

Elektrolüminesans Görüntülerde Arızalı Fotovoltaik Panel Hücrelerin Evrişimli Sinir Ağı ile Otomatik Sınıflandırılması

Hakan AÇIKGÖZ¹, Deniz KORKMAZ^{2*}

¹ Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Gaziantep, Türkiye

² Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

¹ hakan.acikgoz@gibtu.edu.tr, ^{2*} deniz.korkmaz@ozal.edu.tr

(Geliş/Received: 05/04/2022;

Kabul/Accepted: 19/05/2022)

Öz: Fotovoltaik (FV) panel hücrelerindeki arızaların tespiti ve sınıflandırılması güneş enerjisi santrallerinin verimli ve güvenilir bir şekilde işletilebilmesi için oldukça önemli bir konu haline gelmiştir. Bu çalışmada, FV panel hücrelerindeki arızaların hızlı ve doğru bir şekilde tespit edilmesi ve sınıflandırılması için etkin bir evrişimli sinir ağı (ESA) modeli önerilmiştir. Önerilen model, daha az parametre ve model boyutuna sahip SqueezeNet ile transfer öğrenme yaklaşımı kullanılarak geliştirilmiştir. Eğitim yakınsamasını iyileştirmek ve sınıflandırma başarımını arttırmak için modelin aktivasyon fonksiyonları değiştirilerek ateşleme modüllerinden atlama bağlantıları oluşturulmuştur. Deneylerde, elektrolüminesans (EL) görüntülerden elde edilen bir veri seti kullanılmıştır. Sınıf dağılımının dengesizliğini gidermek ve örnek sayısını arttırmak için veri artırma teknikleri uygulanmıştır. Önerilen yöntemin performansı AlexNet, ShuffleNet, GoogLeNet ve SqueezeNet gibi ön eğitilmiş ESA mimarileri ile karşılaştırılmıştır. Gerçekleştirilen deneysel çalışmalarda önerilen yöntemin doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor değerleri sırasıyla %91.29, %84.21, %89.72, %92.04 ve %86.88 olarak elde edilmiştir. Ayrıca, önerilen yöntem diğer yöntemlerin doğruluk ölçütündeki değerlerini %0.99 ile %6.29 arasında iyileştirmiştir. Elde edilen tüm sonuçlar analiz edildiğinde, önerilen yöntemin FV panel hücrelerindeki arızaların tespitinde etkili bir performansa sahip olduğu gözlemlenmiştir.

Anahtar kelimeler: Fotovoltaik panel hücreleri, arıza tespiti ve sınıflandırma, elektrolüminesans görüntüleme, evrişimli sinir ağları, derin öğrenme.

Automatic Classification of Defective Photovoltaic Module Cells in Electroluminescence Images with Convolutional Neural Network

Abstract: Detection and classification of faults in photovoltaic (PV) module cells have become a very important issue for the efficient and reliable operation of solar power plants. In this study, an efficient convolutional neural network (CNN) model is proposed for fast and accurate detection and classification of faults in PV module cells. The proposed model is developed using the transfer learning approach with SqueezeNet, which has fewer parameters and model sizes. In order to improve the training convergence and increase the classification performance, the activation functions of the proposed model are changed and skip connections are added from the fire modules. A dataset obtained from electroluminescence (EL) images is used in the experiments. Data augmentation techniques are also applied to eliminate the imbalance of class distribution and increase the class samples. The performance of the proposed method is compared with pre-trained CNN architectures such as AlexNet, ShuffleNet, GoogLeNet, and SqueezeNet. In the experimental studies, the accuracy, precision, sensitivity, specificity, and F1-score values of the proposed method are obtained as 91.29%, 84.21%, 89.72%, 92.04%, and 86.88%, respectively. In addition, the proposed method improves the accuracy values of the other methods between 0.99% and 6.29%. When all the obtained results are analyzed, it is observed that the proposed method has an effective performance in the detection of faults in PV module cells.

Key words: Photovoltaic module cells, fault detection and classification, electroluminescence imaging, convolutional neural networks, deep learning.

1. Giriş

Son yıllarda, küresel ısınma ve fosil yakıtların azalması güneş, rüzgar, hidroelektrik ve jeotermal enerji gibi yenilenebilir enerji kaynaklarına (YEK) olan ilgiyi arttırmıştır. Bu enerji kaynaklarının arasında, güneş enerjisi dikkat çeken YEK türlerinden biridir. Güneş enerjisi, muazzam potansiyel gücü ve güvenli enerji üretimi gibi özellikleri sayesinde daha kabul edilebilir ve gelecek vaat eden bir enerji kaynağı haline gelmiştir [1,2]. Geleneksel

* Sorumlu yazar: deniz.korkmaz@ozal.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-6432-7243, ² 0000-0002-5159-0659

enerji kaynakları ile karşılaştırıldığında, güneş enerjisi bol kaynak, geniş yayılım, çevre kirliliği içermemesi, serbest kullanım ve kolay erişebilirlik gibi birçok avantaja sahiptir [3,4]. Bu enerjinin önemli özelliklerinden biri de, üretim için gerekli sistemlerin kolay kurulumu ve düşük altyapı maliyetleri içermesidir [1,5]. Böylece, dünya genelinde güneş enerjisi üretim santralleri giderek yaygın hale gelmeye başlamıştır.

Genel olarak güneş enerjisi üretimi termal ve fotovoltaik (FV) sistemlerle sağlanmaktadır. Bunlar arasında FV'ler, güvenli ve sürdürülebilir enerji üreten en önemli güç üretim sistemlerinden biri olarak kabul edilir [6]. Dünya genelinde, toplam FV enerji üretim kapasitesi 10 yıl önce sadece 23 GW iken 2019 yılı sonunda 625 GW'ı aşmıştır. FV kapasitesinin yıllık ilavesi ise 2009 yılında yaklaşık 8 GW iken 2019 yılında 115 GW'dan fazla olmuştur. Ayrıca, FV kapasitesinin 2030 yılında 3,518 TWh'lik enerji üretimini karşılayabileceği tahmin edilmektedir [7]. Bununla birlikte, FV sistemlerinin üretimi ve kullanımında panellerin güvenilirliği, güç düşüşü, dış ortam koşulları ve arızalarla karşılaşılması gibi çeşitli problemler ortaya çıkar. FV panelleri açık havada kurulu olurlar ve genellikle bir alüminyum çerçeve ve cam laminasyon yardımıyla çevre koşullarından korunurlar. Ancak, bu önlemler sert iklim koşullarından dolayı yeterli olmayabilir ve kurulum sırasında panelin kırılması veya çatlaması, düşen ağaç dalları, karlanma, böcek izleri, yanık izleri, gölgelenme ve renk değişimi gibi farklı birçok arıza meydana gelebilir. Ayrıca, hatalı lehimleme veya bağlantı gibi üretim hataları da FV panellerin hasarlı olmasına sebep olabilir. Bu tür çeşitli problemler, FV sistemlerinin akım akışını engelleyerek üretim gücünü ve verimliliğini azaltır. Bu nedenle, güneş enerjisi üretim santrallerinde, maksimum verimi sağlamak için panellerin çalışma durumunu izlemek ve arızalı üniteleri değiştirmek veya onarmak gerekir [8–10].

Arızalı panellerin ve hücrelerin görsel olarak tespit edilmesi uzman kişiler tarafından bile zor bir durumdur. Camlardaki görülebilir çatlak veya kırıkların yanı sıra, bir panelin verimliliğini düşüren birçok kusur gözle görülemeyebilir. Böylece, yukarıda belirtilen arızalar veya kusurların tespiti için akım-gerilim (I-V) eğrisi ölçümü, termal kızılötesi görüntüleme ve elektrolüminesans (EL) görüntüleme gibi yöntemler geliştirilmiştir [6,11]. I-V eğrisi ölçümü, FV panellerinin belirli radyasyon altında çıkışı gerilimini ve akımını ölçülerek bir grafik üzerinde görselleştirilmesine dayanır. Bu eğriler ile tüm bir panelin genel durumunu belirlemek mümkün olsa da küçük kusurların tespiti zordur ve problemleri hücre veya bölgeyi tam olarak belirleyemez [9,11]. Kızılötesi görüntüleme, güneş panelleri ve hücre koşullarının görselleştirilmesi için sıklıkla kullanılan bir diğer yöntemdir. Beklenmedik derecede yüksek bir akım bir bölgede ısınmaya neden olurken, açık devre o bölgenin düşük sıcaklıkta olmasına neden olur. Böylece kızılötesi görüntüleme, kısa devreler, sıcak noktalar ve etkin olmayan hücreler gibi arızaları tespit edebilir. Ancak, termal kameraların çözünürlüğü nispeten düşük olduğu için mikro çatlak gibi kusurların bu yöntemle etkin bir şekilde tespit edilmesi zordur [6]. EL görüntüleme ise FV panellerin gerilim geri beslemesi sonucu yaydığı üst kızılötesi dalga boyundaki ışığı analiz ederek, paneli oluşturan hücreler üzerindeki kristal yapı hakkında bilgi veren etkili bir yöntemdir. Bu yöntem çok daha yüksek çözünürlükte görüntüleme sunar ve mikro çatlakları da tanımlayabilir [12]. EL görüntülerinde, bağlantısı kesilmiş parçalar ışınlama yapmadığı için problemleri hücreler daha koyu görünür. Bir EL görüntüsü elde etmek için akım, 1,150 nm dalga boyunda EL emisyonunu indükleyen bir FV paneline uygulanır ve emisyon bir silikon CCD sensörü ile görüntülenebilir. Bu yöntem mikro çatlakların tespit edilmesini sağlar ve görüntüler yanal ısı yayılımından dolayı bulanıklıktan zarar görmez [9]. Yine de, EL görüntülerin uzman kişiler tarafından detaylı olarak incelenmesi ve yorumlanması hem zaman alıcı bir süreçtir hem de hataya sebep olabilir. Manuel süreç özellikle büyük ölçekli üretim tesislerinde ve enerji santrallerinde denetimin yeterince verimli olmasını engeller. Bu nedenle, EL görüntülerindeki arızaların otomatik olarak yorumlanmasını ve arızaların tespitini sağlamak oldukça önemli bir konu haline gelmiştir [11,13].

Literatürde, FV panellerindeki arızalarının otomatik tespiti ve sınıflandırılmasına yönelik çalışmalar son zamanlarda ivme kazanmaya başlamıştır. Ali ve ark. [4] FV panellerin sıcak noktalarının tespiti ve sınıflandırılması için kızılötesi termografi tekniği kullanılarak hibrit özelliklere dayalı bir destek vektör makinesi (DVM) modeli önermiştir. Ayrıca, RGB, doku, yönlendirilmiş gradyan histogramı ve yerel ikili desenden oluşan yeni bir hibrit öznitelik vektörü ile bir veri birleştirme yaklaşımı kullanılmıştır. Pratt ve ark. [5] tek kristalli ve çok kristalli silikon levha tabanlı FV panellerinin EL görüntüleri ile U-Net mimarisi tabanlı bir anlamsal bölütleme modeli geliştirmişlerdir. Bu model, piksel düzeyinde arıza sınıflandırma maskelerini üretmek için laboratuvar kontrollü hızlandırılmış stres testi dizisine tabi tutulan bir grup panel üzerinde alınan EL görüntülerine uygulanmıştır. Venkatesh ve Sugumaran [8] RGB görüntülerini kullanarak PV panellerde meydana gelen delaminasyon, böcek izi, yanık izi, kırılma ve renk bozulması gibi önemli arızaların tespitini gerçekleştirmişlerdir. Önemli ve baskın öznitelikler J48 karar ağacı algoritması ile belirlenmiştir. Sınıflandırıcı olarak yerel ağırlıklı öğrenme, k-yıldız, en yakın komşu ve k-en yakın komşu algoritmaları kullanılmıştır. Zhao ve ark. [12] üretim hattının denetim gereksinimlerini karşılamak için çok sınıflı arızaların evrişimli sinir ağı (ESA) tabanlı otomatik tespitini sağlamışlardır. Çalışmada, arıza etiketli 5,983 EL görüntüsü kullanılmış ve 19 farklı arıza tanımlanmıştır. Sizzkouhi ve ark. [14] FV panellerinde karşılaşılan çeşitli yaygın arızalar ve kusurlar için otonom bir arıza tespit yöntemi önermiş ve sıklıkla karşılaşılan kuş düşüşlerinin tespitine odaklanmışlardır. Bu bağlamda, VGG-16

modeli modifiye edilerek bir kodlayıcı-kod çözücü mimarisi tabanlı bölütleme yöntemi kullanılmıştır. Akram ve ark. [15] derin öğrenme yöntemi tabanlı transfer öğrenme ile kızılötesi görüntülerdeki panel arızalarının otomatik tespitini gerçekleştirmişlerdir. Başka bir çalışmada, Haidari ve ark. [16] FV enerji santrallerinde sıklıkla karşılaşılan sıcak nokta ve sıcak alt dizi etiketli iki tür farklı arızanın tespiti için VGG16 tabanlı bir ESA mimarisi önermişlerdir. Kullanılan veri seti hava ve karasal termal görüntüleri içermiştir. Espinosa ve ark. [17] semantik bölütleme ve RGB görüntülerinden sınıflandırma için ESA yapısı kullanan bir otomatik fiziksel arıza sınıflandırma yöntemi önermiştir. Deneylerde, arızalı ve arızasız olarak tanımlanan 2 çıkış sınıfı ve arızasız, çatlaklar, gölgeler ve kolayca tespit edilemeyen toz olarak 4 çıkış sınıfı analiz edilmiştir. Su ve ark. [18] ise FV santrallerinde küçük sıcak nokta arıza tespiti için çok ölçekli özellik birleştirme, karmaşık arka plan bastırma ve arıza özneteliği vurgulama yeteneklerini sergileyebilen RCAG-Net isimli bir ESA yapısı önermişlerdir.

Son zamanlarda, bazı çalışmalar ise FV panellerinin hücre arızaları üzerine yoğunlaşmıştır. Deitsch ve ark. [9] DVM tabanlı otomatik hücre arıza tespit ve sınıflama yöntemi önermişlerdir. Sınıflandırıcı için gerekli öznetelikler bir ESA yapısı ile çıkarılmıştır. Çalışmada, hem mono hem de polikristal panellerin yüksek çözünürlüklü EL görüntüleri kullanılmıştır. Chen ve ark. [13] çok kristalli güneş pilleri için bir çatlak tespit yöntemi önermişlerdir. Çatlak ve arka plan arasındaki kontrastı artıran çatlak belirginlik haritasını oluşturmak için bir filtreleme yöntemi kullanılmış ve çatlak bölgesinin belirlenmesi sağlayan yerel eşik ve minimum yayılma ağacını ile bölütleme gerçekleştirilmiştir. Fiorese ve ark. [19] Deeplab-V3 v ResNet-50 tabanlı bir bölütleme yöntemi önermiş 17,064 EL görüntüsü ile hücre arızaları tespit edilmiştir. Su ve ark. [20] heterojen arka plan bozulması altında daha ayırt edilebilir arıza özellikleri elde etmek için, merkez simetrik yerel ikili desen yöntemi ile merkez piksel gradyan bilgisi adlı yeni bir özellik tanımlayıcısı önermişler ve her pikseli eşiklemeye tabi tutmuşlardır. Bir başka çalışmada, farklı seviyede derin öznetelikler kullanılarak bir mikro çatlak tespit yöntemi önerilmiştir. Otomatik kodlayıcı ile yığılanmış gürültü giderme süreci uygulanmış ve ön ilgileri temsil eden öznetelikler ESA yardımı ile çıkartılmıştır [21]. Chen ve ark. [22] ise renkli güneş pili görüntülerinin ışık spektrumu özelliklerini inceleyerek geliştirdikleri ESA yapısı ile hücre yüzeyindeki arızaları sınıflamışlardır.

Yukarıdaki çalışmalar incelendiğinde, bir FV santrali verimliliğinin sağlanması için panel içindeki arıza ve kusurların tam yerinin vurgulanması, etkilenen alanların yüksek hassasiyetle izlenmesini sağlar. Bunun için bir hücre arızasının belirlenmesi de önemli bir adım haline gelir. Böylece, arızalı alanların hızlı bir şekilde tanımlanıp panelin gelecekteki verimlilik kaybının tahmini potansiyel olarak daha kolay belirlenebilir [9,23]. Sonuç olarak, panel hücrelerinin EL görüntüleri ile görsel olarak incelenmesi ve arızaların otomatik sınıflandırılması güneş enerjisi üretim santralleri için önemli bir konu haline gelmektedir.

Bu çalışmada, transfer öğrenme yaklaşımı kullanılarak FV panel hücrelerinin arıza tespiti için derin öğrenme tabanlı bir sınıflandırma yöntemi önerilmiştir. Bu kapsamda, gerçek zamanlı uygulamalar için daha az parametre ve depolama alanı gibi özelliklere sahip SqueezeNet tabanlı bir ESA mimarisi geliştirilmiştir. ESA yapısında, eğitim yakınsamasını iyileştirmek ve fazla öğrenme probleminin üstesinden gelmek için hem toplu normalleştirme (BN) katmanı kullanılmış hem de düzeltilmiş doğrusal birim (ReLU) fonksiyonları üstel doğrusal birim (ELU) fonksiyonları ile değiştirilmiştir. Ayrıca, geliştirilen ağına daha detaylı öznetelikleri birleştirebilmesi için ateşleme katmanlarından atlama bağlantıları oluşturulmuştur. Çalışmada, halka açık bir EL veri seti kullanılmış ve sınıf dağılımının dengesizliğini gidermek için veri artırma teknikleri uygulanmıştır. Çalışmanın değerlendirilmesinde, önerilen modelin etkinliği ve başarımı bazı ön eğitilmiş ESA mimarileri ile karşılaştırılmıştır. Elde edilen sonuçlar, geliştirilen modelin EL görüntülerinden FV panel hücre arızalarını 2 sınıflı olarak işlevsel ve arızalı etiketleri ile etkili bir şekilde sınıflayabildiğini göstermektedir. Önerilen yöntem basit, hızlı ve düşük boyutlu olması gibi özellikleri de pratikte uygulanabilir bir potansiyele sahiptir.

Çalışmanın geri kalan kısmı; kullanılan veri seti, önerilen ESA mimarisi, veri artırma teknikleri, değerlendirme ölçütleri, deneysel çalışmalar ve sonuç bölümlerinden oluşmaktadır.

2. Materyal ve Yöntem


ESA mimarileri kendi kendine öğrenme yetenekleri ve üstün performansları sayesinde görüntü ile ilgili sınıflama problemlerinde son derece etkili çözümler sunabilir. Eğitilmiş çok sayıda katman içeren ESA yapıları, görsel bilgilerin işlenmesinde rol oynayan görsel korteks yapısından esinlenerek geliştirilmiştir. Bir evrişimli ağ genel olarak evrişim, havuzlama ve tam bağlantı katmanları ile aktivasyon fonksiyonlarından meydana gelir. Evrişim katmanları, filtreler aracılığıyla girdileri işleyerek çıktılarını girdiyle uyumlu uzamsal bağlantılara dönüştürür. Aktivasyon fonksiyonları evrişim katmanlarını takip ederek ağı öznetelik çıkarma yeteneğinin artırılmasında yardımcı olur. Havuzlama katmanı ise genel olarak evrişimlerden sonra uygulanan bir örnekleme işlemi gerçekleştirir. Son olarak tam bağlantı katmanı ile belirlenen amacın gerçekleşmesi için nöronların eğitimini sağlar. Böylelikle, geliştirilen ağ mimarisi otomatik ve etkili öznetelikleri öğrenme yeteneği sergileyebilir [18,24].

Bu bağlamda, basit ve etkili bir ön eğitilmiş ağ olan SqueezeNet tabanlı ESA yapısı tasarlanmış ve FV panel hücrelerinin arızalarını otomatik olarak tespit ederek hücrenin işlevselliğini sınıflamak için kullanılmıştır. Bu bölümün devamında deneylerde kullanılan FV veri seti, önerilen ESA yapısı ve veri artırma teknikleri ayrıntılı olarak açıklanmaktadır.

2.1 Kullanılan FV Veri Seti

Bu çalışmada, monokristal ve polikristal FV panellerinin yüksek çözünürlüklü EL görüntülerinden elde edilen halka açık bir güneş pili veri seti kullanılmıştır [9,25]. Bu veri seti 44 farklı FV panelinden elde edilen 300×300 piksel çözünürlükte 2,624 panel hücresinden oluşur. Burada, 18 panel monokristal 26 panel ise polikristal tiptedir. Toplamda 715 görüntü arızalı sınıfını temsil etmektedir. 106 adet görüntü tamamen arızalı olmayan daha küçük kusurları içerirken, 295 görüntü yüzey kusurlarına sahiptir. Bu görüntüler veri setinde %33 ve %67 ağırlığına sahip arızalı şekilde etiketlenmiştir. Geri kalan 1,508 hücre görüntüsü ise herhangi bir algılanabilir arıza olmaksızın işlevsel olarak etiketlenmiştir. Bu çalışmada, %33 ve %67 ağırlıklarında arızalı görüntüler dikkate alınmamış ve sadece arızalı ile işlevsel etiketlerine sahip EL görüntüleri kullanılmıştır.

Veri seti, farklı açılardan bir test laboratuvarı ortamında ve kontrollü koşullar altında toplanarak elde edilmiştir. Böylece, görüntü kalitesini olumsuz etkileyecek etkenler en aza indirgenmiştir. Bazı örnekler ise kırılma, ölçekleme ve döndürme gibi ön işleme adımları ile düzenlenmiştir. Karanlık bir odada yapılan çekimlerde FV panellerinin tek ışık yaydığı göz önüne alındığında, görüntülerin homojen bir şekilde aydınlatılması düşünülmüştür. Veri seti özellikle mikro çatlakları ve elektriksel olarak ayrılmış ve bozulmuş parçaları olan hücreleri, kısa devreli hücreleri, açık devre ara bağlantıları ve lehimleme hatalarını içermektedir. Böylece, FV panellerinin verimliliğini, güvenilirliğini ve dayanıklılığını olumsuz yönde etkileyen yaygın arızalar temsil edilmiştir [9]. Şekil 1’de veri setinde yer alan çeşitli örnek görüntüler gösterilmektedir.



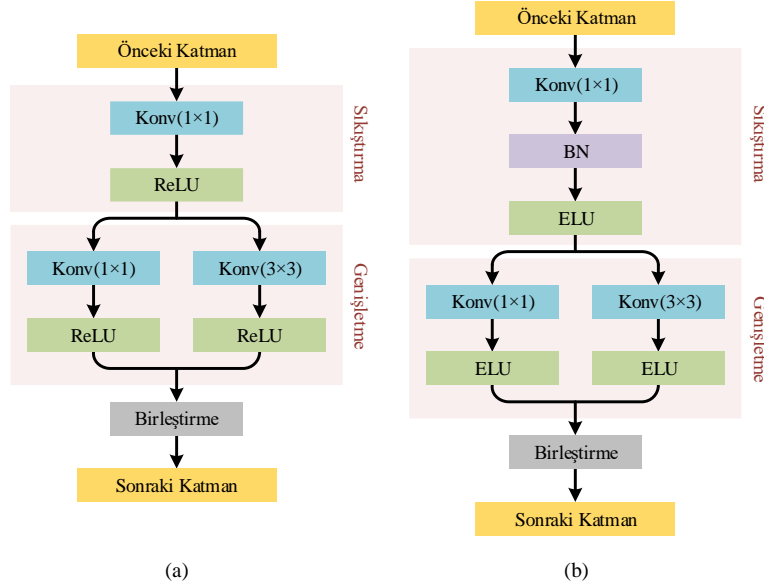
Şekil 1. İşlevsel ve arızalı sınıflarına ait örnek EL görüntüleri.

2.2 Önerilen ESA Modeli

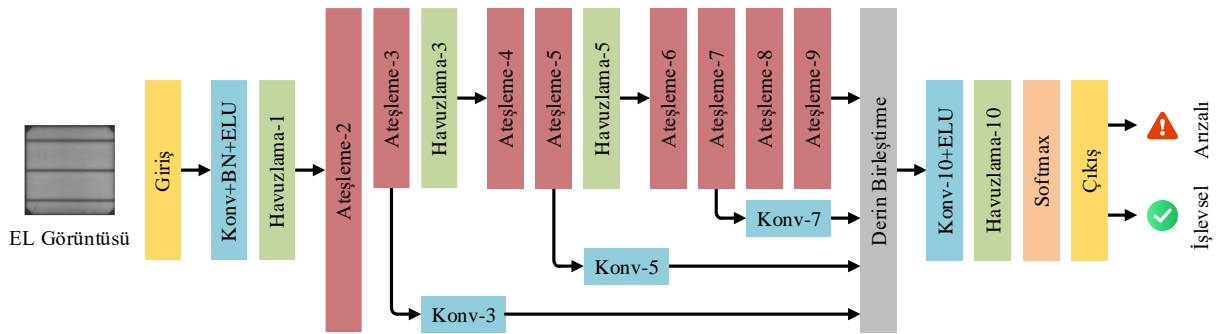
ESA modellerinde sıklıkla kullanılan ön eğitilmiş mimarilerden biri de SqueezeNet mimarisidir. Bu mimari, görüntü işleme problemlerinde büyük boyutlu ve karmaşık derin mimariler ile aynı düzeyde başarı elde etmek için geliştirilen küçük boyutlu ve alternatif bir ESA yapısıdır. Bu mimarinin temel amacı daha az parametreye sahip bir evrişimli ağ oluşturarak 50 kat daha az parametre ve 0.5 MB’dan küçük bir model boyutu ile AlexNet mimarisine benzer doğruluk sağlamaktır [26,27]. SqueezeNet mimarisi daha küçük bant genişliği, verimli dağıtılmış katman yapısı ve düşük depolama alanı gereksinimi gibi özellikleri sayesinde hem hızlı hem de yüksek performans sağlayabilmektedir [28]. Belirtilen özellikler dikkate alınarak, bu çalışmada SqueezeNet tabanlı etkili ve üstün bir ESA modeli önerilmiştir.

SqueezeNet mimarisi genel olarak ateşleme modülü isimli katmanlardan oluşmaktadır. Şekil 2 (a)’da gösterildiği gibi, her bir ateşleme modülü sıkıştırılmış ve genişletilmiş evrişim katmanlarını içerir. Sıkıştırılmış katman 1×1 boyutunda filtrelerden oluşurken genişletilmiş katman 1×1 ve 3×3 boyutunda filtrelerden meydana gelir. Ateşleme modülleri kademeli olarak yerleştirilmiştir ve Ateşleme-2 katmanından başlayarak Ateşleme-9

katmanına kadar toplam 8 modül bulunur. Burada, $H \times W \times C$ boyutundaki giriş görüntüsü sıkıştırılmış katmandan geçer ve evrişim sayısı giriş kanalları sayısının $C/4$ 'üne eşit olur. Daha sonra, evrişimli görüntü genişletilmiş katmandan geçirilerek verinin derinliği çıkış derinliğinin $C/2$ 'sine genişletilir. SqueezeNet model yapısında, evrişim katmanlarını bir ReLU aktivasyon fonksiyonu takip eder ve elde edilen öznelik haritaları bir birleştirme katmanı ile birleştirilir. BN katmanları içermeyen ELU fonksiyonu, BN içeren ReLU fonksiyonuna göre daha iyi performans sergileyebildiği için önerilen modelde tüm ReLU katmanları ELU katmanları ile değiştirilmiştir. Bununla birlikte, eğitim yakınsamasını iyileştirmek ve aşırı öğrenmeden kaçınmak için ateşleme modüllerindeki sıkıştırılmış katmanlarda yer alan evrişim katmanı ile aktivasyon fonksiyonu arasında BN katmanları eklenmiştir [29]. Hesaplama maliyetinin arttırılmaması için ateşleme modülleri içerisindeki genişletilmiş evrişim katmanlarında ise BN katmanı kullanılmamıştır. Bu değişiklikler ile önerilen ateşleme yapısı Şekil 2 (b)'de gösterilmiştir. Ayrıca, alt ateşleme modüllerinden daha derin öznelikleri almak ve çok seviyeli öznelik haritası oluşturmak için Ateşleme-3, Ateşleme-5 ve Ateşleme-7 modüllerinden 1×1 boyutunda filtreler ile atlama bağlantıları tasarlanmıştır [29,30]. Bu bağlantılar ile basit ve etkili bir baypas yapısı elde edilerek ağın doğruluk başarımı arttırılmıştır. Önerilen ESA modelinin genel yapısı Şekil 3'de verilmiştir. Bu şekillerde, evrişim katmanı ise Konv() ifadesi ile temsil edilmiştir. Ağ yapısında yer alan havuzlama katmanları uzamsal boyutlar boyunca bir alt örnekleme işlemi gerçekleştirir ve küresel ortalama havuzlama katmanı, sınıfların özellik haritalarını tek bir sınıf değerine dönüştürür. Ağın sonunda yer alan aktivasyon fonksiyonu ise ikili sınıflara ait olasılık dağılımlarını üretmektedir. Ayrıca, ağın girişi RGB derinlikli 227×227 piksel boyutundadır ve her giriş görüntüsünün boyutu RGB derinlikli ağın girişine göre yeniden boyutlandırılmıştır.



Şekil 2. Ateşleme modülleri: (a) Klasik ateşleme yapısı, (b) Önerilen ateşleme yapısı.




Şekil 3. Önerilen ESA modeli.

2.3 Veri Artırma Teknikleri

Veri setlerinin örnek sayısı derin öğrenme modellerinin başarımını etkilemektedir. Genellikle, sınırlı sayıda veri ile ESA'ları eğitmek, aşırı öğrenmeye neden olur ve eğitilen ağın genelleme yeteneği yüksek olmaz. Ancak, veri setindeki örneklerin nicelik, nitelik ve çeşitlilik yönünden sayısını artırmak geliştirilen ağın eğitim performansını artırabilir. Veri artırma, sınıflandırma problemlerinde ve yeterli verinin olmadığı durumlarda kullanılan popüler yöntemlerden biridir. Veri artırma ile sentetik veri üretimi gerçekleştirilebilir ve sınırlı örneklerin neden olduğu aşırı öğrenme durumuna engel olarak daha iyi bir sınıflandırma performansı sağlar. Böylece, sınıf dağılımları arasındaki düzensizlik en aza indirgenerek tüm sınıflar için aynı sayıda bir kümeleme yapılır [31].

Çalışmada kullanılan FV veri setinde, arızalı ve işlevsel sınıflarına ait toplam 2,223 EL görüntüsü yer almaktadır. Ancak, arızalı sınıfı için 715 adet görüntü bulunmaktadır ve işlevsel sınıfının yarısından daha azdır. Bu durumda, sınıflara ait dağılım düzensizdir ve önerilen ağın eğitim performansı için örneklerin arttırılması gereklidir. Veri arttırmada, veri setinin temsil ettiği genel yapıyı korumak için ters çevirme ve döndürme teknikleri uygulanmıştır. Ters çevirme işleminde sütunlardaki ve satırlardaki elemanlar tersine çevrilmiştir. Döndürme işleminde ise görüntüler merkez noktası etrafında ile saat yönünün tersine 180° açı ile döndürülmüştür. Böylece, her bir sınıf örneği için üç farklı sentetik görüntü elde edilmiştir. Şekil 4'de, arızalı sınıftan seçilen örnek bir görüntü için veri artırma sonucu elde edilen sentetik görüntüler verilmiştir.



Şekil 4. Veri artırma teknikleri ile elde edilen sentetik görüntüler.

3. Bulgular

Bu bölümde, EL görüntülerinde FV panellerdeki arızaların tespiti ve sınıflandırılması için deneysel çalışmalar gerçekleştirilmiştir. Deneyler, Intel (R) i7-10750H CPU @2.60 GHz, NVIDIA Quadro P620 GPU ve 16 GB RAM belleğe sahip bir iş istasyonunda MATLAB R2021b programı aracılığıyla yapılmıştır. Veri setindeki görüntüler arızalı ve işlevsel olarak sınıflandırılarak etiketlenmiştir. İlk olarak veri setindeki görüntülerin %15'i doğrulama, %15'i ise test için ayrılmıştır. Kalan görüntülerde ise eğitim başarımını arttırmak için veri artırma teknikleri uygulanmıştır. Veri artırma sürecinden sonra, her iki sınıfın örnek sayıları en az örneğe sahip sınıfa göre rastgele seçilerek eşitlenmiştir. Önerilen yöntemin FV panel hücreleri görüntülerindeki sınıflandırma başarımını AlexNet, GoogLeNet, ShuffleNet ve SqueezeNet gibi literatürde sıklıkla tercih edilen ön eğitilmiş ESA'lar ile karşılaştırılarak test edilmiştir. Tüm yöntemlere aynı eğitim, doğrulama ve test görüntüleri uygulanarak daha adil bir karşılaştırma amaçlanmıştır. Deneylerde, mini-yığın boyutu ve maksimum döngü sayısı sırasıyla 16 ve 50 olarak belirlenmiştir. Eğitim boyunca başlangıç öğrenme oranı 1e-4 olarak ayarlanmış ve her 10 döngüde bir 0.5 azaltma oranı ile değiştirilmiştir. Optimizasyon yönteminde ise stokastik gradyan inişi kullanılmıştır.

3.1 Değerlendirme Ölçütleri

Derin öğrenme yöntemlerinden elde edilen sonuçları analiz etmek için kullanılan doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor değerlendirme ölçütleri Tablo 1'de verilen hata matrisi yardımıyla hesaplanmıştır.

Doğruluk, doğru tahmin edilen sınıftaki örnek sayısının veri setindeki tüm örnekler olan oranı olarak tanımlanmaktadır ve Denklem (1) ile ifade edilmektedir:

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Kesinlik ise doğru tahmin edilen sorumlu örnek sayısının sorumlu olarak tahmin edilen toplam örnek sayısına oranıdır ve Denklem (2) ile ifade edilebilir:

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

Duyarlılık, doğru tahmin edilen sorunlu örnek sayısının gerçekte sorunlu olan tüm örnek sayısına oranı olarak ifade edilmektedir ve aşağıdaki gibi elde edilebilir:

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

Özgüllük, doğru tahmin edilen sorunlu olmayan örnek sayısının gerçekte sorunlu olmayan tüm örnek sayısına oranı olarak matematiksel olarak aşağıdaki denklem ile ifade edilebilir:

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (4)$$

F1-skor, duyarlılık ve kesinlik parametrelerinin ağırlıklı ortalaması olarak ifade edilebilir ve aşağıdaki denklem ile bulunabilir:

$$\text{F1 - skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (5)$$

Değerlendirme ölçütlerinde kullanılan doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif gibi ifadeler denklemlerde DP, DN, YP ve YN olarak simgelenmiştir. DP ve DN sırasıyla gerçekte pozitif ve gerçekte negatif sınıfta yer alan ve doğru tahmin edilen sayıları ifade etmektedir. YP ve YN ise sırasıyla gerçekte negatif ve pozitif sınıfta yer alan ve yanlış tahmin edilen sayıları göstermektedir.

Tablo 1. Hata matrisi.

Hata Matrisi		Tahmin Edilen Sınıf	
		Pozitif (Arızalı)	Negatif (İşlevsel)
Gerçekteki Sınıf	Pozitif (Arızalı)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif (İşlevsel)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

3.2 Deneysel Çalışmalar

Önerilen yöntem ve ön eğitilmiş ESA yöntemlerinden elde edilen ölçüt sonuçları Tablo 2’de listelenmiştir. Ayrıca bu tablodaki sonuçların daha iyi gözlemlenebilmesi için Şekil 5 sunulmuştur.

Tablo 2. Tüm yöntemlere ait değerlendirme ölçütlerinin sonuçları (%).

Yöntem	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
AlexNet	85.89	73.81	86.92	85.40	79.83
ShuffleNet	87.69	80.00	82.24	90.27	81.11
GoogLeNet	89.79	84.77	83.18	92.92	83.96
SqueezeNet	90.39	85.05	85.05	92.92	85.05
Önerilen Yöntem	91.29	84.21	89.72	92.04	86.88

Tablo 2 derinlemesine analiz edildiğinde ilk olarak tüm yöntemler doğruluk değerleri açısından incelenmiştir. Önerilen yöntemin doğruluk değeri %91.29 olarak hesaplanırken En iyi ikinci sonucu gösteren SqueezeNet’in değeri ise %90.39 olarak elde edilmiştir. AlexNet, ShuffleNet ve GoogLeNet’in doğruluk değerleri ise sırasıyla %85.89, %87.69 ve %89.79 olarak hesaplanmıştır. Bu sonuçlardan en kötü değeri AlexNet’in verdiği

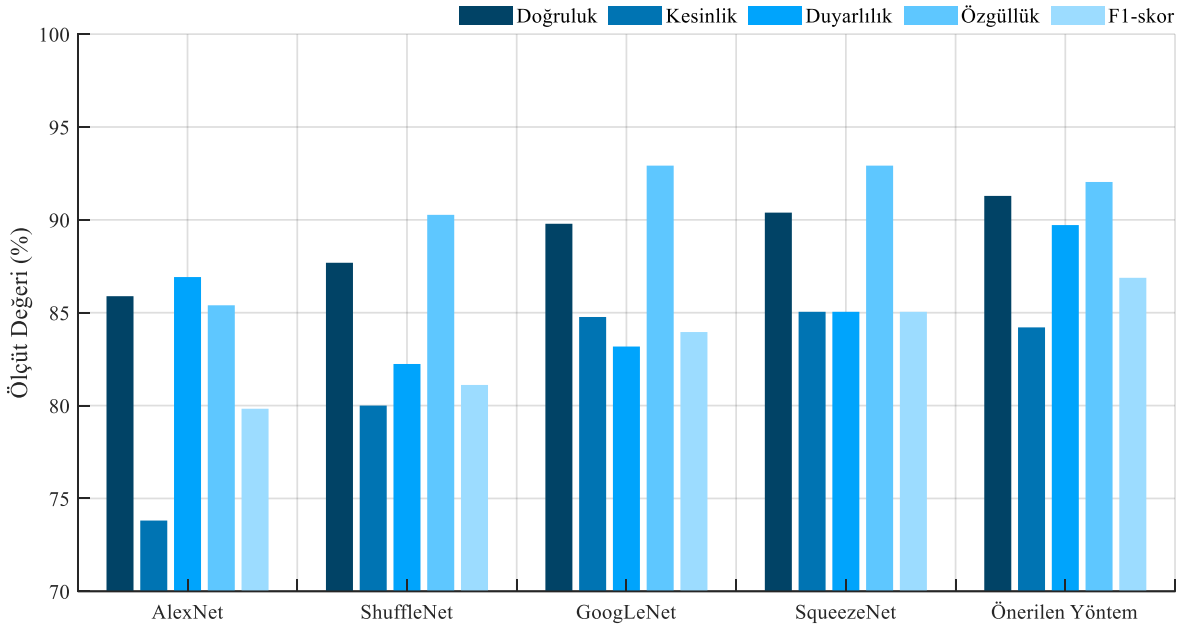
görülmektedir. Bu ölçüt değeri değerlendirildiğinde, önerilen yöntemin daha iyi sınıflandırma sonuçlarını garanti etmesinin yanı sıra FV panellerin daha verimli çalışmasında daha etkin olabileceği düşünülmektedir.

Tüm derin öğrenme yöntemleri kesinlik ölçüt değeri açısından değerlendirildiğinde, önerilen yöntemin kesinlik değeri %84.21 olarak elde edilirken SqueezeNet'in değeri %85.05 olarak hesaplanmıştır. Bu ölçüt değerinde AlexNet, GoogLeNet ve ShuffleNet'in sonuçları sırasıyla %73.81, %80.00 ve %84.77 olarak bulunmuştur. Bu sonuçlardan önerilen yöntemin en iyi ikinci kesinlik değerini sağladığı görülmektedir.

Derin öğrenme yöntemleri diğer bir ölçüt olan duyarlılık değerleri bakımından analiz edildiğinde yine en iyi sonucu %89.72 ile önerilen yöntem sağlamıştır. İkinci en iyi sonucu ise %86.92'lik değeri ile AlexNet göstermiştir. Bu performans değerlendirme ölçütünde ShuffleNet, GoogLeNet ve SqueezeNet'in değerleri %82.24, %83.18 ve %85.05 olarak hesaplanmıştır. Bu ölçütteki sonuçlardan, önerilen yöntemin FV panellerdeki arızaların sınıflandırılmasında diğer yöntemlerden daha iyi sonuçları sağladığı açıkça görülmektedir.

Bu çalışmadaki deneysel çalışmalarda kullanılan derin öğrenme yöntemleri diğer bir ölçüt olan özgüllük değeri açısından analiz edilmiştir. Bu ölçütte en iyi sonucu %92.92 ile GoogLeNet ve SqueezeNet sağlarken en kötü sonucu %85.40'lık değeri ile AlexNet göstermiştir. Önerilen yöntem ise %92.04'lik değer ile en iyi ikinci sonucu sağlamıştır. ShuffleNet'ten elde edilen özgüllük değeri ise %90.27 olarak hesaplanmıştır. Derin öğrenme yöntemleri sonuncu ölçüt olan F1-skor açısından analiz edildiğinde yine en iyi sonuç %86.88 ile önerilen yöntemden elde edilmiştir. En kötü sonucu ise %79.83 ile AlexNet sağlamıştır. ShuffleNet, GoogLeNet, SqueezeNet'in F1-skorundaki değerleri %81.11, %83.96 ve %85.05 olarak hesaplanmıştır.

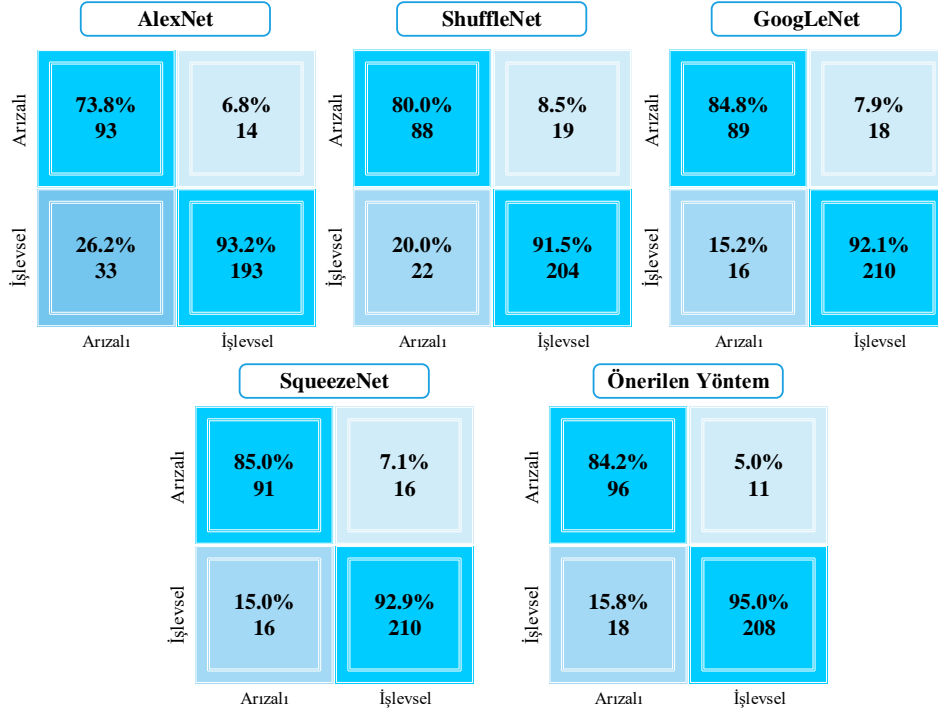
Ayrıca önerilen yöntemin diğer yöntemlerden elde edilen doğruluk, duyarlılık ve F1-skorlarındaki iyileştirme yüzdeleri incelenmiştir. Önerilen yöntem AlexNet, ShuffleNet, GoogLeNet ve SqueezeNet'in doğruluk değerlerini sırasıyla %6.29, %4.11, %1.67 ve %0.99 olarak iyileştirmiştir. Diğer bir ölçüt değeri olan duyarlılıkta ise önerilen yöntem AlexNet, ShuffleNet, GoogLeNet ve SqueezeNet'in sonuçlarını sırasıyla %3.22, %9.10, %7.92 ve %5.49 olarak geliştirmiştir. Önerilen yöntemin F1-skor değerlerindeki iyileştirme yüzdeleri AlexNet, ShuffleNet, GoogLeNet ve SqueezeNet için %8.83, %7.11, %3.48 ve %2.15 olarak hesaplanmıştır.



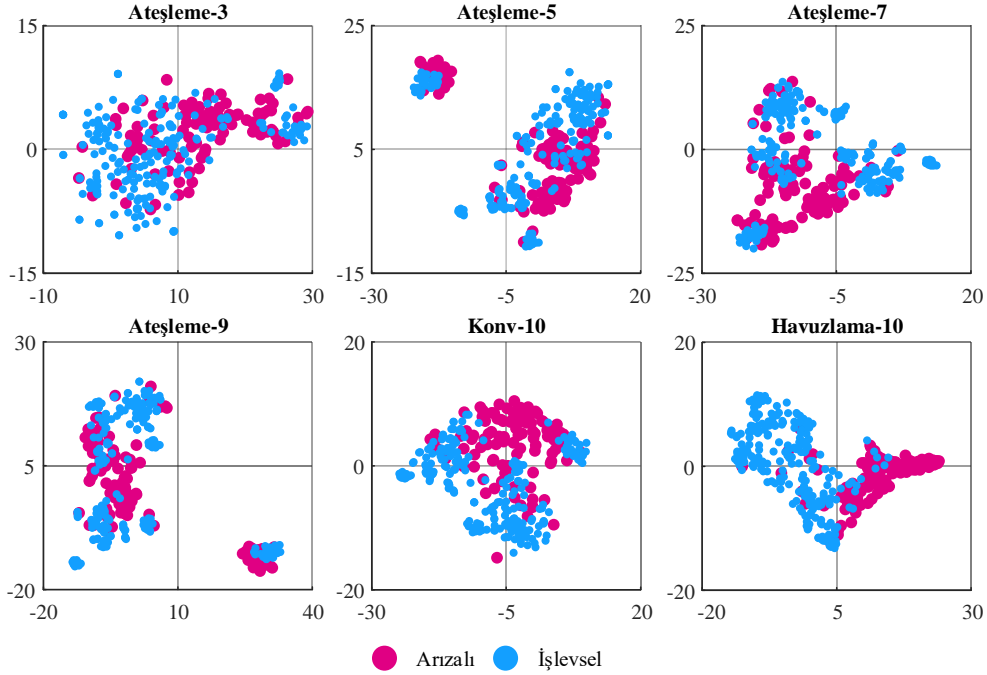
Şekil 5. Değerlendirme ölçütlerinin karşılaştırılması.

Şekil 6'da, bu çalışmada kullanılan tüm derin öğrenme yöntemlerine ait hata matrisleri sunulmuştur. Burada, önerilen yöntem 226 işlevsel etiketindeki görüntülerin 208'ini doğru olarak sınıflandırırken 18 görüntüyü ise yanlış sınıflandırmıştır. Önerilen yöntem arızalı etiketinde bulunan 107 görüntünün 96'sını doğru teşhis ederken 11 görüntüyü ise yanlış tahmin etmiştir. En kötü sonuçları gösteren AlexNet ise arızalı etiketindeki 226 görüntüden 193 görüntüyü doğru tahmin ederken 33 görüntüyü yanlış tahmin etmiştir. İşlevsel etiketindeki 107 görüntüden ise 93 tane görüntüyü doğru tahmin ederken 17 tane görüntüyü ise yanlış tahmin etmiştir. En iyi ikinci sonucu sağlayan SqueezeNet ise işlevsel etiketinden 210 görüntüyü doğru bilirken 16 görüntüyü yanlış tahmin etmiştir.

Arızalı etiketinde ise 91 görüntüyü doğru sınıflandırırken 16 görüntüyü yanlış sınıflandırmıştır. ShuffleNet ve GoogLeNet ise işlevsel olan etiketteki görüntülerden sırasıyla 204 ve 210 tanesini doğru tahmin ederken sırasıyla 22 ve 16 tanesini de yanlış olarak tahmin etmiştir. Yine aynı yöntemler arızalı olan görüntülerden sırasıyla 88 ve 89 tanesini doğru tahmin ederken sırasıyla 19 ve 18 tanesini yanlış tahmin etmiştir.




Şekil 6. Tüm yöntemlerden elde edilen hata matrisleri.



Şekil 7. Önerilen yöntemin katmanlarından çıkartılan öznelilikler.

Önerilen yöntemde, kullanılan veri setindeki her bir etikete ait kümenin önerilen yöntemin katmanlarından çıkartılan öznelikleri görsel olarak analiz etmek için Şekil 7 verilmiştir. Burada, önerilen yöntemin Ateşleme-3, Ateşleme-5, Ateşleme-7, Ateşleme-9, Konv-10 ve Havulama-10 katmanlarındaki arızalı ve işlevsel etiketlerindeki görüntülere ait kümelenmeler görülmektedir. Bu öznelik dağılımları incelendiğinde, Ateşleme-3 katmanından elde edilen arızalı ve işlevsel sınıflara ait öznelikler karmaşık bir durumdadır. Önerilen yöntemin Ateşleme-5 katmanındaki öznelikler analiz edildiğinde yine her bir etiketteki görüntülere ait kümeler aynı noktada bulunmamaktadır. Ateşleme-7 ve Ateşleme-9 katmanlarından çıkartılan özneliklere ait görüntüler incelendiğinde her bir etiket aynı noktada kümelenmemiştir. Son katmanlardan olan Konv-10 ve Havulama-10'daki özellikler gözlemlendiğinde ise her bir etikete ait öznelik dağılımı neredeyse farklı yerlerde ayrılarak kümelenmiştir.

Ayrıca, önerilen yöntemin arızalı ve işlevsel sınıflarındaki her bir görüntüyü tahmin ederken hangi bölgeleri ele alarak bir karar verdiğini görselleştirmek için gradyan ağırlıklı sınıf aktivasyon haritalama yöntemi kullanılmıştır. Bu yöntemden elde edilen sonuçlar Şekil 8'de verilmiştir.



Şekil 8. Önerilen yöntemin sınıflardan seçilen örnek giriş görüntülerine karşı ürettiği ısı haritaları.

Burada, test için hazırlanan veri setindeki arızalı ve işlevsel sınıfında bulunan görüntülerden rastgele olarak ikişer EL görüntüsü seçilmiştir. Arızalı sınıfındaki görüntüler incelendiğinde, önerilen yöntem FV panel hücresindeki arızalı görüntüleri sınıflandırırken belirli bölgelere daha fazla yoğunlaşmıştır. Şekilden de görüldüğü gibi bu bölgeler genellikle hücredeki arızaların olduğu yerlerdir. Önerilen yöntem işlevsel sınıfındaki görüntüyü tahmin ederken yine dikkate değer bölgeleri hesaba katarak karar vermiştir.

4. Sonuç

Bu çalışmada, fotovoltaik (FV) panel hücrelerindeki arızaların tespiti ve sınıflandırılması için efektif bir derin öğrenme modeli önerilmiştir. Önerilen model, daha az parametre ve model boyutuna sahip ön eğitilmiş bir evrişimli sinir ağı (ESA) olan SqueezeNet ile geliştirilmiştir. SqueezeNet yapısında aktivasyon fonksiyonları değiştirilerek ve ateşleme modüllerine atlama bağlantıları eklenerek sınıflandırma başarımının artırılması amaçlanmıştır. Deneysel sonuçlarda, elektrolüminesans (EL) görüntülerden oluşan halka açık bir veri seti kullanılmış ve örnek sayısını çoğaltmak için veri artırma teknikleri uygulanmıştır. Veri setindeki tüm görüntüler eğitim, doğrulama ve test süreçleri için rastgele ayrılmıştır. Önerilen yöntemin FV panel hücrelerinden elde edilen görüntülerdeki arızaların tespit edilip sınıflandırmasındaki başarımını incelemek için AlexNet, ShuffleNet, GoogLeNet ve SqueezeNet gibi en çok kullanılan ön eğitilmiş derin öğrenme mimarileri ile karşılaştırmalar yapılmıştır. Deneysel çalışmalarda, önerilen yöntem arızalı ve işlevsel etiketlerinde bulunan görüntüleri ortalama %91.29'luk bir doğruluk değeri ile sınıflandırmıştır. Ayrıca, önerilen yöntem arızalı sınıfı için oluşturulan test veri setindeki 226 görüntünün 208 tanesini ve işlevsel sınıfındaki 107 görüntünün ise 96 tanesini doğru olarak tahmin etmiştir. Elde edilen tüm sonuçlar değerlendirildiğinde, önerilen ESA yapısı FV panel hücrelerindeki arızaların sınıflandırılmasında diğer

ön eğitilmiş derin öğrenme yöntemlerinden daha üstün performans göstererek daha iyi sonuçların elde edilebileceğini göstermiştir.

İlerleyen çalışmalarda, EL görüntülerinden elde edilen çok sınıflı panel ve hücre arıza tespitinin daha etkin ve doğru bir şekilde yapılabilmesi için farklı özelliklere sahip derin öğrenme yöntemleri ile yeni bir modelin geliştirilebileceği düşünülmektedir.

Kaynaklar

- [1] Korkmaz D. SolarNet: A hybrid reliable model based on convolutional neural network and variational mode decomposition for hourly photovoltaic power forecasting. *Appl Energy* 2021;300:117410. doi:10.1016/j.apenergy.2021.117410.
- [2] Acikgoz H. A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting. *Appl Energy* 2022;305:117912. doi:10.1016/j.apenergy.2021.117912.
- [3] Li B, Delpha C, Diallo D, Migan-Dubois A. Application of Artificial Neural Networks to photovoltaic fault detection and diagnosis: A review. *Renew Sustain Energy Rev* 2021;138. doi:10.1016/j.rser.2020.110512.
- [4] Ali MU, Khan HF, Masud M, Kallu KD, Zafar A. A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography. *Sol Energy* 2020;208:643–51. doi:10.1016/j.solener.2020.08.027.
- [5] Pratt L, Govender D, Klein R. Defect detection and quantification in electroluminescence images of solar PV modules using U-net semantic segmentation. *Renew Energy* 2021;178:1211–22. doi:10.1016/j.renene.2021.06.086.
- [6] Demirci MY, Beşli N, Gümüşçü A. Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in Electroluminescence images. *Expert Syst Appl* 2021;175. doi:10.1016/j.eswa.2021.114810.
- [7] Khezri R, Mahmoudi A, Aki H. Optimal planning of solar photovoltaic and battery storage systems for grid-connected residential sector: Review, challenges and new perspectives. *Renew Sustain Energy Rev* 2022;153:111763. doi:10.1016/j.rser.2021.111763.
- [8] Naveen Venkatesh S, Sugumaran V. Machine vision based fault diagnosis of photovoltaic modules using lazy learning approach. *Meas J Int Meas Confed* 2022;191:110786. doi:10.1016/j.measurement.2022.110786.
- [9] Deitsch S, Christlein V, Berger S, Buerhop-Lutz C, Maier A, Gallwitz F, et al. Automatic classification of defective photovoltaic module cells in electroluminescence images. *Sol Energy* 2019;185:455–68. doi:10.1016/j.solener.2019.02.067.
- [10] Otamendi U, Martinez I, Quartulli M, Olaizola IG, Viles E, Cambarau W. Segmentation of cell-level anomalies in electroluminescence images of photovoltaic modules. *Sol Energy* 2021;220:914–26. doi:10.1016/j.solener.2021.03.058.
- [11] Akram MW, Li G, Jin Y, Chen X, Zhu C, Zhao X, et al. CNN based automatic detection of photovoltaic cell defects in electroluminescence images. *Energy* 2019;189:116319. doi:10.1016/j.energy.2019.116319.
- [12] Zhao Y, Zhan K, Wang Z, Shen W. Deep learning-based automatic detection of multitype defects in photovoltaic modules and application in real production line. *Prog Photovoltaics Res Appl* 2021;29:471–84. doi:10.1002/ppp.3395.
- [13] Chen H, Zhao H, Han D, Liu K. Accurate and robust crack detection using steerable evidence filtering in electroluminescence images of solar cells. *Opt Lasers Eng* 2019;118:22–33. doi:10.1016/j.optlaseng.2019.01.016.
- [14] Moradi Sizkouhi A, Aghaei M, Esmailifar SM. A deep convolutional encoder-decoder architecture for autonomous fault detection of PV plants using multi-copters. *Sol Energy* 2021;223:217–28. doi:10.1016/j.solener.2021.05.029.
- [15] Akram MW, Li G, Jin Y, Chen X, Zhu C, Ahmad A. Automatic detection of photovoltaic module defects in infrared images with isolated and develop-model transfer deep learning. *Sol Energy* 2020;198:175–86. doi:10.1016/j.solener.2020.01.055.
- [16] Haidari P, Hajiahmad A, Jafari A, Nasiri A. Deep learning-based model for fault classification in solar modules using infrared images. *Sustain Energy Technol Assessments* 2022;52:102110. doi:10.1016/j.seta.2022.102110.
- [17] Rico Espinosa A, Bressan M, Giraldo LF. Failure signature classification in solar photovoltaic plants using RGB images and convolutional neural networks. *Renew Energy* 2020;162:249–56. doi:10.1016/j.renene.2020.07.154.
- [18] Su B, Chen H, Liu K, Liu W. RCAG-Net: Residual Channelwise Attention Gate Network for Hot Spot Defect Detection of Photovoltaic Farms. *IEEE Trans Instrum Meas* 2021;70. doi:10.1109/TIM.2021.3054415.
- [19] Fioresi J, Colvin DJ, Frota R, Gupta R, Li M, Seigneur HP, et al. Automated Defect Detection and Localization in Photovoltaic Cells Using Semantic Segmentation of Electroluminescence Images. *IEEE J Photovoltaics* 2022;12:53–61. doi:10.1109/JPHOTOV.2021.3131059.
- [20] Su B, Chen H, Zhu Y, Liu W, Liu K. Classification of Manufacturing Defects in Multicrystalline Solar Cells with Novel Feature Descriptor. *IEEE Trans Instrum Meas* 2019;68:4675–88. doi:10.1109/TIM.2019.2900961.
- [21] Qian X, Li J, Cao J, Wu Y, Wang W. Micro-cracks detection of solar cells surface via combining short-term and long-term deep features. *Neural Networks* 2020;127:132–40. doi:10.1016/j.neunet.2020.04.012.
- [22] Chen H, Pang Y, Hu Q, Liu K. Solar cell surface defect inspection based on multispectral convolutional neural network. *J Intell Manuf* 2020;31:453–68. doi:10.1007/s10845-018-1458-z.
- [23] Gallardo-Saavedra S, Hernández-Callejo L, Alonso-García M del C, Santos JD, Morales-Aragónés JI, Alonso-Gómez V, et al. Nondestructive characterization of solar PV cells defects by means of electroluminescence, infrared thermography, I–V curves and visual tests: Experimental study and comparison. *Energy* 2020;205. doi:10.1016/j.energy.2020.117930.

- [24] Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, et al. Recent advances in convolutional neural networks. *Pattern Recognit* 2018;77:354–77. doi:10.1016/j.patcog.2017.10.013.
- [25] Deitsch S, Buerhop-Lutz C, Sovetkin E, Steland A, Maier A, Gallwitz F, et al. Segmentation of photovoltaic module cells in uncalibrated electroluminescence images. *Mach Vis Appl* 2021;32:1–23. doi:10.1007/s00138-021-01191-9.
- [26] Iandola FN, Han S, Moskewicz MW, Ashraf K, Dally WJ, Keutzer K. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. *Arxiv* 160207360 2016:1–13.
- [27] Ucar F, Korkmaz D. COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Med Hypotheses* 2020;140:109761. doi:10.1016/j.mehy.2020.109761.
- [28] Alhichri H, Bazi Y, Alajlan N, Jdira B Bin. Helping the visually impaired see via image multi-labeling based on SqueezeNet CNN. *Appl Sci* 2019;9. doi:10.3390/app9214656.
- [29] Polsinelli M, Cinque L, Placidi G. A light CNN for detecting COVID-19 from CT scans of the chest. *Pattern Recognit Lett* 2020;140:95–100. doi:10.1016/j.patrec.2020.10.001.
- [30] Yang Z, Yang X, Li M, Li W. Automated garden-insect recognition using improved lightweight convolution network. *Inf Process Agric* 2022. doi:10.1016/j.inpa.2021.12.006.
- [31] Shorten C, Khoshgoftaar TM. A survey on Image Data Augmentation for Deep Learning. *J Big Data* 2019;6:1–48. doi:10.1186/s40537-019-0197-0.