırılmasına yönelik yapılan bütün çalışmalar, Intel(R) Core(TM) i5-7200U CPU @ 2,50GHz 2,71 GHz işlemci, 2 GB NVIDIA GeForce 940 MX ekran kartı ve 12 GB RAM'e sahip bilgisayarda Jupyter Notebook kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan veri seti önerilen model dışında en yaygın kullanılan modellerden olan VGG-19 InceptionV3 ve Resnet101 gibi modellerde de eğitilerek sonuçlar karşılaştırılmıştır.


4.5.1 VGG-19 Modeli Sonuçları

Veri seti VGG-19 modeliyle 8 saat 13 dakikada eğitilmiştir. Veri setinin VGG-19 modeliyle eğitilmesi sonucu ortaya çıkan eğitim doğrulama kaybı grafiği Şekil 4.6' da gösterilmektedir. Eğitim kaybının son değeri:0,5158 ve doğrulama kaybının son değeri:0,2417 olarak gözlenmiştir. Değerlerin 0' a yakınsaması modelin aşırı uyuma düşmediğini göstermektedir.




Şekil 4.6 VGG-19 modelinin eğitim ve doğrulama kaybı grafiği

VGG-19 modelinin eğitim ve doğrulama başarıları grafiği Şekil 4.7’ de görülmektedir. Model test edilen verileri %94,53’ lük başarıyla sınıflandırabilmektedir.



Şekil 4.7 VGG-19 modelinin eğitim ve doğrulama başarıları grafiği

VGG-19 modelinin karışıklık matrisi Şekil 4.8’ de gösterilmektedir. Şekilde görüldüğü üzere “kuş pisliği” sınıfında 83, “temiz” sınıfında 101, “tozlu” sınıfında 100, “elektriksel hasarlı” sınıfında 96, “fiziksel hasarlı” sınıfında 75, “karlı” sınıfında 100, “gölgeleşmiş” sınıfında 85 ve toplamda 640 adet test verisi bulunmaktadır. Model test verisindeki 83 adet kuş pisliği etiketinden 76 adetini doğru sınıflandırmış, 6 adetini tozlu ve 1 adetini fiziksel hasarlı olarak yanlış sınıflandırmıştır. Modelin kuş pisliği etiketini sınıflandırma başarısı %91,56’dır. Model test verisindeki 101 adet temiz etiketinden 86 adetini doğru sınıflandırmış, 12 adetini tozlu ve 3 adetini karlı olarak yanlış sınıflandırmıştır. Modelin temiz etiketini sınıflandırma başarısı %85,14’tür. Model test verisindeki 100 adet tozlu etiketinden 95 adetini doğru sınıflandırmış, 2 adetini kuş pisliği, 1 adetini elektriksel hasarlı, 1 adetini karlı ve 1 adetini gölgeleşmiş olarak yanlış sınıflandırmıştır. Modelin tozlu etiketini sınıflandırma başarısı %95’tir. Model test verisindeki 96 adet elektriksel hasarlı etiketinden tamamını doğru sınıflandırmıştır. Modelin elektriksel hasarlı etiketini sınıflandırma başarısı %100’ dür. Model test verisindeki 75 adet fiziksel hasarlı etiketinden 73 adetini doğru sınıflandırmış, 1 adetini kuş pisliği ve 1 adetini tozlu olarak yanlış sınıflandırmıştır. Modelin fiziksel hasarlı etiketini sınıflandırma başarısı %97,33’tür. Model test verisindeki 100 adet karlı etiketinden tamamını doğru sınıflandırmıştır. Modelin karlı etiketini sınıflandırma başarısı %100’ dür. Model test verisindeki 85 adet gölgeleşmiş etiketinden 79 adetini doğru sınıflandırmış, 1 adetini kuş pisliği ve 5 adetini tozlu olarak yanlış sınıflandırmıştır. Modelin gölgeleşmiş etiketini sınıflandırma başarısı %92,94’tür.



Şekil 4.8 VGG-19 modelinin karışıklık matrisi


Çizelge 4.5 VGG-19 modelinin performansı

	Kesinlik	Geri Çağırma	Doğruluk	F1-skoru
Kuş Pisliği	0,92	0,95	0,98	0,93
Temiz	0,85	1	0,98	0,92
Tozlu	0,95	0,8	0,95	0,87
Elektriksel Hasarlı	1	0,99	1	0,99
Fiziksel Hasarlı	0,97	0,99	0,99	0,98
Karlı	1	0,96	0,99	0,98
Gölgelenmiş	0,93	0,99	0,99	0,96
Ortalama	0,95	0,95	0,98	0,95

Çizelge 4.5’de VGG-19 modelinin her bir sınıf için Kesinlik, Geri Çağırma, Doğruluk değerleri gösterilmektedir. Bunun sonucunda Kesinlik değeri:0,95, Geri Çağırma değeri: 0,95, Doğruluk değeri:0,98 ve F1-skoru: 0,95 olarak hesaplanmıştır.


4.5.2 InceptionV3 Modeli Sonuçları

Veri seti InceptionV3 modeliyle 1 saat 30 dakikada eğitilmiştir. Veri setinin InceptionV3 modeliyle eğitilmesi sonucu ortaya çıkan eğitim doğrulama kaybı grafiği Şekil 4.9’ da gösterilmektedir.



Şekil 4.9 InceptionV3 modelinin eğitim ve doğrulama kaybı grafiği


Eğitim kaybının son değeri:0,3112 ve doğrulama kaybının son değeri:0,3071 olarak gözlenmiştir. Değerlerin 0' a yakınsaması modelin aşırı uyuma düşmediğini göstermektedir. InceptionV3 modelinin eğitim ve doğrulama başarıları grafiği Şekil 4.10' da görülmektedir. Model test edilen verileri %89,68' lik başarı oranıyla sınıflandırabilmektedir.



Şekil 4.10 InceptionV3 modelinin eğitim ve doğrulama başarıları grafiği

InceptionV3 modelinin karışıklık matrisi Şekil 4.11' de gösterilmektedir. Şekilde görüldüğü “kuş pisliği” sınıfında 83, “temiz” sınıfında 101, “tozlu” sınıfında 100, “elektriksel hasarlı” sınıfında 96, “fiziksel hasarlı” sınıfında 75, “karlı” sınıfında 100, “gölgelenmiş” sınıfında 85 ve toplamda 640 adet test verisi bulunmaktadır. Model test verisindeki 83 adet kuş pisliği etiketinden 73 adetini doğru sınıflandırmış, 4 adetini temiz, 5 adetini tozlu ve 1 adetini fiziksel hasarlı olarak yanlış sınıflandırmıştır. Modelin kuş pisliği etiketini sınıflandırma başarıları %87,95’tir. Model test verisindeki 101 adet temiz etiketinden 88 adetini doğru sınıflandırmış, 1 adetini kuş pisliği, 7 adetini tozlu ve 5 adetini gölgelenmiş olarak yanlış sınıflandırmıştır. Modelin temiz etiketini sınıflandırma başarıları %87,12’dir. Model test verisindeki 100 adet tozlu etiketinden 94 adetini doğru sınıflandırmış, 1 adetini kuş pisliği, 4 adetini temiz ve 1 adetini elektriksel hasarlı olarak yanlış sınıflandırmıştır. Modelin tozlu etiketini sınıflandırma başarıları %94’tür. Model test verisindeki 96 adet elektriksel hasarlı etiketinden 93 adetini doğru sınıflandırmış, 1 adetini temiz ve 2 adetini tozlu olarak yanlış sınıflandırmıştır. Modelin elektriksel hasarlı etiketini sınıflandırma başarıları %96,87’dir. Model test verisindeki 75 adet fiziksel hasarlı etiketinden 71 adetini doğru sınıflandırmış, 2 adetini temiz ve 2 adetini tozlu olarak yanlış sınıflandırmıştır. Modelin fiziksel hasarlı etiketini sınıflandırma başarıları

%94,66'dır. Model test verisindeki 100 adet karlı etiketinden 97 adetini doğru sınıflandırmış, 2 adetini temiz ve 1 adetini gölgelenmiş olarak yanlış sınıflandırmıştır. Modelin sınıflandırma karlı etiketini başarısı %97' dir. Model test verisindeki 85 adet gölgelenmiş etiketinden 58 adetini doğru sınıflandırmış, 16 adetini temiz, 10 adetini tozlu ve 1 adetini fiziksel hasarlı olarak yanlış sınıflandırmıştır. Modelin gölgelenmiş etiketini sınıflandırma başarısı %68,23'tür.



Şekil 4.11 InceptionV3 modelinin karışıklık matrisi


Çizelge 4.6 InceptionV3 modelinin performansı

	Kesinlik	Geri Çağırma	Doğruluk	F1-skoru
Kuş Pisliği	0,88	0,97	0,98	0,92
Temiz	0,87	0,75	0,93	0,81
Tozlu	0,94	0,78	0,95	0,85
Elektriksel Hasarlı	0,97	0,99	0,99	0,98
Fiziksel Hasarlı	0,95	0,97	0,99	0,96
Karlı	0,97	1	0,99	0,98
Gölgelenmiş	0,68	0,91	0,95	0,78
Ortalama	0,94	0,91	0,95	0,9

Çizelge 4.6'da InceptionV3 modelinin her bir sınıf için Kesinlik, Geri Çağırma, Doğruluk değerleri gösterilmektedir. Bunun sonucunda Kesinlik değeri:0,94, Geri Çağırma değeri: 0,91, Doğruluk değeri:0,95 ve F1-skoru: 0,9 olarak hesaplanmıştır.


4.5.3 Resnet101 Modeli Sonuçları

Veri seti Resnet101 modeliyle 4 saat 18 dakikada eğitilmiştir. Veri setinin Resnet101 modeliyle eğitilmesi sonucu ortaya çıkan eğitim doğrulama kaybı grafiği Şekil 4.12’ de gösterilmektedir. Eğitim kaybının son değeri:1,6398 ve doğrulama kaybının son değeri:1,5708 olarak gözlenmiştir. Değerlerin 0’ a yakınsama konusunda başarısız olduğu görülmektedir. Model aşırı uyuma düşmemiş ancak modelin eğitimi de başarılı geçmemiştir. Model eğitim sırasında iyi bir şekilde öğrenemediği için test etme sırasında başarısız olmuştur.



Şekil 4.12 Resnet101 modelinin eğitim ve doğrulama kaybı grafiği


Resnet101 modelinin eğitim ve doğrulama başarıları grafiği Şekil 4.13’ te görülmektedir. Model test edilen verileri %39,68’ lik başarı oranıyla sınıflandırabilmektedir.



Şekil 4.13 Resnet101 modelinin eğitim ve doğrulama başarısı grafiği

Resnet101 modelinin karışıklık matrisi Şekil 4.14’ te gösterilmektedir. Şekilde görüldüğü üzere “kuş pisliği” sınıfında 83, “temiz” sınıfında 101, “tozlu” sınıfında 100, “elektriksel hasarlı” sınıfında 96, “fiziksel hasarlı” sınıfında 75, “karlı” sınıfında 100, “gölgelenmiş” sınıfında 85 ve toplamda 640 adet test verisi bulunmaktadır. Model test verisindeki 83 adet kuş pisliği etiketinden 20 adetini doğru sınıflandırmış, 40 adetini temiz, 11 adetini tozlu, 3 adetini elektriksel hasarlı, 7 adetini fiziksel hasarlı ve 2 adetini karlı olarak yanlış sınıflandırmıştır. Modelin kuş pisliği etiketini sınıflandırma başarısı %48,19’dur. Model test verisindeki 101 adet temiz etiketinden 72 adetini doğru sınıflandırmış, 6 adetini kuş pisliği, 11 adetini tozlu, 9 adetini elektriksel hasarlı, 1 adetini fiziksel hasarlı ve 2 adetini karlı olarak yanlış sınıflandırmıştır. Modelin temiz etiketini sınıflandırma başarısı %79,12’dir. Model test verisindeki 100 adet tozlu etiketinden 49 adetini doğru sınıflandırmış, 5 adetini kuş pisliği, 23 adetini temiz, 16 adetini elektriksel hasarlı, 4 adetini karlı ve 3 adetini gölgelenmiş olarak yanlış sınıflandırmıştır. Modelin tozlu etiketini sınıflandırma başarısı %49’dur. Model test verisindeki 96 adet elektriksel hasarlı etiketinden 56 adetini doğru sınıflandırmış, 3 adetini kuş pisliği, 16 adetini temiz, 13 adetini tozlu, 1 adetini fiziksel hasarlı, 4 adetini karlı ve 1 adetini gölgelenmiş olarak yanlış sınıflandırmıştır. Modelin elektriksel hasarlı etiketini sınıflandırma başarısı %60,42’ dir. Model test verisindeki 75 adet fiziksel hasarlı etiketinden 13 adetini doğru sınıflandırmış, 26 adetini kuş pisliği, 22 adetini temiz, 9 adetini tozlu, 1 adetini elektriksel hasarlı ve 4 adetini olarak yanlış sınıflandırmıştır. Modelin fiziksel hasarlı etiketini sınıflandırma başarısı %17,33 tür. Model test verisindeki 100 adet karlı etiketinden 40 adetini doğru sınıflandırmış, 1 adetini kuş pisliği, 24 adetini temiz, 31 adetini tozlu, 3 adetini elektriksel hasarlı ve 1 adetini

gölgelenmiş olarak yanlış sınıflandırmıştır. Modelin karlı etiketini sınıflandırma başarısı %40 dır. Model test verisindeki 85 adet gölgelenmiş etiketinden 2 adetini doğru sınıflandırmış, 8 adetini kuş pisliği, 25 adetini temiz, 18 adetini tozlu, 9 adetini elektriksel hasarlı, 1 adetini fiziksel hasarlı ve 22 adetini karlı olarak yanlış sınıflandırmıştır. Modelin gölgelenmiş etiketini sınıflandırma başarısı %2,35' tir.



Şekil 4.14 Resnet101 modelinin karışıklık matrisi


Çizelge 4.7 Resnet101 modelinin performansı

	Kesinlik	Geri Çağırma	Doğruluk	F1-skoru
Kuş Pisliği	0,24	0,29	0,83	0,26
Temiz	0,71	0,32	0,72	0,45
Tozlu	0,49	0,35	0,78	0,41
Elektriksel Hasarlı	0,6	0,59	0,88	0,59
Fiziksel Hasarlı	0,17	0,57	0,89	0,27
Karlı	0,4	0,51	0,85	0,45
Gölgelenmiş	0,02	0,29	0,86	0,04
Ortalama	0,38	0,4	0,82	0,41

Çizelge 4.7'de Resnet101 modelinin her bir sınıf için Kesinlik, Geri Çağırma, Doğruluk değerleri gösterilmektedir. Bunun sonucunda Kesinlik değeri:0,38, Geri Çağırma değeri: 0,4 Doğruluk değeri:0,82 ve F1-skoru: 0,41 olarak hesaplanmıştır.


4.5.3 Önerilen Modelin Sonuçları

Veri seti Önerilen modelle 1 saat 45 dakikada eğitilmiştir. Veri setinin Önerilen modelle eğitilmesi sonucu ortaya çıkan eğitim doğrulama kaybı grafiği Şekil 4.15’ te gösterilmektedir. Eğitim kaybının son değeri:0,0827 ve doğrulama kaybının son değeri:0,1034 olarak gözlenmiştir. Modelin eğitim ve doğrulama kaybının sıfıra yakınsadığı görülmektedir. Bu durum da modelin aşırı uyuma düşmediğini göstermektedir.



Şekil 4.15 Önerilen modelin eğitim ve doğrulama kaybı grafiği


Önerilen modelin eğitim ve doğrulama başarısı grafiği Şekil 4.16’ da görülmektedir. Grafik incelendiğinde modelin güneş panellerindeki kusurları sınıflandırmada başarılı olduğu gözlenmektedir. Model test edilen verileri %97,19’ luk başarı oranıyla sınıflandırabilmektedir.



Şekil 4.16 Önerilen modelin eğitim ve doğrulama başarıları grafiği

Önerilen modelinin karışıklık matrisi Şekil 4.17’ de gösterilmektedir. Şekilde görüldüğü üzere “kuş pisliği” sınıfında 83, “temiz” sınıfında 101, “tozlu” sınıfında 100, “elektriksel hasarlı” sınıfında 96, “fiziksel hasarlı” sınıfında 75, “karlı” sınıfında 100, “gölgelemiş” sınıfında 85 ve toplamda 640 adet test verisi bulunmaktadır. Model test verisindeki 83 adet kuş pisliği etiketinden 80 adetini doğru sınıflandırmış, 3 adetini fiziksel hasarlı olarak yanlış sınıflandırmıştır. Modelin kuş pisliği etiketini sınıflandırma başarıları %96,39’dur. Model test verisindeki 101 adet temiz etiketinden 100 adetini doğru sınıflandırmış, 1 adetini karlı olarak yanlış sınıflandırmıştır. Modelin temiz etiketini sınıflandırma başarıları %99,01’dir. Model test verisindeki 100 adet tozlu etiketinden 97 adetini doğru sınıflandırmış, 1 adetini elektriksel hasarlı ve 2 adetini gölgelemiş olarak yanlış sınıflandırmıştır. Modelin tozlu etiketini sınıflandırma başarıları %97’dir. Model test verisindeki 96 adet elektriksel hasarlı etiketinden 95 adetini doğru sınıflandırmış, 1 adetini tozlu olarak yanlış sınıflandırmıştır. Modelin elektriksel hasarlı etiketini sınıflandırma başarıları %98,96’ dır. Model test verisindeki 75 adet fiziksel hasarlı etiketinden 74 adetini doğru sınıflandırmış, 1 adetini kuş pisliği olarak yanlış sınıflandırmıştır. Modelin fiziksel hasarlı etiketini sınıflandırma başarıları %98,67’dir. Model test verisindeki 100 adet karlı etiketinden 96 adetini doğru sınıflandırmış, 1 adetini temiz, 2 adetini tozlu ve 1 adetini fiziksel hasarlı olarak yanlış sınıflandırmıştır. Modelin karlı etiketini sınıflandırma başarıları %96’ dır. Model test verisindeki 85 adet gölgelemiş etiketinden 80 adetini doğru sınıflandırmış, 1 adetini temiz, 2 adetini tozlu, 1 adetini fiziksel hasarlı ve 1

adetini karlı olarak yanlış sınıflandırmıştır. Modelin gölgelenmiş etiketini sınıflandırma başarısı %94,11’dir.



Şekil 4.17 Önerilen modelinin karışıklık matrisi

Çizelge 4.8 Önerilen modelinin performansı

	Kesinlik	Geri Çağırma	Doğruluk	F1-skoru
Kuş Pisliği	0,96	0,99	0,99	0,98
Temiz	0,99	0,98	0,99	0,99
Tozlu	0,97	0,95	0,99	0,96
Elektriksel Hasarlı	0,99	0,99	0,99	0,99
Fiziksel Hasarlı	0,99	0,94	0,99	0,96
Karlı	0,96	0,98	0,99	0,97
Gölgelenmiş	0,94	0,98	0,99	0,96
Ortalama	0,96	0,96	0,99	0,97

Çizelge 4.8’de Önerilen modelinin her bir sınıf için Kesinlik, Geri Çağırma, Doğruluk değerleri gösterilmektedir. Bunun sonucunda Kesinlik değeri:0,96, Geri Çağırma değeri: 0,96 Doğruluk değeri:0,99 ve F1-skoru: 0,97 olarak hesaplanmıştır.

Çizelge 4.9 Önerilen modelin diğer modellerle karşılaştırılması

Model	Başarı oranı	Eğitim Süresi
Önerilen Model	%97,19	1 saat 45 dakika
VGG-19	%94,53	8 saat 15 dakika
InceptionV3	%89,68	1 saat 30 dakika
Resnet101	%39,68	4 saat 18 dakika

Çizelge 4.9’ da önerilen modelin başarı oranı ve eğitim süresi diğer modellerle karşılaştırılmıştır. Çizelge 4.9 ‘da görüldüğü üzere en yüksek başarı oranına %97,19 ile önerilen modelle ulaşılmıştır. VGG-19 modeli veri setini %94,53 gibi başarılı bir oranla eğitmiştir ancak eğitim süresinin 8 saat 15 dakika olması zaman ve maliyet açısından kayba neden olacaktır. InceptionV3 modeli veri setini başarılı denebilecek bir oranla %89,68 doğrulukla sınıflandırabilmiştir. Eğitim süresi de diğer modellere göre daha iyidir ancak başarı oranı önerilen modelin altında kalmıştır. Resnet101 modeli veri setini %39,68 gibi başarısız bir oranla eğitmiştir ve eğitim süresi 4 saat 18 dakika gibi fazla bir süredir. Bu durum Resnet101’ in bu veri setinde kullanılmaması gerektiği anlamına gelmektedir. Bu modeller içerisinde en uygunu çizelge 4.9’ da görüldüğü üzere önerilen modeldir. Başarı oranının yüksek olması ve eğitim süresinin kısa olması bu modeli diğer modellerin önüne atmıştır.



BÖLÜM 5

SONUÇLAR

Yenilenemez enerji kaynaklarının tükenmesi ve çevreye verdikleri zarar, başta güneş enerjisi olmak üzere yenilenebilir enerji kaynaklarına olan ilginin artmasına neden olmuştur. Yenilebilir enerji kaynaklarının en yaygını, doğada en çok bulunan güneştir. Güneş panelleri, güneş enerjisini elektrik enerjisine çeviren sistemlerdir. Güneş panellerinin yaygınlığı günümüzde giderek artmaktadır. Güneş panelleri üzerindeki kar, toz, kuş pisliği, mekaniksel hasar, fiziksel hasar ve gölgelenme gibi etkenler enerji üretimindeki verimi azaltmaktadır. Güneş panellerinden iyi performans alabilmek için panel bakımı düzenli yapılmalıdır. Ancak panel bakımları maliyet ve zaman gerektirmektedir.

Günümüzde kullanımı yaygınlaşan derin öğrenme tabanlı modeller görüntülerdeki kusurları saptama ve sınıflandırma konusunda dikkat çekmektedir. Bu tez çalışmasında, güneş panellerindeki kusurların sınıflandırılması üzerine çalışılmıştır. Amaç, güneş panellerindeki “kar, toz, gölge, kuş pisliği, mekaniksel hasar, fiziksel hasar ve gölgelenme” gibi kusurların yüksek doğrulukta sınıflandırılarak olabildiğince hızlı şekilde uzmanlarca müdahale edilmesidir. Bu işlem önerilen derin öğrenme tabanlı modelle mümkün olacaktır. Çalışma 2 aşamadan oluşmaktadır. İlk aşama, ön işleme aşamasıdır ve bu aşamada veri seti yetersiz olması nedeniyle görüntüyü döndürme görüntünün simetriğini alma ve görüntüye gürültü ekleme gibi veri çoğaltma teknikleri kullanılarak arttırılmıştır. İkinci aşama olan eğitim aşamasında ise çoğaltılan veri seti önerilen derin öğrenme modeliyle eğitilmiştir.

Çalışmada kaggle’ da bulunan açık erişimli güneş paneli kusuru veri seti kullanılmıştır. Veri setinde çeşitliliğin sağlanabilmesi için yapay görüntüler oluşturularak toplamda 6098 görüntü elde edilmiştir. Bu görüntülerin 5458 tanesi eğitim ve 640 tanesi ise test için kullanılarak eğitilen modelin performans değerleri gözlenmiştir. Önerilen modelin Kesinlik, Geri çağırma, Doğruluk ve F1-Skoru ortalama değerleri sırasıyla 0,96, 0,96, 0,99, 0,97 olarak hesaplanmıştır.

Bu tez çalışmasında önerilen model, kullanımı en yaygın olan VGG-19, InceptionV3 ve Resnet101 gibi önceden eğitilmiş modellerle karşılaştırılmıştır. Önceden eğitilmiş modeller sırasıyla % 94,53, %89,68 ve %39,68 başarı oranıyla sınıflandırabilirken Önerilen modelin %97,19 başarı oranıyla kusurları sınıflandırdığı gözlenmiştir. Ayrıca önerilen modelin 1 saat 45 dakika gibi kısa bir sürede eğitimini tamamlayarak zaman ve maliyet açısından da diğer modellerden önde olduğu görülmektedir.

Önerilen modelle birlikte güneş enerjisi santralleri veya kişisel kullanımdaki güneş panelleri üzerindeki kusurlar otomatik olarak kısa sürede yüksek doğrulukla saptanabilecek ve böylece verimliliğin azaldığı sürelerde büyük düşüşler yaşanmayacaktır. Gelecek çalışmalarda, güneş panelleri kusurlarını sınıflandırmaya yönelik modeller daha fazla kusur ve veri içeren, görüntü kalitesinin iyi olduğu, aydınlatmanın modeli yanıltmadığı ve farklı iklim koşullarında çekilen görsellerin kullanıldığı veri setleriyle eğitilirse daha başarılı ve güvenilir sonuçlar elde edilebilir.

KAYNAKLAR

- [1] URL-1 < <https://www.mornsun-power.com/html/news-detail/blog-posts/213.html>>, Ziyaret tarihi: 29.06.2023.
- [2] Platon, R., Martel, J. T., Woodruff, N., & Chau, T. Y. (2015). Online fault detection in PV systems. *IEEE Transactions on Sustainable Energy*, 6(4), 1200–1207.
- [3] Li, B., Delpha, C., Diallo, D., & Migan-Dubois, A. (2021). Application of artificial neural networks to photovoltaic fault detection and diagnosis: A review. *Renewable and Sustainable Energy Reviews*, 138.
- [4] Tang, W., Yang, Q., Xiong, K., & Yan, W. (2020). Deep learning based automatic defect identification of photovoltaic module using electroluminescence images. *Solar Energy*, 201, 453–460.
- [5] Jordan, D., Kurtz, S., VanSant, K., & Newmiller, J. (2016). Compendium of photovoltaic degradation rates. *Progress in Photovoltaics*, 24(7), 978–989.
- [6] Korkmaz, D., & Açıkgöz, H. (2022). An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network. *Engineering Applications of Artificial Intelligence*, 113, 104959.
- [7] Espinosa, A. R., Bressan, M., & Giraldo, L. F. (2020). Failure signature classification in solar photovoltaic plants using RGB images and convolutional neural networks. *Renewable Energy*, 162, 249–256.
- [8] Kayci, B., Demir, B. E., & Demir, F. (2022). İHA tarafından elde edilen termal görüntüler kullanılarak fotovoltaik sistemde derin öğrenme tabanlı arıza tespiti ve teşhisi. *Politeknik Dergisi*, 1, 1.
- [9] Pierdicca, R., Malinverni, E. S., Piccinini, F., Paolanti, M., Felicetti, A., & Zingaretti, P. (2018). Deep convolutional neural network for automatic detection of damaged photovoltaic cells. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII–2, 893–900.

KAYNAKLAR (devam ediyor)

- [10] Li, X., Yang, Q., Lou, Z., & Yan, W. (2019). Deep learning based module defect analysis for large-scale photovoltaic farms. *IEEE Transactions on Energy Conversion*, 34(1), 520–529.
- [11] Wei, S., Li, X., Ding, S., Yang, Q., & Yan, W. (2019). Hotspots infrared detection of photovoltaic modules based on hough line transformation and faster-rcnn approach. *In Proceedings of the 2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)* (pp. 1266-1271). IEEE.
- [12] Herráiz, Á. H., Marugán, A. P., & Márquez, F. P. G. (2020). Photovoltaic plant condition monitoring using thermal images analysis by convolutional neural network-based structure. *Renewable Energy*, 153, 334–348.
- [13] Venkatesh, S., & Sugumaran, V. (2021). Fault detection in aerial images of photovoltaic modules based on deep learning. *IOP Conference Series*, 1012(1), 012030.
- [14] Xie, X., Wei, X., Wang, X., Guo, X., Ju, L., & Cheng, Z. (2020). Photovoltaic panel anomaly detection system based on unmanned aerial vehicle platform. *IOP Conference Series*, 768(7), 072061.
- [15] Díaz, J. J. V., Vlamincx, M., Lefkaditis, D., Vargas, S. A. O., & Luong, H. (2020). Solar panel detection within complex backgrounds using thermal images acquired by UAVs. *Sensors*, 20(21), 6219.
- [16] Akram, M. W., Li, G., Jin, Y., Xiao, C., Zhu, C., & Ahmad, A. (2020). Automatic detection of photovoltaic module defects in infrared images with isolated and develop-model transfer deep learning. *Solar Energy*, 198, 175–186.
- [17] Kurukuru, V. S. B., Haque, A., Khan, M. A., & Tripathy, A. K. (2019). Fault classification for photovoltaic modules using thermography and machine learning techniques. *In Proceedings of the 2019 International Conference on Computer and Information Sciences (ICCIS)* (pp. 1-6). IEEE.
- [18] Zaki, S. A., Zhu, H., Fakihi, M. A., Sayed, A. R., & Yao, J. (2021). Deep learning-based method for faults classification of PV system. *IET Renewable Power Generation*, 15(1), 193–205.

KAYNAKLAR (devam ediyor)

- [19] 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.
- [20] Tang, W., Yang, Q., Xiong, K., & Yan, W. (2020b). Deep learning based automatic defect identification of photovoltaic module using electroluminescence images. *Solar Energy*, 201, 453–460.
- [21] Koçak, B., Fernandez, A. I., & Paksoy, H. (2020). Review on sensible thermal energy storage for industrial solar applications and sustainability aspects. *Solar Energy*, 209, 135–169.
- [22] Fernandez-Gonzalez, D., Ruiz-Bustinza, I., Gonzalez-Gasca, C., Pinuela Noval, J., Mochon-Castanos, J., Sancho-Gorostiaga, J., et al. (2018). Concentrated solar energy applications in materials science and metallurgy. *Solar Energy*, 170, 520–540.
- [23] Rashidi, S., Hossein Kashefi, M., & Hormozi, F. (2018). Potential applications of inserts in solar thermal energy systems - *A review to identify the gaps and frontier challenges*. *Solar Energy*, 171, 929–952.
- [24] Kumar, R., Nadda, R., Kumar, S., Kumar, K., Afzal, A., & Razak, K. A. et al. (2021). Heat transfer and friction factor correlations for an impinging air jets solar thermal collector with arc ribs on an absorber plate. *Sustainable Energy Technologies and Assessments*, 47, 101523.
- [25] Krishnan, N., et al. (2023). How solar radiation forecasting impacts the utilization of solar energy: *A critical review*. *Journal of Cleaner Production*.
- [26] Bahtiyar, B. (2006). Fotovoltaik Sistemler İçin Gerçek Zamanlı Bir İzleme Merkezi Tasarım ve Uygulaması. Yayımlanmamış Yüksek Lisans Tezi, Muğla Üniversitesi, Fen Bilimleri Enstitüsü, Muğla.
- [27] URL-2 < <http://www.vertaenerji.com/gunes-enerjisi-depolama-ve-gunes-pilleri/>>, Ziyaret tarihi: 05.07.2023.

KAYNAKLAR (devam ediyor)

- [28] URL-3 <<https://www.aydinlatma.org/gunes-paneli-nasil-calisir.html>>, Ziyaret tarihi: 09.07.2023.
- [29] Afrouzi, H. N., Mashak, S. V., Abdul-Malek, Z., Mehrazamir, K., & Salimi, B. (2013). Solar array and battery sizing for a photovoltaic building in Malaysia. *Jurnal Teknologi*.
- [30] Lincot, D. (2017). The new paradigm of photovoltaics: from powering satellites to powering humanity. *Comptes Rendus Physique*, 18, 381–390.
- [31] Fuyuki, T., & Kitiyanan, A. (2009). Photographic diagnosis of crystalline silicon solar cells utilizing electroluminescence. *Applied Physics A*, 189–196.
- [32] URL-4 <<https://www.solarsanalmarket.com/blog/icerik/monokristal-ve-polikristal-gunes-panellerinin-arasindaki-farklar>>, Ziyaret tarihi: 15.07.2023.
- [33] Druffel, T., Dharmadasa, R., Lavery, B. W., & Ankireddy, K. (2018). Intense pulsed light processing for photovoltaic manufacturing. *Solar Energy Materials and Solar Cells*, 174, 359–369.
- [34] Sumitomo, T., Huang, H., & Zhou, L. (2011). Deformation and material removal in a nanoscale multi-layer thin film solar panel using nanoscratch. *International Journal of Machine Tools & Manufacture*, 51(3), 182–189.
- [35] URL-5 <<https://www.hidenanalytical.com/blog/exploring-spectrometers-thin-film-applications/>>, Ziyaret tarihi: 23.07.2023.
- [36] Karafil, A. (2021). Kısmi gölgelenme durumundaki seri bağlı fotovoltaik (FV) panellerde bypass diyotunun kullanılmasının sistem gücü üzerine etkisi. *Fen-Mühendislik Dergisi*, 23(68), 621–630.
- [37] URL-6 <<https://www.kaggle.com/datasets/pythonsfroz/solar-panel-clean-and-faulty-images>>, Ziyaret tarihi: 18.05.2023.
- [38] Lu, H., Cai, R., Zhang, L., Lü, L., & Zhang, L. (2020). Experimental investigation on deposition reduction of different types of dust on solar PV cells by self-cleaning coatings. *Solar Energy*, 206, 365–373.

KAYNAKLAR (devam ediyor)

- [39] Chanchangi, Y. N., Ghosh, A., & Sundaram, S. (2020). Dust and PV performance in Nigeria: A review. *Renewable & Sustainable Energy Reviews*, 121, 109704.
- [40] LeCun, Y., Bengio, Y., & Hinton, G. E. (2015b). Deep learning. *Nature*, 521(7553), 436–444.
- [41] Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, 1-6.
- [42] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- [43] İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- [44] O’Shea, K., & Nash, R. R. (2015). An introduction to convolutional neural networks. *arXiv* (Cornell University).
- [45] URL-7 < <https://www.hidenanalytical.com/blog/exploring-spectrometers-thin-film-https://miuul.com/not-defteri/evrisimli-sinir-aglarina-giris> >, Ziyaret tarihi: 24.08.2023.
- [46] Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *In Proceedings of the International Conference on Artificial Neural Networks, Thessaloniki, Greece*, 15–18 September 2010 (pp. 92-101). Springer: Berlin/Heidelberg, Germany.
- [47] Dumoulin, V., & Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv* (Cornell University).
- [48] Srivastava, N., Hinton, G. E., 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.

KAYNAKLAR (devam ediyor)

- [49] Kandel, I., & Castelli, M. (2020). The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset. *ICT Express*, 6(4), 312–315.
- [50] Mallat, S. (2016). Understanding deep convolutional networks. *Philosophical Transactions of the Royal Society A*, 374(2065), 20150203.
- [51] Haji, S. H., & Abdulazeez, A. M. (2021). Comparison of optimization techniques based on gradient descent algorithm: A review. *PalArch's Journal of Archaeology of Egypt/Egyptology*, 18(4), 2715-2743.
- [52] Hardt, M., Recht, B., & Singer, Y. (2016, June). Train faster, generalize better: Stability of stochastic gradient descent. In *International Conference on Machine Learning* (pp. 1225-1234). PMLR.
- [53] Dogo, E. M., Afolabi, O. J., Nwulu, N. I., Twala, B., & Aigbavboa, C. O. (2018, December). A comparative analysis of gradient descent-based optimization algorithms on convolutional neural networks. In *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)* (pp. 92-99). IEEE.
- [54] Kaoudi, Z., Quiané-Ruiz, J. A., Thirumuruganathan, S., Chawla, S., & Agrawal, D. (2017, May). A cost-based optimizer for gradient descent optimization. In *Proceedings of the 2017 ACM International Conference on Management of Data* (pp. 977-992).
- [55] Hallén, R. (2017). A study of gradient-based algorithms.
- [56] URL-10 < <https://builtin.com/data-science/gradient-descent> >, Ziyaret tarihi: 17.03.2024.
- [57] Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv*
- [58] Qu, Z., Yuan, S., Chi, R., Chang, L., & Zhao, L. (2019). Genetic optimization method of pantograph and catenary comprehensive monitor status prediction model based on AdADelta deep neural network. *IEEE Access*, 7, 23210–23221.
- [59] Mukkamala, M. C., & Hein, M. (2017). Variants of RMSProp and Adagrad with logarithmic regret bounds. *arXiv* (Cornell University).

KAYNAKLAR (devam ediyor)

- [60] **Zhang, Z.** (2018). Improved Adam optimizer for deep neural networks. *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*.
- [61] **Yi, D., Ahn, J., & Ji, S.** (2020). An effective optimization method for machine learning based on ADAM. *Applied Sciences*, 10(3), 1073.
- [62] **Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q.** (2021). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43–76.
- [63] **Wen, L., Li, X., Li, X., & Gao, L.** (2019). A new transfer learning based on VGG-19 network for fault diagnosis. *2019 IEEE 23rd International Conference on Computer Supported Cooperative Work in Design (CSCWD)*.
- [64] **Chen, J., Zhou, M., Zhang, D., Huang, H., & Zhang, F.** (2021). Quantification of water inflow in rock tunnel faces via convolutional neural network approach. *Automation in Construction*, 123, 103526.
- [65] **URL-11** < <https://deepai.org/machine-learning-glossary-and-terms/inception-module>>, Ziyaret tarihi: 24.03.2024.
- [66] **Chollet, F.** (2016). Xception: Deep learning with depthwise separable convolutions. *arXiv* (Cornell University).
- [67] **Zhu, Y., & Newsam, S.** (2017). DenseNet for dense flow. *2017 IEEE International Conference on Image Processing (ICIP)*.
- [68] **Chan, R., Chung-Wa, N., & Nikolova, M.** (2005). Salt-and-pepper noise removal by median-type noise detectors and detail-preserving regularization. *IEEE Transactions on Image Processing*, 14(10), 1479–1485.
- [69] **Lermi, S. Y., & Onur, T. Ö.** (2024). Güneş paneli kusurlarının derin öğrenme tabanlı sınıflandırılması. *International Journal of Advances in Engineering and Pure Sciences*, 36(2), 140-149.

KAYNAKLAR (devam ediyor)

- [70] Javaid, A., Niyaz, Q., Sun, W., & Alam, M. (2016). A deep learning approach for network intrusion detection system. *Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering*.



ÖZGEÇMİŞ

Sebahattin Yiğit LERMİ, 2022 yılında Zonguldak Bülent Ecevit Üniversitesi Elektrik ve Elektronik Mühendisliği bölümünden mezun oldu. 2022 yılında Zonguldak Bülent Ecevit Üniversitesi Fen Bilimler Enstitüsü Elektrik ve Elektronik Mühendisliği bölümünde tezli yüksek lisans eğitime başladı ve hala eğitime devam etmektedir. Araştırma ilgi alanları arasında görüntü işleme teknikleri, yapay sinir ağı yapıları ve evrişimli sinir ağıları bulunmaktadır.