



Transfer Öğrenme Yaklaşımı Kullanılarak İzolatör Kusurlarının Tespiti

Detection of Insulator Defects Using Transfer Learning Approach

Muhammed Buğracan Özküçük^{1*}, Ömer Faruk Alçin², Muhsin Tunay Gençoğlu³

¹Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik – Elektronik Mühendisliği Bölümü, bugracan.ozkucuk@ozal.edu.tr, Orcid No: 0000-0002-1466-2502

²İnönü Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, omer.alcin@inonu.edu.tr, Orcid No: 0000-0002-2917-3736

³Fırat Üniversitesi, Mühendislik Fakültesi, Elektrik – Elektronik Mühendisliği Bölümü, mtgencoglu@firat.edu.tr, Orcid No: 0000-0002-1774-1986

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 5 Ocak 2024
Revizyon 19 Mart 2024
Kabul 1 Nisan 2024
Online 30 Haziran 2024

Anahtar Kelimeler:

*Izolatör kusuru,
Transfer Öğrenme,
Çoklu Öğrenme,
ESA.*

ÖZ

Elektrik enerjisinin iletimi ve dağıtımı, modern toplumların işleyişinde hayati bir rol oynamaktadır. Bu enerjinin güvenli ve kesintisiz bir şekilde taşınması, elektrik sistemlerinin sağlıklı bir şekilde çalışmasıyla mümkün olmaktadır. Ancak, elektrik iletim hatlarındaki kusurlar, sistemde arızalara ve enerji kesintilerine neden olabilmektedir. İzolatör kusurları, elektrik hatlarındaki en yaygın arızalar arasında yer almaktadır. Bu kusurlar, genellikle izolatör yüzeyindeki çatlaklar, kırıklar, erozyon veya kimyasal bozulmalar şeklinde ortaya çıkmaktadır. Son yıllarda, yapay zekâ ve makine öğrenmesi teknikleri, izolatör kusurlarının belirlenmesi için alternatif bir çözüm sunmuştur. Bu alanda transfer öğrenme, özellikle dikkat çeken bir yaklaşım olarak ön plana çıkmaktadır. Bu yaklaşım, izolatör kusurlarının tespitinde kullanılan verilerden öğrenilen bilgilerin, yeni bir izolatördeki kusurların belirlenmesinde kullanılmasına olanak sağlamaktadır. Bu çalışmada izolatör görüntülerinden transfer öğrenme yaklaşımı kullanılarak izolatör türü ve sağlamlık durumu (normal/kusurlu) tespiti yapılmıştır. Bu problemlerin verimli çözümü için Çoklu Öğrenme yaklaşımı dikkate alınmıştır. Bu durumlar literatürde yaygın olarak kullanılan çok sınıflı görüntü veri setlerinde iyi başarımlar gösteren AlexNet, ResNet50 ve GoogLeNet gibi mimarilere giriş olarak uygulanmıştır. İzolatörün sağlamlık durumunun tespitinde en iyi doğruluk oranına % 97.674 ile AlexNet ve ResNe50 mimarilerinde ulaşılmıştır. İzolatör türünün belirlenmesinde en iyi doğruluk oranına % 90.698 ile ResNe50 mimarisinde ulaşılmıştır.

ARTICLE INFO

Article history:

Received 5 January 2024
Received in revised form 19 March 2024
Accepted 1 April 2024
Available online 30 June 2024

Keywords:

*Insulator Defect,
Transfer Learning,
Multi Learning,
CNN.*

Doi: 10.24012/dumf.1415322

* Sorumlu Yazar

ABSTRACT

The transmission and distribution of electrical energy play a vital role in the functioning of modern societies. The safe and uninterrupted transportation of this energy is made possible by the healthy operation of electrical systems. However, defects in electricity transmission lines can cause malfunctions in the system and even power outages. Insulator defects are among the most common defects in power lines. These defects usually occur in the form of cracks, fractures, erosion, or chemical distortions on the insulator surface. In recent years, artificial intelligence and machine learning techniques have provided an alternative solution for the determination of insulator defects. Transfer learning comes to the fore in this field as an approach that attracts particular attention. This approach allows the information learned from the data used in the detection of insulator defects to be used in the determination of defects in a new insulator. In this study, the type of insulator and the state of robustness (normal or defective) were determined using the transfer learning approach from the insulator images. A Multiple Learning approach has been taken into account for the efficient solution of these problems. These cases have been applied as an introduction to architectures such as AlexNet, ResNet50, and GoogLeNet, which show good performance in multi-class image datasets widely used in the literature. The best accuracy rate in determining the stability status of the insulator was reached in the AlexNet and ResNe50 architectures with 97.674%. The best accuracy rate in determining the insulator type was reached in ResNe50 architecture with 90.698%.

Giriş

İzolatörler, elektrik dağıtım ve iletim hatlarında iletkenleri direklerle mekanik olarak sabitleyen ve elektriksel olarak izole eden temel ekipmanlardır [1]. İzolatör arızası, enerji nakil hatlarının sürekliliği ve güvenliği için doğrudan bir tehdittir. İstatistiksel olarak, izolatör kusurlarından kaynaklanan kazalar, güç sistemi arızalarının en yüksek oranını oluşturmaktadır. Güç kaynağındaki uygunluk, enerji şirketlerinin dağıtım şebekelerinde uyguladıkları önleyici ve düzeltici bakım hizmetlerinin kalitesi ile yakından ilişkilidir. Bu faaliyetlerin gerçekleştirilmesi için ilk olarak, arızalı elemanlar (kırık, çatlamış, deforme olmuş, kirlenmiş veya buzlanmış), kötü yerleştirilmiş, eksik veya kayıtlı olmayan bileşenler, sızıntı akımları vb. elektrik hatlarında bulunan uygunsuzluklar aranmalıdır. İzolatörlerdeki arızaların tespiti, bu tür sistemlerin kararsızlığına bağlı elektrik kesintilerini ve ekonomik kayıpları azaltabilir. Ayrıca, bu hatların kentsel yerleşimleri içerdiği göz önüne alındığında, izolatörlerin olası arızalarının tespit edilmesi sadece elektrik kesintilerini önlemek için değil, aynı zamanda bu tür yüksek yoğunluklu alanlarda kamu tehlikesi nedenlerinden dolayı da büyük önem taşımaktadır [2, 3]. Bu nedenle, izolatör kusurlarının yapay zekâ yöntemleri ile zamanında tespit edilmesi önemlidir.

Son yıllarda güç ekipmanlarının denetiminde helikopter ve insansız hava aracı (İHA) gibi hava platformları kullanıma sunulmuş, yüksek verimlilik, doğruluk ve güvenlik gösterdiğinden bu elemanlar önemli bir araç haline gelmişlerdir. Platforma monte edilen bir kamera, izolatör bilgilerini içeren birçok görüntü elde edebilmekte ve izolatör kusurlarının incelenmesi, bu tür hava görüntülerine dayalı olarak gerçekleştirilmektedir [4].

Karmaşık hava görüntülerinde birden fazla izolatörü farklı açılarda konumlandırmak için OAD-BSPK (Oryantasyon açısı algılama ve ikili şekil ön bilgisi) kullanılan birçok çalışma izolatör lokalizasyonuna odaklanmıştır [5]. Bununla birlikte, izolatör şekli hakkında önceden bilgi sahibi olunması gerektiğinden bu yöntem kısıtlayıcıdır ve yalnızca belirli senaryolar altında (örneğin dokusuz arka planlar), gökyüzüne bakan bir kamera ile çalışabilir. Bu nedenle, son derece karmaşık arka planlar için iyi çalışmaz. Park ve ark. [6], izolatörleri tespit etmek için çoklu kamera sensör sistemi kullanmıştır. Yaklaşımları, yalnızca izolatörleri güçlü bir kontrast yoluyla tespit edebilmekte ve uygulanabilirliğini önemli ölçüde sınırlandırmaktadır. Sağlam olmayan yöntemin aksine, Li ve ark. [7] hava görüntülerinde yerel özelliklere ve uzaysal düzene dayalı bir izolatör algılama algoritması önermiştir. Hava görüntülerinde izolatörlerin oranı genellikle çok küçük olduğundan, kusur tespitinde gerekli olmayan ve mümkün olmayan yerleştirme için özel olarak tasarlanmıştır. Mussina ve ark. [8] İHA kullanılarak izolatörlerin potansiyel gerçek zamanlı izlenmesi için yeni bir Füzyon Evrişim Ağı (FCN) önermiştir. FCN, Evrişimsel Sinir Ağı (ESA) ve Çok Katmanlı Sinir Ağı (MNN) alt sınıflandırıcısından oluşmaktadır. Önerilen FCN'nin performansını karşılaştırmak ve kıyaslamak için, Dalgacık

Dönüşümü ve Temel Bileşenler Analizi (PCA) yöntemleri kullanılarak çıkarılan özneliklerin birleştirilmesinde geleneksel sınıflandırma algoritmaları da uygulanmaktadır. Gao ve ark. [9], DVM (Destek Vektör Makinesi) ve WMRA (Dalgacık Çoklu Çözünürlük Analizi)'yı birlikte kullanarak izolatörler için bir durum analiz sistemi önermiştir. DVM sınıflandırıcısı kusur kategorisi bilgilerini sağlayabilmesine rağmen, kusur konumu elde edememiştir. Liu ve ark. [10], RPN'ye (Bölge Öneri Ağı) dayalı bir ESA'nın basamaklı mimarisini kullanmışlar, VGG ve ResNet'i birleştirmişlerdir. Yöntem yeterince hızlı olmadığından gerçek zamanlı incelemede istenmeyen bir durum oluşmaktadır. Hao ve ark. [11], izolatörlerde buzlanma üzerine yapılan çalışmalarda buz türünün önemli bir parametre olduğu düşünülerek kar, kırağı, karışık kırağı, sır ve normal buz türlerini tanımak için zayıf denetimli ve aşamalı transfer öğrenme yöntemi üzerinde durulmuştur. Çalışmanın sadece buz türlerinin morfolojik benzerliklerine odaklanması atlama durumunun tespiti için yetersiz kalmıştır.

Bu çalışmada izolatör kusurlarını tespit etmek için transfer öğrenme tabanlı bir yaklaşım sunulmuştur. Ayrıca çok görevli öğrenme yaklaşımı ile izolatör kusurlarının yanısıra izolatör çeşitleri de tespit edilmeye çalışılmıştır. Böylece eğitilen bir model ile iki sınıflandırma problemi çözülmüştür.

Materyal Metot

Evrişimli Sinir Ağı (ESA)

ESA, bir dizi evrişimli katmandan oluşan ve kendine giriş olarak tanımlanan görüntüleri işleyen bir derin sinir ağı yöntemidir. ESA içerisindeki katmanlar sırasıyla; giriş olarak verilen resmin özelliğini algılar, doğrusal olmayanları belirler, parametrelerin hesaplanma sayısını azaltıp uygunluğunu kontrol eder ve son olarak sınıflandırma işlemini gerçekleştirir [12]. Bu durum Şekil 1' deki gibi ifade edilebilir.



Şekil 1. ESA katmanlarının işleyişi

Evrişimsel katmanların ana görevi, önceki katmanlardan gelen özelliklerin lokal bağlantılarını belirleyip bilgilerini eşleştirmektir. A girişinin X filtresiyle ($X \in \mathbb{R}^{2a_1+2a_2}$) konvolüsyonu aşağıdaki gibi verilmiştir [13].

$$(A * X)_{c,d} = \sum_{k=-a_1}^{a_1} \sum_{l=-a_2}^{a_2} 2X_{k,l} A_{c-k,d-l} \quad (1)$$

Softmax fonksiyonu ESA yapısında, önceki katmanın ham değerlerini tahmin edilen sınıf puanlarına olasılık dağılımıyla eşleştirerek kullanılan yaygın bir fonksiyondur.

$$\gamma(\theta_j) = \frac{e^{\theta_j}}{\sum_{j=1}^N e^{\theta_j}}, \quad j = 1, \dots, N \quad (2)$$

Burada ; $\gamma(\theta_i)$ her bir θ_i softmax çıktısını , θ_i ve θ_j ise girdi vektörünün değerlerini temsil eder.

Yığın normalleştirme katmanı, ESA yapısının eğitim süresini ve ağ başlatma duyarlılığını azaltmak için kullanılan katmandır. Girişi normalleştirilmiş etkenler (θ_i), minimum yığın ortalama (z_q) minimum yığın varyansı (y_q) aşağıdaki gibi hesaplanır :

$$\theta_i' = \frac{\theta_i - z_q}{\sqrt{y_q^2 + C}} \quad (3)$$

Burada C sabittir ve y_q 'nin çok küçük olması sayısal durumu düzenler. z_q ve y_q aşağıdaki gibi hesaplanır.

$$z_q = \frac{1}{n} \sum_{i=1}^n \theta_i \quad (4)$$

$$y_q = \frac{1}{n} \sum_{i=1}^n (\theta_i - z_q)^2 \quad (5)$$

Yığın normalleştirme katmanındaki etkileşimler, kaydırma ve ölçekleme işlemi ile aşağıdaki gibi sonuçlandırılır.

$$\mu_i = v\theta_i' + t \quad (6)$$

Burada v, t sırasıyla denge ve ölçek faktörleridir. Bu faktörler, eğitim sürecinde güncellenen en uygun değerlerdir.

ESA birçok avantaja sahiptir. Bu avantajlar şunlardır [14]:

- Ham görüntülerden herhangi bir işlem gerektirmeden ayıklama özelliğine sahiptir.
- Şekil bozulmalarına karşı direnç sağlar.
- Veri boyutunu azaltır.
- Tek bir ağ yapısında sınıflandırma işlemi gerçekleştirir.

ESA daha çok yüz tanıma uygulamalarında kullanılmış olsa da COVID-19 hastalığının teşhisinde radyolojik görüntüler için kullanılarak oldukça başarılı sonuçlar elde edilmiştir [15,16].

Transfer Öğrenme

Makine öğrenimi ve veri madenciliği teknikleri Dünya üzerinde birçok uygulamada kullanılmıştır. Geleneksel makine öğrenimi metodolojilerinin bir varsayımı, eğitim verilerinin ve test verilerinin aynı alandan alınmasıdır. Böylece girdi özellik alanı ve veri dağıtım özellikleri aynı

olur. Ancak, bazı uygulamalarda makine öğreniminin bu varsayımı geçerli değildir [17]. Bu nedenle, farklı alanlardan daha kolay elde edilen verilerle eğitilmiş yüksek performanslı öğretiler oluşturmaya ihtiyaç vardır. Bu metodolojiye transfer öğrenme denilmektedir. Transfer öğrenme, farklı fakat ilgili kaynak alanlarında bulunan bilgileri transfer ederek hedef öğretilerin hedef alanlardaki performansını iyileştirmeyi amaçlamaktadır. Bu şekilde, hedef öğretiler oluşturmak için çok sayıda hedef alan verisine bağımlılık azaltılabilmektedir.

Transfer öğrenme problemleri üç sınıfa ayrılabilir. Bunlar; transdüktif, endüktif ve denetimsiz transfer öğrenmedir. Bu üç sınıf, etiket belirleme açısından yorumlanabilir. Transdüktif transfer öğrenme, etiket bilgisinin yalnızca kaynak alanından geldiği durumları ifade eder. Hedef etki alanı örneklerinin etiket bilgileri mevcutsa endüktif transfer öğrenimi olarak kategorize edilebilir. Etiket bilgisi hem kaynak hem de hedef etki alanları için bilinmiyorsa, durum denetimsiz transfer öğrenmesi olarak bilinmektedir. Başka bir sınıflandırma, kaynak ve hedef özellik boşlukları ve etiket boşlukları arasındaki tutarlılığa dayanmaktadır [18].

$$\begin{cases} U^a = U^b \\ V^a = V^b \end{cases} \quad (7)$$


Denklemler 7'de; U özellik alanı, V etiket alanı, a kaynak etki alanı ve b hedef etki alanıdır. Buradaki eşitlik homojen transfer öğrenme olarak adlandırılır. Bu eşitliğin olmaması durumu ise heterojen transfer öğrenme olarak bilinmektedir.

AlexNet

Çeşitli ESA mimarileri arasında AlexNet, görüntü sınıflandırmada yaygın olarak kullanılan en verimli mimarilerden biridir. Alex Krizhevsky ve ark. tarafından sunulan mimari 1000 sınıftan oluşan yaklaşık 1,2 milyon görüntüyü ImageNet Large-Scale Visual Recognition Challenge (ILSVRC) yarışmasında en doğru olarak sınıflandırmıştır [19].

Şekil 2'de de görüleceği üzere AlexNet 11 katmandan meydana gelmektedir. İlk iki katmanı evrişim, maksimum havuzlama, normalizasyon, 3. ve 4. katmanlar evrişim, 5. katman evrişim, maksimum havuzlama, 6. ve 7. katmanlar tam bağlı katman ve son katman sınıflandırma işlemi yapan softmax'dır [19].

Evrişim işlemi yapılırken ilk katmanda 11x11 boyutlu 96 filtre kullanılmaktadır. Ağda evrişim işlemi sonucu görüntü boyutu 55x55 olmaktadır. Modeldeki ilk havuzlama katmanında 3x3 boyutlu filtreler kullanılmaktadır. İşlem sonrası görüntü boyutu 27x27 olmaktadır.




Şekil 2. AlexNet mimarisini

ResNet50

ResNet, He Kaiming ve ark. tarafından 2015 yılında ILSVRC yarışmasının kazananı olmuştur. ResNet, bir katmandan diğerine son tahmine ulaşmak için gereken deltayı tahmin eder ve derin ağların eğitimi için etkili bir yöntemdir [20]. ResNet'te kullanılan kimlik eşlemesi, mevcut katman gerekli değilse modelin bir ESA ağırlık katmanını atlamasına izin verir. Bu durum eğitim setine, aşırı uyum sorununun önlenmesinde yardımcı olmaktadır. Aşırı uyum, eğitim doğruluğunun yüksek, test doğruluğunun ise düşük olması durumudur. Derinlik arttıkça ağın en iyi hale getirilmesi zorlaşmaktadır. Bu sorunun üstesinden gelmek amacıyla önerilen artık sinir ağı, bir ağ oluşturmak için artık blokları üst üste istifleyen bir tür yapay sinir ağıdır.

Şekil 3 artık bloğun bir temsilini göstermektedir. Burada a girişi, çıkışa doğrudan eklenir. Kısa yol veya atlama bağlantısı olarak bilinen bu durum $f(x) + x$ olarak verilmiştir.



Şekil 3. Artık blok

GoogleNet

GoogleNet 2014 yılında ILSVRC yarışmasının kazananı olmuştur. GoogleNet mimarisini, AlexNet gibi önceki son teknoloji mimarilerden çok farklıdır. 1×1 evrişim ve daha derin bir mimari oluşturmasını sağlayan küresel ortalama havuzlama gibi birçok farklı yöntem kullanmaktadır. GoogleNet başlangıç modüllerinden dolayı kompleks bir yapıdır. Başlangıç modülü, parametrelerin ölçeğini ve model karmaşıklığını sınırlandırmaya yardımcı olan küçük boyutlu birkaç evrilmiş çekirdekte oluşmaktadır. Buradaki

problem işlem karmaşıklığı, çıkış boyutunun oldukça büyük olması ve parametre sayısının paralel işlemlerden dolayı büyümesidir [21].

Karmaşıklık Matrisi

Sınıflandırma işlemlerinde gerçek veri ile öngörülen değerleri karşılaştırmak amacıyla karmaşıklık matrisinden yararlanılır.

Tablo 1. Karmaşıklık matrisini

		Öngörülen sınıflar		
		S ₁	S ₂	Toplam
Gerçek Sınıflar	S ₁	X	Y	X+Y
	S ₂	Z	T	Z+T
	Toplam	X+Z	Y+T	X+Y+Z+T

İki sınıflı bir model için Tablo 1'de belirtilen tanımlar kullanılmıştır. İki sınıflı bir modelde sınıflardan birinin S₁, diğerinin S₂ olduğu varsayılmaktadır. Uygulamanın türüne göre bu değerler pozitif-negatif, evet-hayır, başarılı-başarısız vb. olarak belirlenmektedir. Tablo 1'deki değerlerin açıklaması aşağıda belirtilmiştir.

X: Gerçek sınıfların S₁ sınıfı ile öngörülen S₁ sınıf değerinin eşit olma sayısını belirlemektedir. Bu değer S₁ sınıfı için başarılı öngörü sayısını ortaya koymaktadır.

Y: Gerçek sınıfların S₁ sınıfına karşılık öngörülen S₂ sayısını vermektedir. Bu değer S₂ sınıfı için başarısız öngörü sayısını belirlemektedir.

Z: Gerçek sınıfların S₂ sınıfına karşılık öngörülen S₁ sınıf değerinin sayısını vermektedir. Bu değer S₁ sınıfı için başarısız öngörü sayısını belirlemektedir.

T: Gerçek sınıfların S₂ sınıfı ile öngörülen S₂ sınıf değerinin eşit olma sayısını vermektedir. Bu değer S₂ sınıfı için başarılı öngörü sayısını ortaya koymaktadır.

Doğruluk Ölçütü – Hata Oranı

Karmaşıklık matrisini elde edildikten sonra sınıflandırma modelinin doğruluk değeri, gerçek değerlerin öngörülen değerle hangi oranda aynı olduğunu ortaya koymaktadır. Doğruluk ölçütü Denklem 8'deki gibi hesaplanmaktadır [22].

$$\text{Doğruluk} = \frac{X + T}{X + Y + Z + T} \quad (8)$$

Doğruluk değeri kullanılarak sınıflandırma modelinin hata oranına Denklem 9'daki gibi ulaşmak mümkündür.

$$\text{Hata oranı} = 1 - \text{Doğruluk} \quad (9)$$

Duyarlılık Ölçütü

Sınıflandırma modeline ilişkin karmaşıklık matrisinin birinci sıradaki sınıfı için öngörme başarısını elde etmek amacıyla kullanılmaktadır. Duyarlılık ölçütü Denklem 10'daki gibi hesaplanmaktadır [22].

$$\text{Duyarlılık} = \frac{X}{X + Y} \quad (10)$$

Denklem 10'dan elde edilen sonuç, normal sınıfının öngörülmesindeki başarıyı ortaya koymaktadır.

Özgüllük Ölçütü

Sınıflandırma modeline ilişkin karmaşıklık matrisinin ikinci sıradaki sınıfı için öngörme başarısını elde etmek amacıyla kullanılmaktadır. Özgüllük ölçütü Denklem 11'deki gibi hesaplanmaktadır [22].

$$\text{Özgüllük} = \frac{T}{T + Z} \quad (11)$$

Denklem 11'den elde edilen sonuç, kusurlu sınıfının öngörülmesindeki başarıyı ortaya koymaktadır.

Kesinlik Ölçütü

Karmaşıklık matrisinde birinci sütunda yer alan sınıfın tahmin başarısı o sınıfa ait tüm gözlemler içindeki payı olarak Denklem 12'deki gibi hesaplanmaktadır [22].

$$\text{Kesinlik} = \frac{X}{X + Z} \quad (12)$$

Denklem 12'den elde edilen sonuç, normal sınıfı için isabetli öngörülere ortaya koymaktadır.

Deneysel Çalışma

Bu çalışmada, transfer öğrenme yaklaşımı kullanılarak izolatör görüntülerinden izolatörün malzeme türü ve sağlık durumu (normal/kusurlu) tespiti yapılmıştır. Bu iki problemin verimli çözümü için Çoklu Öğrenme (ÇÖ) yaklaşımı dikkate alınmıştır. Bu yaklaşım ile belirtilen iki durumun çözümünün tek bir modelle gerçekleştirilmesi amaçlanmıştır. ÇÖ yaklaşımı ile her bir probleme ait modeller karşılaştırılmıştır. Birinci durum (Durum I) izolatörün kusurlu veya normal olduğu durumu, ikinci durum (Durum II) izolatörün hangi malzemeden yapıldığı durumunu ve son durum (Durum III) ise ÇÖ yaklaşımı ile malzeme (silikon, porselen veya cam) ve izolatör durumunu (kusurlu/normal) göstermektedir. Deney veri seti Güney Brezilya'da bulunan Blumenau şehri elektrik şebekesinden çekilmiş görüntülerden elde edilmiş IEEE Data Port internet sitesinden alınmıştır [23]. Üç farklı durumda literatürde yaygın olarak kullanılan, çok sınıflı görüntü setlerinde iyi başarımlar gösteren AlexNet, ResNet50 ve GoogLeNet gibi mimarilere giriş olarak uygulanmıştır. Mimarilerin hiper parametreleri ampirik yolla elde edilmiş ve Tablo 2'de verilmiştir.

Tablo 2. Eğitimde kullanılan hiper parametre bilgileri


Parametre	AlexNet	GoogLeNet	ResNet50
Optimizasyon	sgdm		
En küçük yığın boyutu (minibatch size)	32	8	8
Öğrenme Oranı	1e-4	1e-4	1e-3
Tekrar Sayısı	10	10	10

Deneysel çalışma ÇÖ yaklaşımının performansının belirgin bir şekilde vurgulanması için üç adımda gerçekleştirilmiştir. İlk önce Durum I ele alınmıştır. Durum I'e ilişkin deneysel sonuçlar Tablo 3'te verilmiştir.

Tablo 3. Durum I için performans sonuçları

Durum I	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
AlexNet	97.674	95.455	100.000	100.000
ResNet50	97.674	95.455	100.000	100.000
GoogLeNet	93.023	95.455	90.476	91.304

Tablo 3'te görüldüğü gibi Durum I için AlexNet, ResNet50 ve GoogLeNet için performans sonuçları verilmiştir. AlexNet ve ResNet50 en fazla doğrulukla sınıflandırma yapmıştır. GoogleNet %93.023 oranla diğer iki sınıflandırıcıya göre daha az doğruluk oranına sahiptir. Duyarlılık oranları her üç sınıflandırıcı için aynıdır. Özgüllük ve kesinlik oranı AlexNet ve ResNet50'de % 100'e ulaşmıştır.



Şekil 4. Durum I için karmaşıklık matrisleri


Durum I için karmaşıklık matrisi Şekil 4'te verilmiştir. Şekil 4'ün satırları gerçek sınıfları, sütunları tahmin edilen sınıfları göstermektedir. Şekil 4.(a) ve Şekil 4.(b)'de görüleceği üzere AlexNet ve ResNet50 kusurlu izolatörlerden 21 numuneyi doğru, 1 numuneyi yanlış sınıflandırırken normal izolatörlerin 21 tanesini de doğru sınıflandırmıştır. Numune sayısının az olmasından dolayı yanlış sayısı 1 olmasına rağmen % 97.674 olmuştur. GoogLeNet Şekil 4.(c)' görüleceği gibi diğer iki modelden göre daha fazla hataya sahip olmuştur.

Tablo 4'te görüldüğü gibi Durum II için veriler AlexNet, ResNet50 ve GoogLeNet'te sınıflandırılmıştır.

Tablo 4. Durum II için performans sonuçları

Durum II	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
AlexNet	70.455	65.278	86.257	66.111
ResNet50	75.000	80.556	88.947	73.333
GoogLeNet	70.455	73.611	86.637	67.635

Durum II de, Durum I'e göre doğruluk oranları düşmüştür. ResNet50 % 75 doğruluk oranıyla diğer iki sınıflandırıcıya göre sınıflandırma yapmıştır. ResNet50 'nin duyarlılık, özgüllük ve kesinlik oranları daha iyi sonuç vermiştir.



Şekil 5. Durum II için karmaşıklık matrisleri

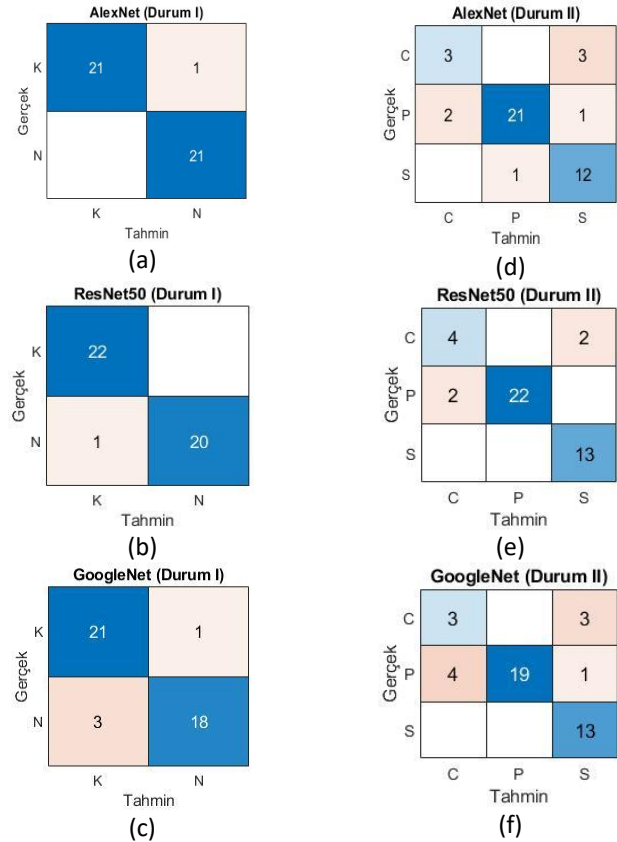
Durum II için karmaşıklık matrisleri Şekil 5'te verilmiştir. 6 adet cam izolatör içinde 5 tanesini doğru tahmin eden ResNet50 en iyi tahmini yapmıştır (Şekil 5.(b)). 24 adet porselen izolatör içinde en iyi tahmini 15 adet ile AlexNet tahmin ederken (Şekil 5.(a)), 13 tahmin ile en az tahmine

GoogLeNet sahip olmuştur (Şekil 5.(c)). Silikon izolatörlerin hepsini tüm sınıflandırıcılar doğru tahmin etmiştir.

Tablo 5. Çoklu Öğrenme yaklaşımıyla performans sonuçları

ÇÖY	Durum	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
AlexNet	I	97.674	95.455	100.000	100.000
	II	83.721	76.603	91.999	76.818
ResNet50	I	97.674	100.000	95.238	95.652
	II	90.698	86.111	95.976	84.444
GoogLeNet	I	90.698	95.455	85.714	87.500
	II	81.395	76.389	91.952	73.109

Tablo 5'te Çoklu Öğrenme yaklaşımı ile Durum I ve Durum II ele alınmıştır. Çoklu Öğrenme yaklaşımında Durum I için duyarlılık oranının yükseldiği ve en başarılı mimarinin ResNet50 olduğu belirlenmiştir. Özgüllük ve kesinlik ölçütünde ise en iyi oranın değişmediği ve en başarılı mimarinin AlexNet olduğu görülmüştür. Çoklu Öğrenme yaklaşımında Durum II için duyarlılık, özgüllük ve kesinlik ölçütlerinin oranının Durum I'e göre daha iyileştirildiği ve en iyi sonuçlara ResNet50 mimarisinde ulaşıldığı sonucuna varılmıştır.



Şekil 6. Çoklu Öğrenme yaklaşımıyla karmaşıklık matrisleri

Şekil 6'da Çoklu Öğrenme yaklaşımıyla karmaşıklık matrisleri verilmiştir. Çoklu Öğrenme yaklaşımı ile Durum I'de çok farklılık olmazken, Durum II'de iyileşmeler olmuştur. Durum II'de en fazla tahmin hatası cam izolatörde iken Çoklu Öğrenme yaklaşımıyla beraber 24 adet izolatörden 2 izolatörün tahmininde yanlışlık olup en iyi tahmin ResNet50 ile gerçekleştirilmiştir (Şekil 6.(e)).

Tablo 6'da çoklu öğrenme yaklaşımıyla sınıflandırıcıların doğruluk tablosu verilmiştir. Durum I'in doğruluk oranı Durum II'ye göre daha yüksektir. Çoklu öğrenme yaklaşımıyla Durum II'nin doğruluk oranı yükselmiştir. Bu farkın ResNet50 mimarisinde %75'ten %90.698'e yükselmesi belirgin bir şekilde görülmektedir

Tablo 6. Çoklu Öğrenme yaklaşımıyla sınıflandırıcıların doğruluk tablosu

	Durum I	Durum II	ÇÖY	
			ÇÖY - Durum I	ÇÖY - Durum II
Mimari	Doğruluk (%)			
AlexNet	97.674	70.455	97.674	83.721
ResNet50	97.674	75.000	97.674	90.698
GoogLeNet	93.023	70.455	90.698	81.395

Kaynakça

- [1] L. Li, W. Jin, and Y. Huang, "Few-shot contrastive learning for image classification and its application to insulator identification," *Applied Intelligence*, vol. 52, no. 6, pp. 6148–6163, Sep. 2021, doi: 10.1007/s10489-021-02769-6.
- [2] X. Miao, X. Liu, J. Chen, S. Zhuang, J. Fan, and H. Jiang, "Insulator Detection in Aerial Images for Transmission Line Inspection Using Single Shot Multibox Detector," *IEEE Access*, vol. 7, pp. 9945–9956, 2019, doi: 10.1109/access.2019.2891123.
- [3] R. M. Prates, R. Cruz, A. P. Marotta, R. P. Ramos, E. F. Simas Filho, and J. S. Cardoso, "Insulator visual non-conformity detection in overhead power distribution lines using deep learning," *Computers & Electrical Engineering*, vol. 78, pp. 343–355, Sep. 2019, doi: 10.1016/j.compeleceng.2019.08.001.
- [4] R. Miller, F. Abbasi, and J. Mohammadpour, "Power line robotic device for overhead line inspection and maintenance," *Industrial Robot: An International Journal*, vol. 44, no. 1, pp. 75–84, Jan. 2017, doi: 10.1108/ir-06-2016-0165.
- [5] M. W. Adou, H. Xu and G. Chen, "Insulator Faults Detection Based on Deep Learning," *2019 IEEE 13th International Conference on Anti-counterfeiting, Security, and Identification (ASID)*, Xiamen, China, 2019, pp. 173-177, doi: 10.1109/ICASID.2019.8925094.
- [6] J. Park et al., "Vehicular Multi-Camera Sensor System for Automated Visual Inspection of Electric Power Distribution Equipment," *2019 IEEE/RSJ*

Sonuç

İzolatörlerin bütünlüğünün değerlendirilmesi, elektrik iletim hatlarının güvenli çalışmasını sağlamak için oldukça önemlidir. Bu çalışmada, transfer öğrenme yaklaşımı kullanılarak, izolatör görüntülerinden izolatör tipi ayırt edilmiş ve izolatörlerin kusurları belirlenmiştir. İzolator tipinin ve kusurların belirlenmesinde çoklu öğrenme yaklaşımı ile üç ana sınıflandırma görevi göz önünde bulundurulmuştur. AlexNet, ResNet50 ve GoogLeNet mimarilerine izolator görüntüleri giriş olarak uygulanmıştır. Durum I için AlexNet % 97.674, ResNet50 % 97.674 ve GoogLeNet ile %93.023 doğruluk oranlarına ulaşılmıştır. Durum II için AlexNet % 70.455, ResNet50 % 75 ve GoogLeNet ile %70.455 doğruluk oranlarına ulaşılmıştır. Durum I için başarımlar oranları daha yüksektir. Çoklu öğrenme yaklaşımıyla Durum II için doğruluk oranlarının AlexNet ile % 83.721, ResNet50 ile % 90.698 ve GoogLeNet ile %81.395 olduğu sonucuna ulaşılmıştır. Elde edilen sonuçlar, çoklu öğrenme yaklaşımının düşük doğruluk oranlarını yükselttiğini ve önerilen yöntemin bu sınıflama türünde verimli olduğunu göstermektedir.

International Conference on Intelligent Robots and Systems (IROS), Macau, China, 2019, pp. 281-288, doi: 10.1109/IROS40897.2019.8968085.

- [7] X. Li, H. Su, and G. Liu, "Insulator Defect Recognition Based on Global Detection and Local Segmentation," *IEEE Access*, vol. 8, pp. 59934–59946, 2020, doi: 10.1109/access.2020.2982288.
- [8] D. Mussina, A. Irmanova, P. K. Jamwal, and M. Bagheri, "Multi-Modal Data Fusion Using Deep Neural Network for Condition Monitoring of High Voltage Insulator," *IEEE Access*, vol. 8, pp. 184486–184496, 2020, doi: 10.1109/access.2020.3027825.
- [9] Y. Gao, L. Gao and X. Li, "A New Semi-Supervised Deep Learning Approach for Intelligent Defects Recognition," *2020 IEEE International Conference on Networking, Sensing and Control (ICNSC)*, Nanjing, China, 2020, pp. 1-4, doi: 10.1109/ICNSC48988.2020.9238100.
- [10] J. Liu, C. Liu, Y. Wu, H. Xu, and Z. Sun, "An Improved Method Based on Deep Learning for Insulator Fault Detection in Diverse Aerial Images," *Energies*, vol. 14, no. 14, p. 4365, Jul. 2021, doi: 10.3390/en14144365.
- [11] Y. Hao, W. Liang, L. Yang, J. He, and J. Wu, "Methods of image recognition of overhead power line insulators and ice types based on deep weakly-supervised and transfer learning," *IET Generation, Transmission & Distribution*, vol. 16, no. 11, pp. 2140–2153, Feb. 2022, doi: 10.1049/gtd2.12428.

- [12] S. Albawi, T. A. Mohammed and S. Al-Zawi, "Understanding of a convolutional neural network," *2017 International Conference on Engineering and Technology (ICET)*, Antalya, Turkey, 2017, pp. 1-6, doi: 10.1109/ICEngTechnol.2017.8308186.
- [13] F. Demir, D. A. Abdullah, and A. Sengur, "A New Deep CNN Model for Environmental Sound Classification," *IEEE Access*, vol. 8, pp. 66529–66537, 2020, doi: 10.1109/access.2020.2984903.
- [14] S. S. Liew, M. Khalil-Hani, S. Ahmad Radzi, and R. Bakhteri, "Gender classification: a convolutional neural network approach," *Turkish Journal of Electrical Engineering & Computer Sciences*, vol. 24, pp. 1248–1264, 2016, doi: 10.3906/elk-1311-58.
- [15] Li et al., "Facial Expression Recognition with Faster R-CNN," *Procedia Computer Science*, vol. 107, pp. 135–140, 2017, doi: 10.1016/j.procs.2017.03.069.
- [16] X. Fan, X. Feng, Y. Dong, and H. Hou, "COVID-19 CT image recognition algorithm based on transformer and CNN," *Displays*, vol. 72, p. 102150, Apr. 2022, doi: 10.1016/j.displa.2022.102150.
- [17] K. Weiss, T. M. Khoshgoftaar, and D. Wang, "A survey of transfer learning," *Journal of Big Data*, vol. 3, no. 1, May 2016, doi: 10.1186/s40537-016-0043-6.
- [18] F. Zhuang et al., "A Comprehensive Survey on Transfer Learning," in *Proceedings of the IEEE*, vol. 109, no. 1, pp.43-76, Jan.2021, doi: 10.1109/JPROC.2020.3004555.
- [19] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [20] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
- [21] M. Özküçük, Ö. F. Alçin, and M. Gençoğlu, "EMG Sinyalleri Kullanılarak GoogLeNet ve Çok Seviyeli DPD ile El Tutma Hareketlerinin Sınıflandırılması," *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 34, no. 1, pp. 33–43, Mar. 2022, doi: 10.35234/fumbd.932585.
- [22] S. Siuly et al., "A New Framework for Automatic Detection of Patients With Mild Cognitive Impairment Using Resting-State EEG Signals," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, no. 9, pp. 1966-1976, Sept. 2020, doi: 10.1109/TNSRE.2020.3013429.
- [23] Stéfano Stefenon, December 10, 2021, "Inspection of Electrical Power Distribution Grid (South of Brazil)", IEEE Dataport, doi: <https://dx.doi.org/10.21227/pvzk-c971>.