



## Katener Sistemlerindeki İzolatör Kusurlarının Derin Öğrenme ile Tespiti

Gülşah KARADUMAN<sup>\*</sup>, Erhan AKIN, Berkan BİNAY, Miraç DİLEKLİ

Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye

\*gkaraduman@firat.edu.tr

(Alınış/Received: 10.05.2022, Kabul/Accepted: 22.06.2022, Yayımlama/Published: 31.07.2022)

**Öz:** İzolatörler elektrikli demiryolu hatlarında katener sistemlerin en önemli bileşenleridir. İzolatörlerde meydana gelen kırıklar veya yanmalar ulaşımda kesintilere neden olmaktadır. Bu kesintiler de özellikle yüksek hızlı ray hatlarında güvenli çalışmayı engeller. İzolatörlerdeki arızaların erken bir aşamada tespit edilmesi katener sistemlerine en uygun zamanda müdahale etmeyi ve izolatör kaynaklı kazaları engellemeyi sağlayacaktır. Bu makalede katener sistemlerindeki izolatörleri arızalı ya da sağlam olarak sınıflandırmak için derin öğrenme tabanlı bir yöntem önerilmektedir. Çalışmada 1100 adet izolatör görüntüsü içeren bir veri seti kullanılmıştır. Bu veri setindeki görüntüler ResNet34 derin öğrenme mimarisi ile eğitilmiş ve test edilmiştir. Önerilen mimari ile izolatörlerdeki arızalar %95,7 doğruluk, %99 kesinlik ve %96,6 duyarlılık değerleriyle sınıflandırılmıştır. Bu değerler gerçekleştirilen çalışmanın katener sistemlerindeki izolatörlerdeki arıza tespiti için güvenilir bir yöntem olduğunu göstermektedir.

**Anahtar kelimeler:** Katener, İzolatör, Derin öğrenme, Sınıflandırma, ResNet34

### Detection of Insulator Faults in Catenary Systems with Deep Learning

**Abstract:** Insulators are the most important components of catenary systems in electrified railway lines. Fractures or burns in insulators cause interruptions in transportation. These interruptions also prevent safe operation, especially on high-speed rail lines. Detecting faults in insulators at an early stage will enable to intervene in catenary systems at the most appropriate time and prevent insulator-related accidents. In this article, a deep learning-based method is proposed to classify insulators in catenary systems as faulty or intact. A data set containing 1100 insulator images was used in the study. The images in this dataset are trained and tested with the ResNet34 deep learning architecture. With the proposed architecture, faults in insulators are classified with 95,7% accuracy, 99% precision and 96,6% recall values. These values show that the performed study is a reliable method for fault detection in insulators in catenary systems.

**Keywords:** Catenary, Insulator, Deep learning, Classification, ResNet34

## 1. Giriş

Raylı sistemlerde izolatörler, yüksek hızlı demiryollarındaki katenerlerin temel bileşenlerini oluşturmaktadırlar. İzolatörlerde meydana gelen arızalar yüksek hızlı trenlerin güvenli çalışmasını etkileyebilir hatta durdurabilir. Bu sebeple izolatörlerdeki kusurların tespit edilmesi güvenli ve konforlu bir seyahat için oldukça önemlidir. Düzenli olarak kontrol edilmeyen ve arızaların tespiti yapılmayan sistemlerde sistem çabuk bozulur, arızalanır ve hem maddi açıdan zarar verirken hem de kamu güvenliğini fazlasıyla tehdit etmektedir. Bu arızaların tespiti bazen insan gözüyle tespit edilemezken önceden eğitilmiş makineler bu olasılığı fazlasıyla düşürmektedir. Bunun en büyük örneği gece karanlığında bu arızalar insan gözüyle görülmeyecek boyutlarda olup herhangi bir hasar, aşınma, voltaj hataları tespit edilemez. Yüksek çözünürlüklü kameralar ile alınan görüntüler önceden eğitilen sistemlere gönderilerek gece karanlığında bile bu hatalar yakalanabilmekte ve tespit edilebilmektedir, sistem tarafından tanınan bu hatalar bir ara yüz ile kullanıcının bilgisine anlık sunulabilmektedir [1]. Mevsimlerin bile bu elektrik sistemlerinin üzerinde etkisi varken, zorlu mevsim koşulları altında temassızlık sorunları, genleşme ve büzülme sorunları da düzeltilmediği takdirde taşıta ve yolculara ciddi hasarlar

Atıf için/Cite as: G. Karaduman, E. Akın, B. Binay, M. Dilekli, " Katener sistemlerindeki izolatör kusurlarının derin öğrenme ile tespiti," *Demiryolu Mühendisliği*, no. 16, pp. 185-195, July. 2022. doi: 10.47072/demiryolu.1114665

verirken kamu güvenliğine büyük ölçüde zarar verir. Son yıllarda bunların önüne geçmek amacıyla katener sistemlerinin arızalarının tespiti için birçok yazılım ve donanım sistemi geliştirilmiştir. Özellikle demiryolu ekipmanlarının eksikliklerinin ve bu ekipmanlardaki kusurların tespiti için derin öğrenme uygulamaları oldukça yaygın olarak kullanılmaktadır [13].

Mekanik gücü yüksek olan ve temizlemeye pek ihtiyaç duymayan izolatörler katener sistemlerde hava hattını taşımaya ve topraklamaya yaramaktadır. Bazı yapılarda rüzgâr ve yağmur ile kendini temizleyebilen izolatörler cam, kauçuk gibi malzemelerden yapılmaktadır. Şekil 1’de bir seramik izolatör gösterilmektedir. İzolatörler elektrik akımını iyi iletmelidir ve herhangi bir akım kaçağı, kırılma, hasar görme, aşınma gibi sorunlarla karşı karşıya kalmamalıdır.



Şekil 1. Seramik izolatör [2]


Tan vd. [1] izolatörlerdeki arızaları tespit edebilmek için saçaklı kontür özneliklerine ve gri benzerlik eşleşmesine dayalı bir füzyon algoritması önermişlerdir. Kontür çıkarma ile her bir izolatör diskini ayrı ayrı elde etmişlerdir. Disklerin aralarındaki boşlukların mesafesine ve gri parlaklık benzerliğine dayanan bir izolatör hata tespit modeli oluşturmuşlardır. %91,71 oranında bir kesinlik ve %99,5 duyarlılık ile izolatörleri sınıflandırmışlardır. Han vd. [3] katener sistemindeki izolatörlerdeki kusurları otomatik olarak tespit edebilmek için bir bilgisayarlı görü algoritması geliştirmişlerdir. Geliştirdikleri algoritma iki aşamadan oluşmaktadır. Birinci aşamada izolatörleri tespit etmektedirler. İkinci aşamada ise izolatörlerdeki kusurları tespit etmektedirler. İzolatörlerdeki kusurların tespiti için bir yerel yoğunluk periyodu tahmin algoritması tasarlamışlardır. Deneysel sonuçlarda geliştirdikleri algoritmanın seramik disklerin kırılmasını ve iki disk arasına sıkışan yabancı cisimleri algıladığını raporlamışlardır. Fan vd. [5] otomatik bir izolatör kusur tespit yöntemi önermişlerdir. Önerdikleri yöntemde ilk olarak Rastgele Orman sınıflandırma yöntemi ile izolatör görüntülerini bölütlemişlerdir. Daha sonra, izolatörlerin normal ve kusurlu durumlarını sınıflandırmak için bir Konvolüsyonel Sinir ağı mimarisi kullanmışlardır. Geliştirdikleri mimari için deneysel veri seti olarak kullandıkları görüntüleri bir insansız hava aracı ile elde etmişlerdir. Geliştirdikleri mimari izolatör kusurlarını %89 doğrulukla tanımıştır. Mehlomakulu vd. [6] katener sistemlerinde izolatör arızalarını tespit etmek için drone denetiminde optik ve termal görüntüler elde eden ve bu görüntüleri birleştiren bir yöntem önermişlerdir. Önerdikleri yöntemde kendi tasarladıkları bir evrimsel sinir ağı modeli ile önceden eğitilmiş VGG16 ve ResNet50 modelleri arasında bir karşılaştırma yapmışlardır. Elde ettikleri sonuçlarda VGG16 modelinin diğer modellere göre görüntüleri daha doğru tanıdığını görmüşlerdir. Wen vd. [7] izolatör defektlerinin tespit edilmesi için tam bölge tabanlı ve kaskad maske çıkarma tabanlı olmak üzere iki derin öğrenme mimarisi önermişlerdir. İlk olarak özellik piramit ağı, kademeli regresyon ve birleşim üzerinden geliştirilmiş kesişim dâhil olmak üzere bir dizi gelişmiş tekniğe dayalı bir R-CNN mimarisi önermişlerdir. Önerdikleri modelde önce bir kodlayıcı-kod çözücü maske çıkarma ağı kullanarak karmaşık arka planı ortadan kaldırmak için bir izolatör maske görüntüsü oluşturmuşlardır ve daha sonra izolatörlerdeki kusurları tespit etmek için tam bölge tabanlı bir CNN ağı önermişlerdir. Sampedro vd. [8] izolatör kusurlarını tespit etmek için izolatördeki disk dizilerinin segmentasyonundan sorumlu bir bileşeni ve teşhisinden sorumlu iki bileşeni birleştiren bir yöntem önermektedirler. İzolatör disk dizilerinin bölümlenme bileşeni, CNN mimarisinin belirli seviyelerinde yeni atlama bağlantılarını kullanarak

U-Net ağının yeteneklerini geliştirerek Up-Net olarak adlandırdıkları yeni bir evrişimli ağ mimarisinden oluşmaktadır. Önerdikleri Up-Net varyantlarının yeteneklerini izolatör dizi elemanlarının doğru segmentasyonunu sağlayarak, veri büyütme ve transfer öğrenme tekniklerini uygulayarak arttırmışlardır. İzolatör dizisi teşhisi ile ilgili olarak, izolatör dizisi bölümlene bileşeni tarafından üretilen maskeyi girdi olarak alan ve değişken sayıda diskin yokluğunu belirleme yeteneğine sahip bir evrişimsel sinir ağı (CNN) tasarlamışlardır. İzolatörlerin kirlenmeleri de elektrik iletimini kesintiye uğratabilmektedir. Corso vd. [9] izolatörlerdeki kirlilik seviyelerini görüntüden sınıflandırmak için k-en yakın komşu algoritmasının kullanılmasını önermişlerdir. Ortalama, varyans, asimetri, basıklık, enerji ve entropi gibi bilgisayarlı görme özelliklerini k-NN'yi eğitmek için kullanmışlardır. k-NN, k-kat çapraz doğrulama yöntemini kullanarak %85.17'ye kadar doğruluk elde etmişlerdir. Liu vd. [10] karmaşık bir arka plana sahip hava görüntülerinde izolatör arızalarının tespiti için Sadece Bir Kez Bakarsınız (YOLO) temelli modifiye edilmiş bir model önermişlerdir. İlk olarak, farklı sahnelerde bir veya birden fazla arızaya sahip hava görüntülerini toplamışlardır ve ardından yeni bir veri seti oluşturmuşlardır. İkinci olarak, düşük çözünürlüklü öznetelik katmanlarında özneteliğin yeniden kullanımını ve yayılmasını artırmak için, YOLO-v3 ve Çapraz Aşamalı Kısmi Ağa dayalı bir Çapraz Aşama Kısmi Yoğun YOLO (CSPD-YOLO) modeli önermişlerdir. Özellik piramidi ağı ve geliştirilmiş kayıp işlevini, izolatör arıza tespitinin doğruluğunu artırmak için CSPD-YOLO modeline uyarlamışlardır. Li vd. [11] izolatör disklerini bölümlenmek için doğru olmayan konumlandırma, düşük tanıma verimliliği ve karmaşık arka planda yalıtkan görüntünün zor bölümlenmesi problemlerini çözmeyi amaçlayan dinamik maske kullanan bir kızılötesi izolatör görüntü bölümlenme algoritması önermişlerdir. Önerdikleri algoritmada kızılötesi görüntüdeki izolatörleri dikdörtgen bir çerçeve ile işaretleyerek izolatör dizisinin genel bölümlenmesini gerçekleştirmişlerdir. Elde ettikleri deneysel sonuçlarda, önerdikleri algoritmanın çok sayıda kızılötesi görüntüyü eğitmek için ResNet-101-FPN omurgasını ve 3x eğitim planını kullandığını, bu da izolatörlerin doğru tanımlanmasını ve yüksek hassasiyetli segmentasyonunu gerçekleştirebildiğini göstermişlerdir. Zhao vd. [12] İkili Sağlam Değişmez Ölçeklenebilir Anahtar Noktalara ve Yerel olarak Birleştirilmiş Tanımlayıcıların Vektörüne dayanan izolatör dizilerinin tespiti için kızılötesi görüntü kullanan bir yöntem önermişlerdir. Önerdikleri yöntemde kullandıkları özellik çıkarma yöntemini Binary Feature Pooling olarak adlandırmışlardır. Destek Vektör Makinesine (SVM) dayalı bir sınıflandırma modelini, kızılötesi görüntüde izolatör dizisini bulmak için çok ölçekli sürgülü pencere çerçevesine entegre etmişlerdir. Li vd. [14] izolatör kusurlarının tespiti için derin öğrenme ve Zernike moment algoritmalarını birleştiren bir yöntem önermişlerdir. İzolatörleri tanımak için R-CNN algoritması kullanmışlardır. İzolatörlerin kontur özelliklerini çıkarmak için de Zernike moment algoritmasını kullanmışlardır. Han vd. [15] izolatörlerdeki kırılmaları tespit etmek için YOLOv5'e dayalı bir yöntem önermişlerdir. Geliştirilmiş YOLOv5 algoritması ile ortalama kesinlik değerini %95.02 olarak elde etmişlerdir.

Bu çalışmada katener sistemlerinin sağlıklı çalışması için izolatörlerdeki kusurların tespitlerine odaklanılmıştır. Katener sistemlerdeki izolatörlerdeki kırıkların tespit edilmesi için hazır bir veri seti kullanılmıştır. Veri seti iki sınıftan oluşmaktadır: kırık, sağlam. Veri setinden alınan izolatör görüntülerine segmentasyon uygulanarak izolatörler arka plandan ayrılmış ve izolatördeki disk görüntüleri elde edilmiştir. Disk görüntülerinin siyah beyaz görüntüleri elde edilerek her bir diskin sınırı belirlenmiştir. Sınırları belirlenen diskler ile beyaz piksel yoğunluklarından yola çıkılarak izolatör görüntüsündeki disk sayıları elde edilmiştir. Her bir disk görüntüsü orijinal görüntü ismine ek olarak yeniden adlandırılmış ve siyah beyaz disk görüntülerinden oluşan yeni bir veri seti oluşturulmuştur. Bu veri seti ResNet34 derin öğrenme mimarisi kullanılarak sınıflandırılmıştır. Her görüntüye ait disk görüntülerinin ResNet34 mimarisinden elde edilen sınıf değerlerinden herhangi biri "Kırık" sınıfına ait ise orijinal görüntü "Kırık" olarak sınıflandırılmıştır. Tüm disklerin "Sağlam" sınıfına ait olması durumunda da orijinal görüntü "Sağlam" olarak değerlendirilmektedir. Deneysel çalışmalar sonucunda izolatörlerdeki arızalar %95,7 doğruluk, %99 kesinlik ve %96,6 duyarlılık değerleriyle sınıflandırılmıştır. Bu değerler literatürdeki değerlere oranla daha iyidir.

## 2. Metot

Katener sistemler elektrikli trenlere hareket etmeleri için gerekli gücü sağlamaktadırlar. Elektrikli trenlerin güvenli bir şekilde çalışması için katener sisteminin tüm bileşenleri sağlıklı olmalıdır. Bu makalede de katener sisteminin en önemli bileşenlerinden biri olan izolatörlerdeki arızaları sınıflandırmak için bir yöntem önerilmektedir. Önerilen yöntemin blok diyagramı Şekil 2’de verilmektedir.



Şekil 2. Önerilen yöntemin blok diyagramı

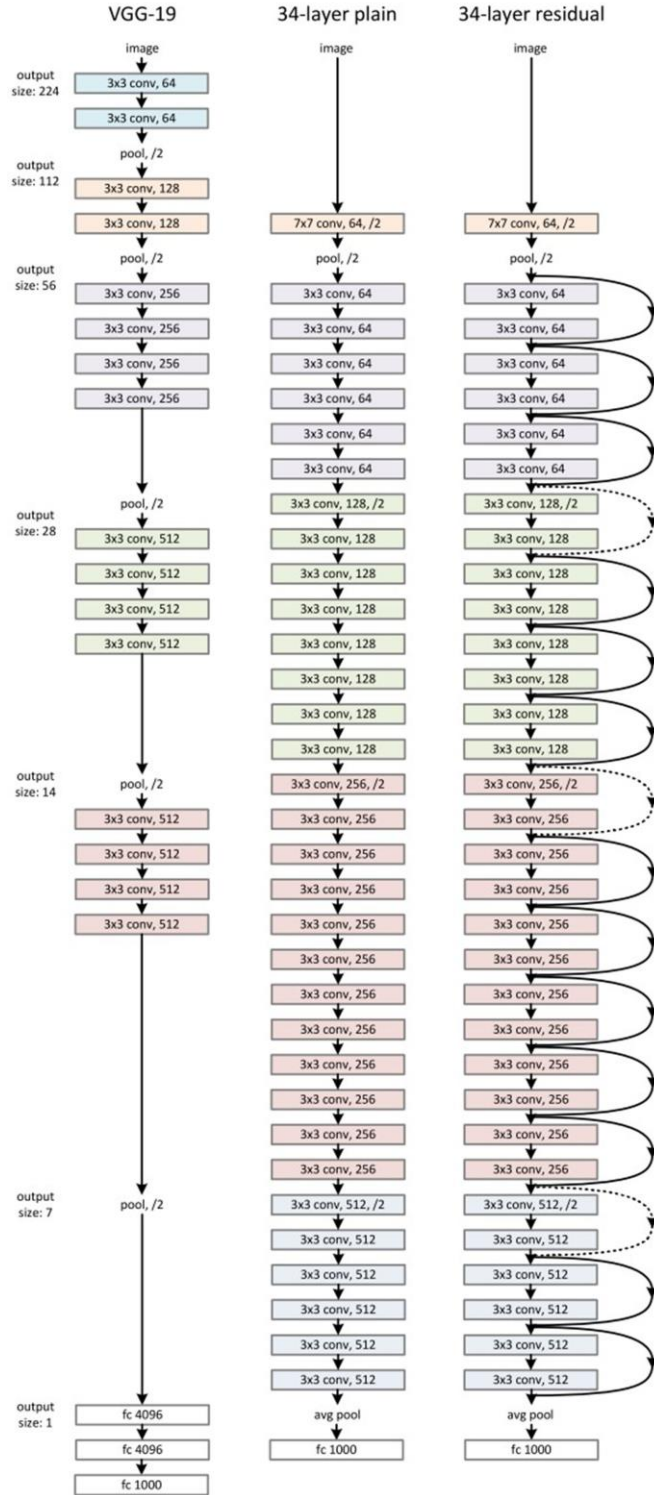
Bu çalışmada yaklaşık 1100 adet görüntü eğitim verisi olarak kullanılmıştır. Görüntüler app.labelbox sitesinden elde edilmiştir. Yaklaşık 1100 görüntü arasında çeşitli uzaklıklarda, kırık, sağlam, hasar görmüş şeklinde izolatör örnekleri bulunmaktadır. Görüntülerden kırık, hasar görmüş ve eksik diskli görüntüler KIRIK sınıfına aittir. Veri setinde toplam 855 görüntü SAĞLAM sınıfına, 245 görüntü de KIRIK sınıfına aittir. KIRIK sınıfı önerilen yöntemde 0 olarak, SAĞLAM sınıfı da 1 olarak gösterilmektedir. 3 disk halinde ve seramikten olan bu izolatörler çeşitli boyutlarda ve renklerde. Bu çalışmada hedef resim formatında verilen bir izolatörü tanımak, algılamak ve algılanan bu izolatörün kırık veya sağlam olup olmadığını tespit etmektir. Önerilen yöntemde öncelikle girdi olarak alınan görüntünün bir izolatör olup olmadığı kontrol edilmekte ve daha sonra kaç diskin hasarlı olup olmadığı kontrol edilmektedir. Veri setinden elde edilen görüntüler K-means kümeleme algoritması kullanılarak segmentasyon işlemi gerçekleştirilmektedir. Kullanılan K-means algoritmasının adımları aşağıdaki gibidir:

- Görüntüyü siyah-beyaz görüntüye dönüştür
- K adet küme merkezi rastgele belirlenir ( $c_1, c_2, \dots, c_k$ )
- Görüntüdeki her beyaz piksel( $p$ ) için en yakın  $c_i$  kümesi bulunur ve  $p, c_i$  kümesine atanır. Bu atama işlemi için Denklem 1. deki formül kullanılır:

$$K = \sum_{c_i} \sum_{p \in C_i} \|p_j - c_i\| \quad (1)$$

- Kümelerin yeni merkezleri hesaplanır ( $c_j$ )
- Eğer küme merkezi değişirse 2. Adıma gidilir.

Segmentasyon işlemleri tamamlandıktan sonra beyaz piksellerin oluşturdukları alanlar Canny kenar çıkarım algoritması ile belirlendi.



Şekil 3. ResNet34 mimarisi [3]

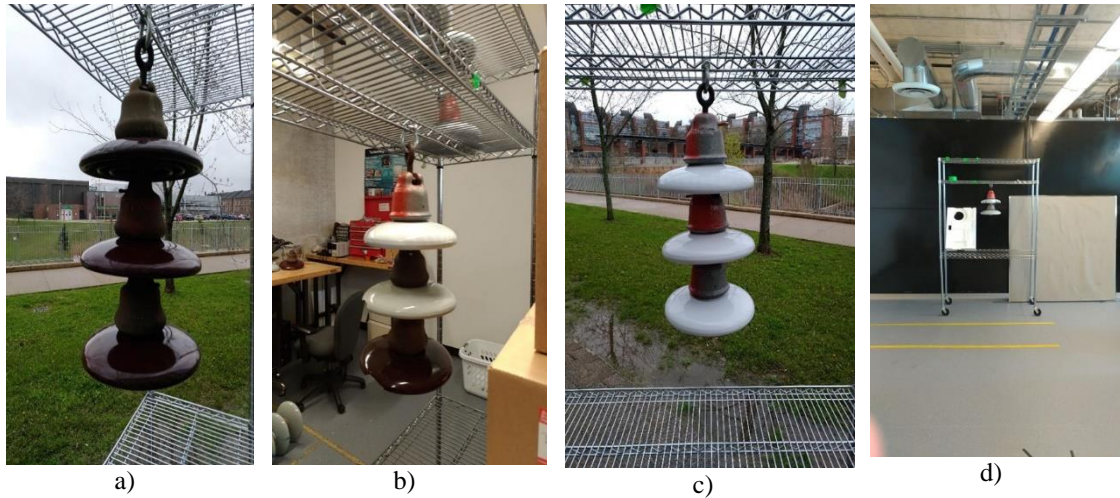
Daha sonra sınırları belirlenen her bir alan sayılarak görüntüde kaç disk olduğu belirlenmiştir. Belirlenen disk sayısı ve beyaz piksel yoğunluğunun olduğu alanlar referans alınarak görüntü disk sayısı kadar bölündü. Böylece her disk ayrı bir görüntü olarak kaydedildi. Disk görüntülerinin hangi orijinal görüntüye ait olduğu belli olacak şekilde adlandırma yapıldı. Örneğin “G1.jpg” görüntüsüne ait birinci disk görüntüsü “G1-D1” şeklinde kaydedildi. Bu şekilde veri seti disk

görüntülerinden oluşacak şekilde güncellendi. Veri setindeki görüntüleri sınıflandırmak için ResNet34 mimarisi kullanıldı.

Görüntü tanıma amacıyla derin öğrenme içeren bu mimari yapay sinir ağlarının eğitimi için kullanılır ve derin ağların eğitimi açısından referansız eğitim yerine referanslı eğitimi baz almaktadır. Düşük karmaşıklığa sahiptir ancak diğer ağlardan kat ve kat daha fazla eğitim verisi ve girdisi içerir. Yaklaşık 150 katmana kadar derinliğe sahip ağların eğitimi için sıklıkla kullanılan bir mimaridir. Hata payı %3'lük bir seviyeye kadar inen bu mimaride yüzlerce katmanlı ağlarda analiz yapmayı da bize sunmaktadır. Kısacası önceden eğitilmiş modeller referans olarak yeni modellerin eğitimi için kullanılır. Şekil 3'te ResNet34 mimarisinin blok diyagramı gösterilmektedir. ResNet34 mimarisinin çıktısı olarak disklerin "Sağlam" veya "Kırık" sınıflarından hangisine ait oldukları elde edilmektedir. Her bir orijinal görüntünün tüm disk görüntülerinin sonuçları ele alınmaktadır. Eğer disk sınıflarından biri bile "Kırık" sınıfına ait ise o görüntüdeki izolatör arızalı olarak değerlendirilmektedir.

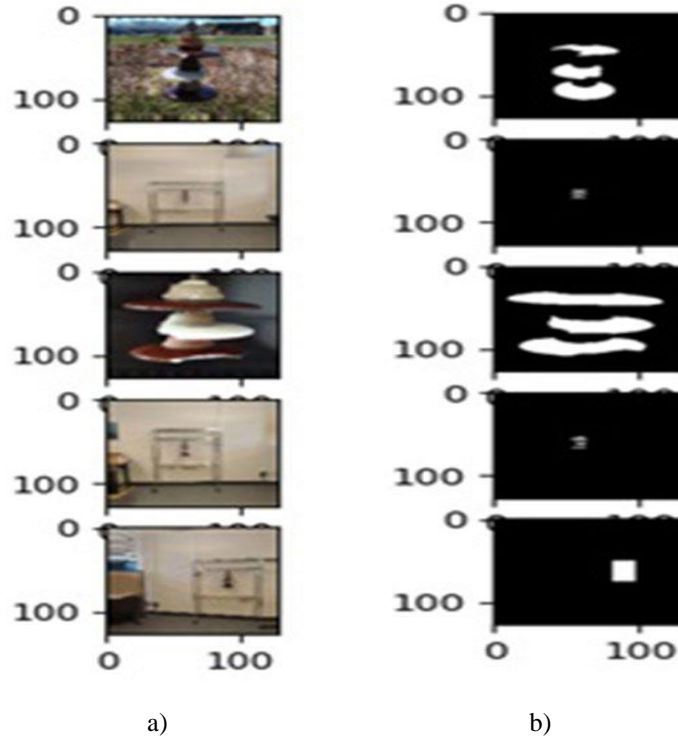
### 3. Bulgular

1100 adet eksik, farklı renklerde, kırık ve sağlam izolatör görüntülerinden oluşan bir veri setindeki görüntüler bir derin öğrenme mimarisi ile sınıflandırıldı. Şekil 4'te veri setine ait bazı görüntüler verilmektedir.




**Şekil 4.** Veri setindeki bazı görüntü örnekleri a) Tek renk sağlam seramik izolatör b) Farklı renklerde kırık ve sağlam diskli izolatör c) Tek renk sağlam seramik izolatör d) Eksik diskli izolatör

Veri setindeki görüntülere K-means kümeleme algoritması kullanılarak segmentasyon işlemi uygulanmıştır. Bazı görüntülere segmentasyon uygulandıktan sonraki görseller Şekil 5'te gösterilmektedir. Segmentasyon işleminden sonra her bir diskin ayrı ayrı değerlendirilmesi ve daha sağlıklı sonuç elde edilmesi için bölütlenmiş görüntülerde kaç adet disk olduğu bulunmuştur. Siyah beyaz görüntülere Canny kenar çıkarma algoritması uygulandı. Canny kenar çıkarması ile beyaz piksellerle gösterilen disklerin sınırları belirlendi. Bu belirlenen sınırlar ve bölütlenmiş görüntülerdeki her bir beyaz piksel yoğunluğu içeren alanlar referans alınarak her bir görüntü kaç adet disk olduğu bulunmuştur. Disk sayısına göre her bir görüntü alt görüntülere ayrılmıştır. Alt görüntüler ayrılan bazı orijinal görüntü örnekleri Şekil 6'da gösterilmektedir.



Şekil 5. Segmentasyon uygulanmış bazı görüntüler a) Orijinal görüntüler b) Segmentasyon uygulanmış görüntüler

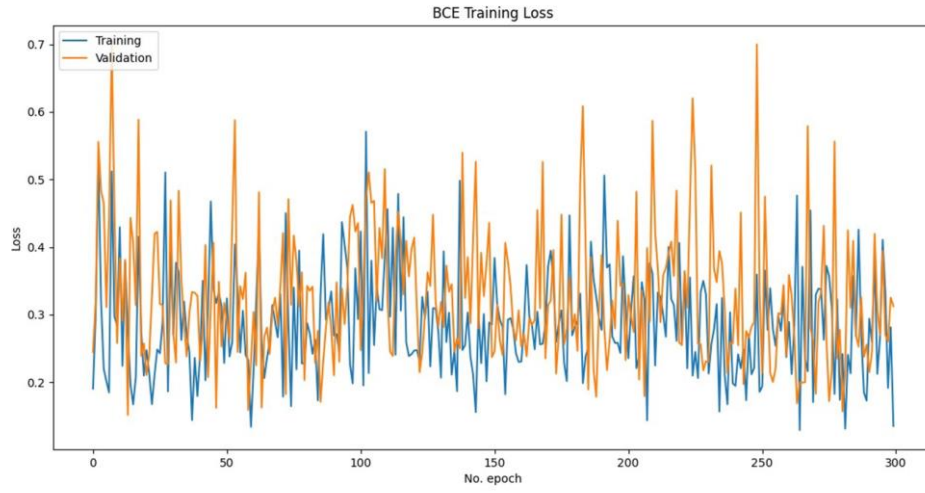


Şekil 6. Alt görüntülere ayrılmış orijinal görüntüler a) Sağlam izolatöre ait alt görüntüler b) Bir diski kırık izolatöre ait alt görüntüler


Elde edilen alt görüntülerle yeni bir veri seti oluşturulmuştur. Oluşturulan veri setindeki görüntülerin 1100 tanesi ile ResNet34 mimarisi eğitilmiş, 300 tanesi ile de doğrulama işlemi gerçekleştirilmiştir. Doğrulama ve test işleminde kullanılan görüntüler eğitimde kullanılmamıştır. ResNet34 mimarisi 300 epoch eğitilmiştir. ResNet34 mimarisinde kullanılan veri seti ile elde edilen doğruluk grafiği Şekil 7’de, kayıp grafiği de Şekil 8’de gösterilmektedir. Şekil 9’da da 50 epoch için doğruluk ve kayıp grafikleri verilmektedir.



Şekil 7. ResNet34 doğruluk grafiği




Şekil 8. ResNet34 kayıp grafiği



Şekil 9. 50 Epochta Eğitilen Sinir Ağının doğruluk ve kayıp grafikleri



ResNet34 mimarisinden elde edilen sınıflandırma sonuçlarını daha detaylı analiz edebilmek için Konfüzyon Matrisi oluşturulmuştur. Kullanılan derin öğrenme mimarisine ait Konfüzyon Matrisi ve başarı metrikleri Şekil 10'da gösterilmektedir.



Şekil 10. Konfüzyon matris ve başarı metrikleri

Konfüzyon matrisinde doğrulama için kullanılan 300 görüntüden True Negatif(TN) değeri 1 olarak elde edilmiştir. False Pozitif(FP) değeri 3, False Negatif(FN) değeri 10 ve True Pozitif(TP) değeri 286 olarak elde edilmiştir. Bu değerlerden yola çıkılarak doğruluk değeri 0.957, kesinlik değeri 0.990 ve duyarlılık değeri de 0.966 olarak elde edilmiştir. Doğruluk değeri 0,957 olarak elde edilmiştir. Bu değer %95 doğrulama yaptığını belirtmektedir ve bu oran sisteminin ne kadar doğru sonuçlar verdiğini göstermektedir. Kesinlik değeri 0,990 olarak hesaplanmıştır. Bu değer %99 oranında algılama yaptığını göstermektedir ve sistemin algılamalarını ve ölçümlerini ne kadar hassas bir şekilde yaptığını göstermektedir. Önerdiğimiz sistemin literatürdeki çalışmalar ile karşılaştırılması Tablo 1'de verilmektedir.

Tablo 1. Önerilen yöntemin literatürdeki çalışmalar ile karşılaştırılması

Referans Numarası	Kullanılan Yöntem	Doğruluk Oranı
[9]	KNN	% 85,17
[5]	CNN	% 89
[1]	Kontür özellikleri ve gri benzerlik eşleştirme	% 91,71
[15]	YOLOv5	% 95,02
Önerilen Yöntem	ResNet34	% 95,7

Tablodan da görülebileceği gibi önerilen yöntem literatürde yapılan çalışmalara göre daha yüksek bir doğruluk oranına sahiptir.

#### 4. Sonuç

İzolatörler katener sistemlerinde elektrik ileten tellerin havada asılı durmasını ve katener hattının topraklanmasını sağlayan bileşenlerdir. İzolatörler elektrik iletimi sırasında yanabilmekte veya kırılabilir. Bu bileşenlerde oluşan bu arızalar katener hattının güvenliğini tehdit etmektedir. Katener hattının sağlıklı bir şekilde çalışması için tüm bileşenleri gibi izolatörlerinin de sağlam olması gerekmektedir. Bu makalede de izolatör görüntülerinden oluşan bir veri seti

kullanılarak izolatörlerdeki arızaların tespiti için derin öğrenme tabanlı bir yöntem önerilmiştir. Veri setindeki görüntüler bölütlenerek izolatör disklerini içeren alt görüntüler elde edilmiştir. Bu alt görüntüler ResNet34 mimarisi ile sınıflandırılmıştır. Sınıflandırılan alt görüntüler birleştirilerek orijinal görüntülerin sağlamlığı değerlendirilmiştir. Yapılan deneysel çalışmalar sonucunda izolatörlerdeki arızalar %95,7 doğruluk, %99 kesinlik ve %96,6 duyarlılık değerleriyle sınıflandırılmıştır.

### Kaynakça

- [1] P. Tan, X. F. Li, X. J. M. Xu, J. E. Ma, F. J. Wang, J. Ding, Y. Ning, “Catenary insulator defect detection based on contour features and gray similarity matching”. *Journal of Zhejiang University Science A*, vol. 21, no.1, pp. 64-73, 2020, doi: 10.1631/jzus.A1900341.
- [2] Elektrikci, “Elektrik Tesislerinde İzolatörler” 2022 [Online]. Available: <https://www.elektrikce.com/elektrik-tesislerinde-izolatorler/> [21.07.2022].
- [3] Y. Han, Z. Liu, D. J. Lee, W. Liu, J. Chen, & Z. Han, “Computer vision-based automatic rod-insulator defect detection in high-speed railway catenary system”. *International Journal of Advanced Robotic Systems*, vol. 15, no.3, pp.1-15, 2018, doi: 10.1177/1729881418773943.
- [4] T. Kumar, “ResNet-34” 2022 [Online]. Available: <https://www.kaggle.com/datasets/pytorch/resnet34> [21.07.2022].
- [5] P. Fan, H. M. Shen, C. Zhao, Z. Wei, J. G. Yao, Z. Q. Zhou, Q. Hu, ” Defect identification detection research for insulator of transmission lines based on deep learning ”. *In Journal of Physics: Conference Series*, vol. 1828, No. 1, pp. 1-7 IOP Publishing, February, 2021, doi:10.1088/1742-6596/1828/1/012019.
- [6] V. Mehlomakulu, T. Magadza, “Transmission line isolator fault detection based on deep learning and UAV imageries”, *International Journal of Science and Research (IJSR)*, vol.11, no.2, pp. 1028-1035, February 2022, doi: 10.21275/SR22216013540.
- [7] Q. Wen, Z. Luo, R. Chen, Y. Yang, & G. Li, “Deep learning approaches on defect detection in high resolution aerial images of insulators”. *Sensors*, vol. 21, no.4, pp.1-24, 2021, doi:10.3390/s21041033.
- [8] C. Sampedro, J. Rodriguez-Vazquez, A. Rodriguez-Ramos, A. Carrio, & P. Campoy, “Deep learning-based system for automatic recognition and diagnosis of electrical insulator strings”. *IEEE Access*, vol. 7, pp.101283-101308, 2019, doi: 10.1109/ACCESS.2019.2931144.
- [9] M. P. Corso, F. L. Perez, S. F. Stefenon, K. C. Yow, R. García Ovejero, & V. R. Q. Leithardt, “Classification of contaminated insulators using k-nearest neighbors based on computer vision”. *Computers*, vol. 10, no. 9, pp. 1-18, 2021, doi: 10.3390/computers10090112.
- [10] C. Liu, Y. Wu, J. Liu, Z. Sun, & H. Xu, “Insulator Faults Detection in Aerial Images from High-Voltage Transmission Lines Based on Deep Learning Model”. *Applied Sciences*, vol. 11, no. 10, pp. 1-20, 2021, doi: 10.3390/app11104647.
- [11] T. Li, J. Zhou, G. Song, Y. Wen, Y. Ye, & S. Chen, “Insulator Infrared Image Segmentation Algorithm Based on Dynamic Mask and Box Annotation”. *11th International Conference on Power and Energy Systems (ICPES)*, China, 2021, pp. 432-435.
- [12] Z. Zhao, G. Xu, & Y. Qi, “Representation of binary feature pooling for detection of insulator strings in infrared images”. *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 23, no. 5, pp. 2858-2866, 2016, 10.1109/TDEI.2016.7736846.
- [13] E. Güçlü, İ. Aydın and E. Akın , "DCGAN ve Siyam Sınır Ağını Kullanarak Demiryolu Bağlantı Elemanlarındaki Kusurların Tespiti", *Demiryolu Mühendisliği*, no. 15, pp. 46-59, Jan. 2022, doi:10.47072/demiryolu.1015962.
- [14] T. Li, T. Hao, “Damage Detection of Insulators in Catenary Based on Deep Learning and Zernike Moment Algorithms”, *Applied Sciences*, vol. 12, no. 10, pp. 1-16, 2022, doi: 10.3390/app12105004.
- [15] G. Han, M. He, M. Gao, J. Yu, K. Liu, L. Qin, “Insulator breakage detection based on improved YOLOv5”. *Sustainability*, vol. 14, no. 10, pp. 1-17, 2022, doi:10.3390/su14106066.
- [16] G. Karaduman, M. Karakose, I. Aydın, E. Akın, “Contactless rail profile measurement and rail fault diagnosis approach using featured pixel counting”, *Intelligent Automation And Soft Computing*, vol. 26, no. 3, pp. 455–463, 2020, doi:10.32604/iasc.2020.013922.

**Özgeçmiş****Gülşah KARADUMAN**

1986 tarihinde doğmuştur. Lisans, Yüksek Lisans ve Doktora eğitimini Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde tamamlamıştır. Fırat Üniversitesinde Dr. Öğretim Üyesi olarak çalışmaktadır. İlgili alanına giren araştırma konuları Raylı Sistemler, Arıza Teşhisi, Görüntü İşleme, Yapay Zekâdır.

E-Posta: gkaraduman@firat.edu.tr

**Erhan AKIN**

1962 tarihinde doğmuştur. Lisans, Yüksek Lisans ve Doktora eğitimini Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde tamamlamıştır. Fırat Üniversitesinde Prof. Dr. olarak çalışmaktadır. İlgili alanına giren araştırma konuları Raylı Sistemler, Arıza Teşhisi, Görüntü İşleme, Yapay Zekâ, Bulanık Mantık ve Kontrol Sistemleridir.

E-Posta: eakin@firat.edu.tr

**Berkan BİNAY**

2000 tarihinde doğmuştur. Lisans eğitimine Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde devam etmektedir. İlgili alanına giren araştırma konuları Görüntü İşleme, Yapay Zekâdır.

E-Posta: binayberkan@gmail.com

**Miraç DİLEKLİ**

1997 tarihinde doğmuştur. Lisans eğitimine Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde devam etmektedir. İlgili alanına giren araştırma konuları Görüntü İşleme, Yapay Zekâdır.

E-Posta: mirac.mrdl@gmail.com

**Beyanlar:**

Bu makalede bilimsel araştırma ve yayın etiğine uyulmuştur.

Gülşah KARADUMAN: Kaynaklar, Metodoloji, Yazma-orijinal taslak hazırlama, Görselleştirme, İnceleme. Erhan AKIN: Metodoloji, Kontrol, Yazma-gözden geçirme ve düzenleme. Yazarların katkıları: Berkan BİNAY: Kavramsallaştırma, Yazılım. Miraç DİLEKLİ: Kavramsallaştırma, Yazılım, Doğrulama.