

# Güneş Paneli Kusurlarının Derin Öğrenme Tabanlı Sınıflandırılması

## Classification of Solar Panels Defects Based on Deep Learning

Sebahattin Yiğit LERMİ<sup>1</sup>, Tuğba Özge ONUR<sup>1</sup>

<sup>1</sup>Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü,  
Zonguldak, Türkiye

### Öz

Yenilenebilir 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. Fotovoltaik paneller üzerindeki kar, toz, gölge, kuş pisliği, mekaniksel ve fiziksel arıza 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 seti yetersiz olması nedeniyle veri çoğaltma teknikleri kullanılarak arttırılmıştır. İkinci aşama olan eğitim aşamasında ise çoğaltılan veri seti önerilen derin öğrenme modeliyle eğitilmiştir. Eğitim sonucunda önerilen modelin 7 farklı kusurun sınıflandırılmasında %96.56 başarı elde ettiği gözlemlenmiştir.

**Anahtar Kelimeler:** Derin öğrenme, Güneş panelleri, Fotovoltaik, Veri çoğaltma, Sınıflandırma

### Abstract

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 well known energy alternatives for clean and sustainable energy production. Factors such as snow, dust, shadow, bird droppings, mechanical and physical failure on photovoltaic panels reduce the efficiency in energy production, and therefore panel maintenance should be done regularly. When maintenance is performed 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, a damage detection classification was carried out on solar panels using the deep learning technique. Our study consists of two stages. The first stage is the pre-processing stage. At this stage, the data set is increased using data augmentation techniques due to insufficient data set. In the second stage, the training stage, the replicated data set was trained with the proposed deep learning model. As a result of the training, it was observed that the proposed model achieved %96.56 success in classifying 7 different defects.

**Keywords:** Deep learning, Solar panels, Photovoltaics, Data augmentation, Classification

## I. GİRİŞ

Yenilenebilir 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 MW'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 olabileceği gibi zaman ve maliyet açısından da kayıplara yol açmaktadır. Bu sorunların giderilebilmesi için günümüzde kullanımı giderek artan derin öğrenme ve görüntü işleme teknolojileri önerilmektedir.

### 1.1. İlgili Çalışmalar

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 fotovoltaik 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 büyüme ve aşırı örnekleme tekniği kullanarak ağ performansını arttırmışlardır. Çalışmalarında 11 farklı fotovoltaik panel kusuru (çatlama, sıcak nokta gibi) kullanarak 11 anormali türünü sınıflandırmada %93,51 doğruluk elde etmişlerdir. Elde edilen sonuçların fotovoltaik 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 evrişimli sinir ağlarını 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, termal kamera yerleştirilmiş dronla elde edilen güneş paneli termal görüntülerini 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 eğitilmiştir. Eğitim sonucunda hücre arızaları %98, modül arızaları %89 ve panel arızaları %77 başarıyla saptanmıştır [8].

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

Li ve arkadaşları tarafından yapılan çalışmada, büyük boyutlu fotovoltaik panel 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 VGG16 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].

Herraz ve arkadaşları çalışmalarında, güneş panellerindeki kusurları bulmak için insansız hava aracına monte edilen termografik kameradan yararlanılan yeni bir teknik önermişlerdir. Yapılan çalışmada sıcak noktaların tespit edilmesinde ve yeniden konumlandırılmasında kullanılacak panellerin yerinin tespit edilmesi amacıyla yeni bir yöntem sunulmuştur. İki yeni bölge tabanlı evrişimli sinir ağına 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 insansız hava araçlarından (İHA) elde edilen hava görüntülerinin yardımıyla derin öğrenmeye dayalı fotovoltaik 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 fotovoltaik kızılötesi hedef anomali tespit sistemi önermektedir. FV panel kusurlarının İHA tarafından tespitinin doğruluğunu arttırmak için Sobel ve Canny operatörlerini birleştirmişlerdir. Yatay ve dikey özellikleri çıkarmak için Sobel operatörü, dikey ve yatay kenar özelliklerini hesaplamak ve doldurmak için Canny operatörü kullanılmıştır. 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 fotovoltaik panelleri 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 kontrastı 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 fotovoltaik modül kusurlarının otomatik olarak tespit edilmesi üzerine çalışmışlardır. Veri setleri normal çalışan ve arızalı modüllerin kızılötesi görüntülerini içermektedir. Başlangıçta transfer öğrenimi için fotovoltaik 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 versiyonunu kullanarak incelemişlerdir. Kusur sınıflandırıcısını oluşturmak için, alınan özellikler bir yapay sinir ağı (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 MATLAB simülasyon modeline yardımcı olacağını düşünmüşlerdir. İkinci olarak, derin öğrenme kullanılarak FV sistemlerdeki hataların sınıflandırılmasına yönelik yeni bir yaklaşım önermişlerdir. 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 süreçleri için simülasyon testlerinde sırasıyla %98,3 ve %98,9, deneysel testlerde ise %96,76 ve %97,41 civarında ortalama sınıflandırma doğruluğu elde etmiştir [18].

Deitsch ve arkadaşları, EL görüntülerinde arızalı fotovoltaik modül hücrelerinin otomatik sınıflandırılması adlı çalışmalarında FV hücrelerdeki sorunları tespit edebilmek amacıyla 2 farklı yaklaşım ortaya sunmuşlardır. Yaklaşımlar, donanım gereksinimleri nedeniyle farklılık göstermektedir. Donanım açısından verimli olan, Destek Vektör Makinesi (DVM) kullanılarak sınıflandırılmaya dayanmaktadır. Daha fazla donanım gerektiren yöntem

ise ESA'yı kullanmaktadır. Her iki yaklaşım da 1968 farklı hücre üzerinde eğitilmiştir. ESA başarı oranı %88,42 ve DVM başarı oranı %82,44'tür [19].

Tang ve arkadaşları EL görüntüleri kullanılarak fotovoltaik modülün derin öğrenme tabanlı otomatik kusur tespiti isimli çalışmalarında 2 farklı adımla EL görüntülerini derin öğrenmeye dayalı kusur tespitini sunmuşlardır. Önerilen çalışmada ilk adım kısıtlı sayıdaki EL görüntüyü yüksek kalitede arttırmak, ikinci adım ise 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 özelliklerin çıkarılmasında, ESA kullanılmaktadır. Önerilen model diğer çözümlerle karşılaştırıldığında, FV modülü denetiminin doğruluğunu ve verimliliğini önemli ölçüde artırabilir. Önerilen model %83'lük başarı oranına sahiptir [20].

Sunulan literatür taramasından görüldüğü üzere, güneş panellerindeki hasarların tespiti için son dönemde birçok çalışma yapılmıştır. Ancak yapılan çalışmalarda yaklaşımların hiçbiri çok sınıflı hasarları kısa bir sürede yüksek doğrulukta sınıflandıramamaktadır. Güneş panelleri üzerindeki hasarların erken tespit ve müdahale edilebilmesi, veriminin artması için oldukça önemlidir. Bu çalışmada, güneş panelleri üzerindeki hasarların hızlı ve otomatik bir şekilde tespit edilebilmesi için görüntü işleme ve derin öğrenme tabanlı arıza tespit yöntemi önerilmiştir. Önerilen yöntem, ön işleme ve ESA tabanlı oluşturulan derin öğrenme mimarisine sınıflandırma aşamaları olmak üzere 2 aşamadan oluşmaktadır. Bu çalışma kapsamında farklı iklim şartlarında elde edilen görüntüler, model performansının iyileştirilmesi ve veri setinin yetersiz olması nedeniyle veri çoğullama teknikleri ile (yakınlaştırma, simetrisini alma, görüntüyü belirli açılarla döndürme, gürültü ekleme ve parlaklık değiştirme) artırılmıştır. Önerilen yöntem 7 farklı panel kusurunu yüksek doğrulukta sınıflandırabilmektedir.

## II. MATERYAL VE METOD

### 2.1. Veri Seti

Bu çalışma kapsamında kullanılan veri seti, açık erişimli Kaggle [21] web sitesinden elde edilmiştir.

### 2.2. Ön İşleme

Veri setinde Tablo 1'de görüldüğü üzere toplam 988 adet farklı görüntü vardır. Her görüntü 0-6 arası sınıflandırılmıştır. Kuş Pislği olan paneller 1, Temiz olan paneller 2, Tozlu olan paneller 3, Elektriksel Hasarlı paneller 4, Fiziksel Hasarlı paneller 5, Gölgelemiş paneller 6, Karlı paneller 7 olarak sınıflandırılmıştır.

**Tablo 1** Orijinal veri seti

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

**Tablo 2** Çoğaltılmış veri seti

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

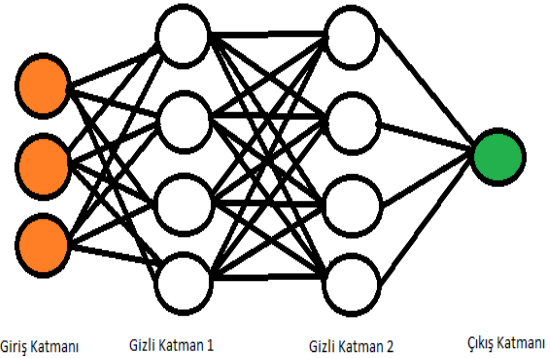
Tablo 1’de görüldüğü üzere veri setinde, 200 adet kuş pisiği, 202 adet temiz, 220 adet tozlu, 98 adet elektriksel hasarlı 66 adet fiziksel hasarlı, 122 adet karlı ve 80 adet gölgelenmiş panel görüntüsü vardır. Bu çalışmada kullanılan veri setindeki panel görüntüsü örnekleri Şekil 1’de gösterilmiştir.

**Şekil 1.** Veri setinde bulunan örnek panel görüntüleri

Tablo 1’de görüldüğü üzere veri seti, görüntü sayısı açısından yetersizdir 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 Tablo 2’de gösterilmiştir.

### 2.3. Derin Öğrenme

Derin öğrenme, temeli yapay sinir katmanlarından oluşan bir ağıdır. Çoklu nöron bağlantıları birleşerek katmanları oluşturur. Derin sinir ağı, katmanların üst üste istiflenmesiyle oluşturulan yapay sinir ağlarının diğer adıdır. Burada oluşan ağı derinliği katman sayısının az veya çok olmasıyla belirlenir. Katman sayısı arttıkça ağ yapısı derinleşmektedir. Benzer şekilde katman sayısının azalması, ağ yapısının ya derin olmadığını ya da derinleştiğini gösterir [22]. Şekil 2’de örnek bir derin öğrenme modeli verilmiştir.


**Şekil 2.** Derin öğrenme adımları

ESA; giriş, evrişim, havuzlama, düzleştirme, aktivasyon, seyreltme, tam bağlantı ve sınıflandırma katmanları olmak üzere sekiz katmandan oluşmaktadır.

Giriş katmanı, adından da anlaşılacağı gibi ESA'nın en üst katmanıdır. Performans ve maliyet açısından doğru giriş görsel boyutunun kullanılması gerekir. Görsel boyutunun artması başarı oranını arttıracak gibi işlem sayısını da artırır, bu durum da performansı olumsuz etkiler. Aynı şekilde görsel boyutunun küçülmesi başarı oranını azaltacağı gibi işlem sayısını da azaltır, bu durum da performansı olumlu etkileyebilmektedir.

Evrişim katmanı ESA'ların temel yapı taşıdır [23]. Bu katman, dönüşüm katmanı olarak da bilinir ve bu dönüşüm filtrenin bütün görüntü üzerinde dolaştırılmasıdır [24]. Filtreler 2x2, 3x3, 5x5 gibi farklı

boyutlarda olabilir. Filtreler, önceki katmandaki görüntüler üzerinde evrişim işlemi kullanarak çıktı verilerini üretir. Bu işlem sonucu Özellik Haritası oluşur.

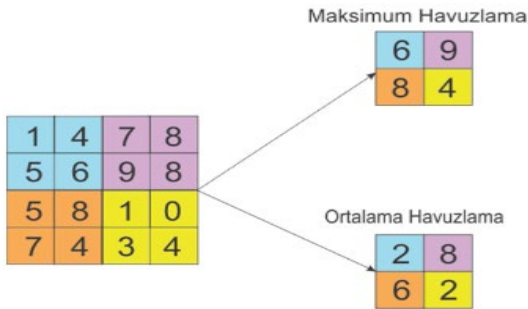


Şekil 3. Konvolüsyon işlemi uygulanma örneği

Evrişim katmanında üretilen her özellik haritası, bir ESA'ya doğrusal olmama özelliği sağlamak amacıyla aktivasyon fonksiyonu kullanır. ReLU (Rectified Linear Unit) en popülerleridir [24].

Bir ESA tasarımında, havuzlama katmanı evrişim katmanları arasında 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 havuzlama diğer havuzlama yöntemleriyle karşılaştırıldığında, daha yüksek performans ve daha hızlı yakınsama gösterdiği görülmüştür [25].



Şekil 4 Maksimum ve ortalama havuzlama örneği

Düzleştirme katmanı, 2 veya 3 boyutlu gibi çok boyutlu formattaki verileri tek boyutlu bir vektöre dönüştürür. Tamamen bağlı katmanlar, bir ESA'da girişin bir boyutlu bir vektör olmasını beklediklerinden, bu yeniden şekillendirme işlemi, evrişim ve havuzlama katmanlarından tamamen bağlı katmanlara geçişte gereklidir.

Bir ESA tasarımında, tam bağlantılı katman genellikle en sonda bulunur [22]. Tam bağlantılı katmanda nöronlar, geleneksel sinir ağlarındakine benzer şekilde gruplandırılır. Önceki evrişimli veya havuzlama katmanının çıktısından elde edilen düzleştirilmiş bir vektör, girdi olarak kullanılır.

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, denetlenmemiş verilere genelleme yapmakta zorlandığında, modelin aşırı uyumlu olduğu anlaşılır. Seyreltme, bu soruna basit ama etkili bir çözümdür. Tamamen bağlantılı katmanın ardından bu katman gelir. Derin öğrenme mimarisinin bu katmanında sınıflandırma gerçekleşir. Bu katmanın çıkış değeri sınıflandırılacak nesne sayısı kadardır. Farklı sınıflandırıcılar olsa da başarısından dolayı genellikle softmax kullanılır [24].

### III. SONUÇLAR VE TARTIŞMA

Bu çalışmada, güneş paneli kusurlarını yüksek doğrulukta sınıflandırabilmek için model yapısında ve parametrelerinde düzenlemeler yapılarak en iyi sonuca ulaşılmaya çalışılmıştır. Deneylerde 2 farklı model yapısı kullanılmıştır. Model özetleri Şekil 5 ve Şekil 6' da verilmiştir.

sequential (Sequential)	(32, 256, 256, 3)	0
conv2d (Conv2D)	(32, 254, 254, 32)	896
max_pooling2d (MaxPooling2D)	(32, 127, 127, 32)	0
conv2d_1 (Conv2D)	(32, 125, 125, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(32, 62, 62, 64)	0
conv2d_2 (Conv2D)	(32, 60, 60, 64)	36928
max_pooling2d_2 (MaxPooling2D)	(32, 30, 30, 64)	0
conv2d_3 (Conv2D)	(32, 28, 28, 64)	36928
max_pooling2d_3 (MaxPooling2D)	(32, 14, 14, 64)	0
conv2d_4 (Conv2D)	(32, 12, 12, 64)	36928
max_pooling2d_4 (MaxPooling2D)	(32, 6, 6, 64)	0
conv2d_5 (Conv2D)	(32, 4, 4, 64)	36928
max_pooling2d_5 (MaxPooling2D)	(32, 2, 2, 64)	0
flatten (Flatten)	(32, 256)	0
dense (Dense)	(32, 64)	16448
dropout (Dropout)	(32, 64)	0
dense_1 (Dense)	(32, 7)	455

Şekil 5. Denenen ilk model yapısı

sequential (Sequential)	(32, 256, 256, 3)	0
conv2d (Conv2D)	(32, 254, 254, 32)	896
max_pooling2d (MaxPooling2D)	(32, 127, 127, 32)	0
conv2d_1 (Conv2D)	(32, 125, 125, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(32, 62, 62, 64)	0
conv2d_2 (Conv2D)	(32, 60, 60, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(32, 30, 30, 128)	0
conv2d_3 (Conv2D)	(32, 28, 28, 128)	147584
max_pooling2d_3 (MaxPooling2D)	(32, 14, 14, 128)	0
conv2d_4 (Conv2D)	(32, 12, 12, 128)	147584
max_pooling2d_4 (MaxPooling2D)	(32, 6, 6, 128)	0
conv2d_5 (Conv2D)	(32, 4, 4, 256)	295168
max_pooling2d_5 (MaxPooling2D)	(32, 2, 2, 256)	0
flatten (Flatten)	(32, 1024)	0
dense (Dense)	(32, 64)	65600
dropout (Dropout)	(32, 64)	0
dense_1 (Dense)	(32, 7)	455

Şekil 6. Denenen ikinci model yapısı

Şekil 5' te görüldüğü üzere, ilk modelde 6 konvolüsyon katmanı bulunmaktadır. Bu katmanlardaki filtre sayıları sırasıyla 32, 64, 64, 64, 64, 64'tür. Şekil 6' da görülen ikinci modelde de 6 konvolüsyon katmanı bulunmaktadır ve katmanlardaki filtre sayıları sırasıyla 32, 64, 128, 128, 128, 256' dir. Tablo 3' te parametre değişikliklerinin başarı oranı ve eğitim süresine etkisi görülmektedir.

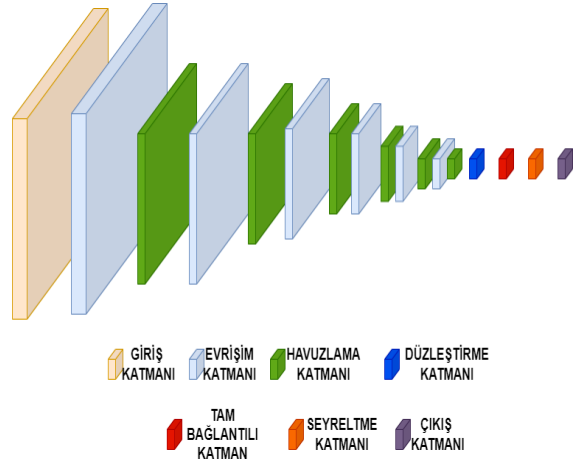
Tablo 3. Parametre değişimlerini ve sonuçları

Parametre	Model 1	Model 2	Model 3	Model 4
Epok sayısı	50	50	50	50
Kümeleme sayısı	32	32	32	16
Seyreltme miktarı	0.5	0.5	Yok	Yok
Model yapısı	1.yapı	2.yapı	1.yapı	1.yapı
Başarı oranı	96.56	95.94	95.78	91.03
Eğitim süresi	57 dakika	63 dakika	56 dakika	51 dakika

Tablo 3' te denenen modeller 10'ar kez çalıştırılıp ortalamaları alınmıştır. Bunun sonucunda görüldüğü gibi denenen 4 farklı model arasından başarı oranı ve eğitim süresi gibi faktörler göz önüne alınarak Model 1 seçilmiştir.

Tablo 3' te denenen modeller 10'ar kez çalıştırılıp ortalamaları alınmıştır. Bunun sonucunda görüldüğü gibi denenen 4 farklı model arasından başarı oranı ve

eğitim süresi gibi faktörler göz önüne alınarak Model 1 seçilmiştir.




Şekil 7. Önerilen evrişimli sinir ağı modeli

Önerilen mimarinin eğitimi sırasında en hızlı ve en iyi yakınsama yaptığından dolayı Adam optimizasyonu kullanılarak epok başına ağırlıklar sürekli olarak güncellenmiştir. Önerilen modelde kullanılan parametreler Tablo 4'te verilmiştir.


Tablo 4. Önerilen model parametreleri

Epok sayısı	50
Kümeleme(batch)	32
Öğrenme oranı	10 <sup>-5</sup>
Görsel boyutları	256x256
Evrişim	
Aktivasyon fonksiyonu	ReLU
Sınıflandırma	
Aktivasyon fonksiyonu	Softmax
Kayıp fonksiyonu	Losses.SparseCategorical Crossentropy
Seyreltme katsayısı	0.5

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. Eğitim sonucu epok başına hata grafiği Şekil 8' de görülmektedir. Şekil 8'den de görüldüğü üzere eğitim ve doğrulama kayıpları 0'a yakınsamakta ve bu da modelin aşırı uyuma düşmediğini göstermektedir. Önerilen modelin eğitim süresi epok başına 68 saniyedir. Eğitim toplamda 57 dakikada tamamlanmıştır.



Şekil 8. Eğitim ve doğrulama kaybı grafiği



Şekil 9. Eğitim ve doğrulama başarıları grafiği

Önerilen modelin eğitim ve doğrulama başarıları Şekil 9'da gösterilmiştir. Şekil 9'dan da görüldüğü üzere önerilen model, veri setini %96,56 gibi yüksek bir doğrulukta eğitmiştir.

### 3.1. Performans Metrikleri

Önerilen model tarafından yapılan tahminlerin veri kümesindeki gerçek sınıf etiketleriyle ne kadar iyi eşleştiğinin belirlenmesi amacıyla geri çağırma, kesinlik ve f1-skoru performans metrikleri kullanılmıştır.

**Kesinlik:** Tüm gerçek olumsuz örnekler arasında yanlış pozitif tahminlerin oranıdır.

$$\frac{TP}{(TP + FP)} \quad (1)$$

**Geri Çağırma:** Tüm gerçek olumlu örnekler arasında gerçek olumlu tahminlerin oranıdır.

$$\frac{TP}{(TP + FN)} \quad (2)$$

**F1-Skoru:** İki ölçüm arasında denge sağlayan hassaslık ve hatırlamanın harmonik ortalamasıdır.

$$\frac{2 * \text{Geri Çağırma} * \text{Kesinlik}}{(\text{Kesinlik} + \text{Geri Çağırma})} \quad (3)$$

Eşitlik (1), (2) ve (3) '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.

Buna göre sırasıyla eşitlik (1), (2) ve (3) ile hesaplanan performans metrik değerleri Tablo 5'te verilmiştir.

Tablo 5. Performans metrikleri

	Kesinlik	Geri Çağırma	F1 Skoru
Kuş Pislği	0.95	0.96	0.96
Temiz	0.98	0.94	0.96
Tozlu	0.97	0.94	0.95
Elektriksel-Hasarlı	0.96	0.99	0.97
Fiziksel-Hasarlı	0.97	0.97	0.97
Karlı	1	0.97	0.98
Gölgelenmiş	0.92	0.97	0.95
Ortalama	0.97	0.97	0.97

Tablo 5'te görüldüğü üzere ortalama kesinlik değeri 0.97, geri çağırma değeri 0.97 ve f1-skoru 0.97 olarak hesaplanmıştır.

Gerçek	0-Kuş Pislği	79	1	0	0	3	0	0
	1-Temiz	1	97	0	0	1	0	2
	2-Tozlu	7	1	87	3	0	0	2
	3-Elektriksel-Hasarlı	0	1	0	95	0	0	0
	4-Fiziksel-Hasarlı	2	0	0	0	73	0	0
	5-Karlı	3	1	0	0	0	94	2
	6-Gölgelenmiş	0	1	0	1	0	0	83
	Tahmin	0-Kuş Pislği	1-Temiz	2-Tozlu	3-Elektriksel-Hasarlı	4-Fiziksel-Hasarlı	5-Karlı	6-Gölgelenmiş

Şekil 10. Eğitim sonucu oluşan karışıklık matrisi

Şekil 10' da modelin karışıklık matrisi görülmektedir. Bu matris eğitimin doğruluğunun görülebilmesi açısından önemlidir. Örneğin, model 100 adet tozlu panel görüntüsünün 87'sini doğru tahmin etmiştir. 1 adet görüntü tozlu olmasına rağmen temiz olarak, 7 tanesi kuş pislği olarak, 3 adet görüntü elektriksel hasarlı olarak, 2 adet görüntü ise gölgelenmiş olarak tahmin edilmiştir.

Tablo 6' da önerilen modelin yapılan çalışmalarla karşılaştırılması gösterilmiştir. Önerilen model, çok sınıflı hasarları kısa bir sürede yüksek doğrulukta sınıflandırma konusunda diğer çalışmaların önündedir.

Tablo 6. Önerilen modelin mevcut çalışmalarla karşılaştırılması

	Sınıf Sayısı	Başarı Oranı	Eğitim süresi
Korkmaz ve Ark. [6]	11	93.5	-
Espinosa ve Ark. [7]	4	70	-
Pierdica ve Ark. [9]	2	70	-
Li ve Ark. [10]	6	97.9	8 saat

Vankatesh ve Arkadaşları [13]	6	95.4	-
Kurukuru ve Arkadaşları [17]	8	91.7	-
Önerilen model	7	96.56	57 Dakika

#### IV. SONUÇ

Yenilenemez enerji kaynaklarının tükenmesi ve çevreye verdikleri zarar, başta güneş enerjisi olmak üzere yenilenebilir enerji kaynaklarına olan ilginin artmasına neden olmuştur. Yenilenebilir enerji kaynaklarının en yaygını, doğada en çok bulunan güneştir. Güneş panelleri, güneş enerjisini elektrik enerjisine çeviren sistemlerdir. Güneş panellerinin yaygınlığı günümüzde giderek artmaktadır.

Güneş panellerinden iyi performans alabilmek için panel bakımı düzenli yapılmalıdır. Ancak panel bakımları maliyet ve zaman gerektirmektedir.

Bu çalışmada panel kusurları, "Kuş Pislği, Temiz, Tozlu, Elektriksel Hasarlı, Fiziksel Hasarlı, Karlı ve Gölgelenmiş" şeklinde sınıflandırılan veri seti kullanılmış ve kusurların tespit edilerek sınıflandırılabilmesi için derin öğrenme tabanlı bir ESA modeli önerilmiştir. Önerilen modelin kesinlik, geri çağırma ve f1-skoru değerleri sırasıyla %97, %97, %97 olarak ölçülmüştür. Elde edilen sonuçlar, panel kusurlarının sınıflandırılması için önerilen modelin diğer modellere kıyasla çok sınıflı hasarları kısa bir sürede yüksek doğrulukta sınıflandırma konusunda önde olduğunu göstermektedir. Çalışmada önerilen model sayesinde, panel kusurları kısa sürede yüksek bir doğrulukla belirlenebilecek ve panellerden istenilen verim alınabilecektir.

#### KAYNAKLAR

- [1] "Times of 1500 PV system has come" URL: <https://www.mornsun-power.com/html/news-detail/blog-posts/213.html>
- [2] Platon, R., Martel, J. T., Woodruff, N., & Chau, T. Y. (2015b). Online fault detection in PV systems. IEEE Transactions on Sustainable Energy, 6(4), 1200–1207. <https://doi.org/10.1109/tste.2015.2421447>
- [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 & Sustainable Energy



- Reviews, 138, 110512. <https://doi.org/10.1016/j.rser.2020.110512>
- [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. <https://doi.org/10.1016/j.solener.2020.03.049>
- [5] Jordan, D., Kurtz, S., VanSant, K., & Newmiller, J. (2016). Compendium of photovoltaic degradation rates. *progress in photovoltaics*, 24(7), 978–989. <https://doi.org/10.1002/pip.2744>
- [6] Korkmaz, D., & Açıköz, 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. <https://doi.org/10.1016/j.engappai.2022.104959>
- [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. <https://doi.org/10.1016/j.renene.2020.07.154>
- [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. <https://doi.org/10.2339/politeknik.1094586>
- [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. <https://doi.org/10.5194/isprs-archives-xlii-2-893-2018>
- [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. <https://doi.org/10.1109/tec.2018.2873358>
- [11] S. Wei, X. Li, S. Ding, Q. Yang and W. Yan, (2019). Hotspots Infrared detection of photovoltaic modules based on hough line transformation and faster-rcnn approach, 2019 6<sup>th</sup> International Conference on Control, Decision and Information Technologies (CoDIT), pp. 1266-1271, <https://doi.org/10.1109/codit.2019.8820333>
- [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. <https://doi.org/10.1016/j.renene.2020.01.148>
- [13] Venkatesh, S., & Sugumaran, V. (2021). Fault detection in aerial images of photovoltaic modules based on deep learning. *IOP Conference Series*, 1012(1), 012030. <https://doi.org/10.1088/1757-899x/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. <https://doi.org/10.1088/1757-899x/768/7/072061>
- [15] Díaz, J. J. V., Vlaminc, 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. <https://doi.org/10.3390/s20216219>
- [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. <https://doi.org/10.1016/j.solener.2020.01.055>
- [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, 2019 International Conference on Computer and Information Sciences (ICCIS), pp. 1-6, <https://doi.org/10.1109/iccisci.2019.8716442>
- [18] Zaki, S. A., Zhu, H., Fakhri, 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. <https://doi.org/10.1049/rpg2.12016>
- [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. <https://doi.org/10.1016/j.solener.2019.02.067>
- [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. <https://doi.org/10.1016/j.solener.2020.03.049>
- [21] Solar panel clean and faulty images. (2023, May 16). Kaggle. <https://www.kaggle.com/datasets/pythonafroz/solar-panel-clean-and-faulty-images>
- [22] LeCun, Y., Bengio, Y., & Hinton, G. E. (2015b). Deep learning. *nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [23] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- [24] İnik, Ö. & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, c. 6, sayı. 3, ss. 85-104. <http://dergipark.gov.tr/download/article-file/380999>

- [25] Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. in proceedings of the International Greece, Springer: Berlin/Heidelberg, Germany, 2010; pp. 92–101.