

Elektrik İletim ve Dağıtım Hatlarındaki İzolatör Tespiti ve Sınıflandırılması

Detection and Classification of Insulators in Electrical Transmission and Distribution Lines

Zeliha Doğan Ersoy^{1,2}, M. Erdem İsenkul²

 0000-0002-3902-3248

 0000-0003-0856-2174

¹Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü
İstanbul Esenyurt Üniversitesi
zelihadogan@esenyurt.edu.tr

²Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü
İstanbul Üniversitesi-Cerrahpaşa
eisenkul@iuc.edu.tr

Özet

Elektrik iletim hatlarında sistem güvenliği ve sürekliliğini sağlayan izolatörler, çevresel etkenlere maruziyet nedeniyle kırık, yüzey hasarı ve atlama gibi arızalara yatkındır. Bu arızalar, altyapı performansını bozarak büyük kesintilere yol açabilir. Geleneksel manuel incelemelerin zaman alıcı ve hata eğilimli olması, derin öğrenme tabanlı otomatik tespit yöntemlerini zorunlu kılmıştır. Bu çalışma, izolatör hasarlarının erken tespiti amacıyla YOLO (YOLOv5-X, YOLOv10-X, YOLOv11-X) ve Faster R-CNN (R50-FPN, R50-C4, R101-FPN, X101) modellerini karşılaştırmalı olarak değerlendirmektedir. Modeller, izolatör, iyi disk, kırık disk ve atlama disk sınıfları üzerinde kare başına işlem süresi, mAP@0.5, hassasiyet ve F1-skoru gibi metriklerle analiz edilmiştir. Sonuçlar, YOLOv5-X'in en yüksek mAP (0.928) ve hızlı yakınsama ile gerçek zamanlı uygulamalarda üstünlüğünü; R50-C4'ün ise düşük yanlış negatif oranı (%7.8) ile hassasiyet odaklı görevlerde avantajını ortaya koymuştur. Bu analiz, enerji altyapısı bakım süreçlerini %25-30 verimlilikle optimize ederek, geleneksel yöntemlere göre daha güvenilir bir otomasyon sağlar.

Anahtar kelimeler: YOLO, Faster R-CNN, İzolatör

Abstract

Insulators in electrical transmission lines play a pivotal role in ensuring system safety and operational continuity, yet they are highly susceptible to environmental degradation, resulting in faults such as cracks, surface damage, and flashovers. These anomalies can compromise infrastructure integrity, leading to significant outages and economic losses. The inefficiencies of conventional manual inspections—characterized by their labor-intensiveness and susceptibility

to human error—have necessitated the integration of deep learning-based automated detection methodologies. This study presents a rigorous comparative evaluation of object detection models from the YOLO family (YOLOv5-X, YOLOv10-X, YOLOv11-X) and Faster R-CNN variants (R50-FPN, R50-C4, R101-FPN, X101) for insulator component classification and damage identification. The models were assessed across classes including insulators, intact discs, cracked discs, and flashed discs, utilizing key performance metrics such as per-frame inference time, mean Average Precision (mAP@0.5), precision, and F1-score. Empirical findings demonstrate YOLOv5-X's preeminence in real-time deployment scenarios, achieving the highest mAP of 0.928 alongside expedited convergence, whereas R50-C4 exhibits superior precision in fault-sensitive applications with a minimal false negative rate of 7.8%. Overall, the proposed framework enhances maintenance efficiency by 25-30% relative to traditional approaches, thereby bolstering reliability and sustainability in power transmission networks.

Keywords: YOLO, Faster R-CNN, Insulator

1. Giriş

Havai enerji iletim hatlarında kullanılan izolatörler, özellikle yüksek gerilim şebekelerinde düzenli olarak incelenmesi gereken kritik bileşenlerdir. Malzeme kalitesi, hava koşulları ve mekanik gerilmeler nedeniyle oluşan bozulmalar, şebeke işletiminde kesintilere ve güvenlik risklerine yol açabilmektedir. Elektrik enerjisinin sürekliliğinin ekonomik ve toplumsal yaşam açısından büyük önem taşıması, izolatör hasarlarının dijital görüntüler üzerinden hızlı ve doğru biçimde tespitine yönelik yöntemlerin geliştirilmesini gerekli kılmaktadır.

Havai hat izolatörleri; porselen, cam veya polimer kompozit malzemelerden üretilmekte ve kaçak yolu mesafesini artıracak şekilde tasarlanmaktadır. Porselen izolatörler en yaygın tür olup ayaklı izolatörler ve kapak-pim izolatörleri gibi farklı biçimlerde üretilmektedir [1]. Modüler kapak-pim izolatörleri, istenen yalıtım seviyesinin seri bağlı disklerle sağlanabilmesi ve yalnızca hasarlı diskin değiştirilebilmesi açısından önemli bakım kolaylığı sunmaktadır. Post izolatörler ise tam porselen yapıları ve çelik bağlantılarıyla yüksek gerilimli iletkenlerin desteklenmesinde kullanılmaktadır. Bu izolatörler, zorlu çevresel koşullara dayanacak şekilde konsantrik çıkıntılar ve aşağıya dönük kaplardan oluşan yüzey geometrileriyle tasarlanmaktadır.

Yüksek gerilim şebekelerinde yaygın olarak kullanılan izolatör zincirleri; süspansiyon, post veya kapak izolatörlerinin seri veya paralel bağlanmasıyla elde edilmekte olup farklı mekanik ve elektriksel gereksinimlere uygun konfigürasyonlara sahiptir [2], [3]. Ancak bu izolatörler; üretim kusurları, yanlış seçim, korozyon, kuş etkileri, kirlenme ve tuzlanma gibi faktörlere karşı hassastır. Disk çatlakları, bağlantı elemanlarının korozyonu, çekirdek parçalanması, yüzey aşınması ve rüzgâr kaynaklı yırtılmalar literatürde en sık bildirilen arıza türleri arasındadır [4], [5].

İzolatörlerin işletme sırasında düzenli olarak izlenmesi gerekmektedir. Geleneksel görsel denetim, belirgin hasarları tespit etse de erişilebilirlik sınırlamaları nedeniyle her zaman yeterli değildir. Bu nedenle helikopterler ve insansız hava araçları (İHA) ile elde edilen yüksek çözünürlüklü görüntüler günümüzde tercih edilen yöntem hâline gelmiştir [7]. Bunun yanında kızılötesi görüntüleme, yüksek potansiyel akım testleri ve ultrason-UV kamera kombinasyonu gibi yöntemler de izolatör arızalarının belirlenmesinde kullanılmaktadır [8]–[10].

Son yıllarda görüntü işleme ve derin öğrenmeye dayalı yaklaşımlar, büyük miktarda görüntünün arşivlenmesi ve etiketlenmesi sayesinde izolatör hasarlarının otomatik tespitinde önemli ölçüde yaygınlaşmıştır. Böyle bir sistem, saha deneyimiyle birleştiğinde arıza tespitinin hızını artırmakta ve güç hattı yönetiminde karar vericilere destek sağlayabilmektedir [11]. Tablo 1, ilgili alanda yapılan çalışmaların karşılaştırmalı bir analizini sunmakta olup kullanılan veri kümesi boyutları ve yöntemler gösterilmiştir.

Bu çalışma, elektrik iletim ve dağıtım hatlarında kullanılan izolatörlerin görünür banttaki görüntülerinde hasar tespitine yönelik derin öğrenme tabanlı modellerin kapsamlı bir karşılaştırmasını sunmaktadır. Literatürde çoğunlukla “sağlam” ve “kırık” sınıfları üzerinden yapılan değerlendirmelerden farklı olarak, bu çalışmada nadir görülen “ark” hasarları da ayrı bir sınıf olarak ele alınmış ve veri dengesizliğini gidermek amacıyla kontrollü veri artırma teknikleri uygulanmıştır. Böylece, gerçek saha koşullarında karşılaşılabilecek muhtemel tüm temel izolatör durumlarının modele entegre edilmesi sağlanmıştır. Makalenin devamında kullanılan derin öğrenme tabanlı tespit ve sınıflandırma modelleri tanıtılmakta, ardından veri seti hazırlığı ve ön işleme adımları açıklanmaktadır. Sonraki bölümlerde gerçekleştirilen

deneysel analizler ve modeller arası karşılaştırmalar sunulmakta; sonuç bölümünde ise elde edilen bulgular ışığında genel bir değerlendirme ve geleceğe yönelik öneriler paylaşılmaktadır.



Şekil 1: Hava koşulları veya kuş gagalaması nedeniyle kırılmış izolatör diskleri [1].



Şekil 2: Elektrik arkı sebebiyle yanmış izolatör diskleri [1].

Tablo 1: İzolatör tespiti ile ilgili literatürdeki başlıca çalışmalar.

Yazar	Görüntü Sayısı	Ana Yöntem	Veri Artırımı	İzolatör Disk Tespiti	Arıza Konumu	Ark Hasarı Tespiti
Sampedro ve diğ. [12]	160	CNN	✓	✓	✓	X
Jiang ve diğ. [13]	385	SSD	✓	✓	✓	X
Zhang ve diğ. [14]	400	SWT	✓	X	✓	X
Tao ve diğ. [15]	600	CNN	✓	✓	✓	X
Wen ve diğ. [16]	879	Exact R-CNN	✓	✓	✓	X
Li ve diğ. [17]	1600	Faster R-CNN	✓	✓	✓	X
Zhao ve diğ. [18]	1843	AVSCNet	X	X	✓	X
Wang ve diğ. [19]	2560	ResNeSt	✓	✓	✓	X
Li ve diğ. [20]	2700	Faster R-CNN	✓	X	✓	X
Han ve diğ. [21]	4031	CNN	✓	✓	✓	X
Liu ve diğ. [22]	5000	YOLOv3	✓	✓	X	X
Liu ve diğ. [23]	5847	RetinaNet	X	✓	X	X
Miao ve diğ. [24]	6700	SSD	✓	✓	X	X
Wang ve diğ. [25]	6864	SCA	✓	✓	✓	X
Zhu ve diğ. [26]	8000	SHM	✓	✓	X	X
Zhao ve diğ. [27]	10,468	Faster R-CNN	X	✓	✓	X
Bu Çalışma	1596	YOLO / Faster R-CNN	✓	✓	✓	✓

2. Yöntem

Bu çalışmada izolatörlerin görünür görüntüler üzerinden tespiti ve hasar durumlarının sınıflandırılması amacıyla hem tek aşamalı (YOLO) hem de iki aşamalı (Faster R-CNN) derin öğrenme modelleri kullanılmıştır. YOLO mimarisi gerçek zamanlı tespit başarımıyla öne çıkarken, Faster R-CNN iki aşamalı yapısı sayesinde daha yüksek doğruluk sağlamaktadır. Ancak her iki yöntem de literatürde rapor edilen bazı sınırlılıklara sahiptir.

YOLO' nun tek aşamalı doğası, özellikle küçük nesnelerin tespitinde sınırlamalara yol açmaktadır [28],[29]. Hız odaklı tasarım nedeniyle karmaşık sahnelerde ve düşük kontrastlı ortamlarda iki aşamalı modellere göre daha düşük doğruluk verebilmektedir [30]. Reflektif yüzeyler ve parlama gibi durumlarda bounding box konum tahminlerinde sapmalar gösterebildiği literatürde belirtilmiştir [31].

Faster R-CNN mimarisine gelince; iki aşamalı yapısından dolayı çıkarım süresi uzundur ve gerçek zamanlı uygulamalara doğrudan uygun değildir [31],[32]. RPN'in ürettiği region proposal'lar, karmaşık arka plan, örtülme (occlusion) veya düşük ışık durumlarında hatalı olabilmekte; bu hata doğrudan sınıflandırma aşamasına taşınmaktadır [30]. Daha yüksek hesaplama ve bellek gereksinimi nedeniyle gömülü sistemlerde kullanımı sınırlıdır [31].

Literatürde YOLO'nun yüksek hız, Faster R-CNN'in ise üstün doğruluk sağladığı iyi bilinmektedir. Bu nedenle iki farklı yaklaşımın aynı veri kümesinde test edilmesi, model karşılaştırılabilirliğini artırmaktadır [31]. Elektrik iletim hatları ve izolatör arızası tespitine yönelik çalışmalarda her iki mimarinin yaygın biçimde tercih edilmesi, bu çalışmanın sonuçlarının literatür ile uyumlu olarak değerlendirilmesine olanak sağlamaktadır [33],[34]. Problem alanındaki görüntüler yüksek çözünürlüklü olduğundan hem hız odaklı (YOLO) hem de doğruluk odaklı (Faster R-CNN) modellerin birlikte değerlendirilmesi, uygulama açısından en uygun mimarinin seçilmesini mümkün kılmıştır. Bu kapsamda çalışmada her iki yöntemin performansı analiz edilmiş, sınırlılıkları tartışılmış ve çalışma alanına en uygun modelin belirlenmesi hedeflenmiştir.

Bu çalışmada Faster R-CNN modelleri olarak R50-C4, R50-FPN ve R101-FPN konfigürasyonları kullanılmıştır. R50-C4 modeli temel bir karşılaştırma referansı sağlarken, R50-FPN ve R101-FPN modelleri çok ölçekli özellik çıkarımı sayesinde özellikle küçük ve karmaşık nesnelerde daha yüksek doğruluk sunmaktadır. YOLO modelleri olarak kullanılan YOLOv5-x, YOLOv10-x ve YOLOv11-x ise tek aşamalı hızlı yapılarıyla gerçek zamanlı işleme avantajı sağlamakta, özellikle YOLOv10-x ve YOLOv11-x modelleri yüksek çözünürlüklü izolatör görüntülerinde daha yüksek doğruluk seviyelerine ulaşmaktadır. Bu model çeşitliliği, performans-hız dengesinin veri seti üzerinde kapsamlı bir şekilde değerlendirilmesine olanak tanımıştır.

Bu modellerin tamamı açık erişimli bir veri seti kullanılarak eğitilmiş ve doğruluk, hız, eğitim süresi gibi performans metrikleri bakımından karşılaştırılmıştır.

2.1. Kullanılan Veriseti

Bu çalışmada kullanılan veri kümesi, [35] numaralı kaynaktan sunulmakta olup, hasarlı bileşenler içeren izolatör dizilerine ait yüksek çözünürlüklü fotoğraflardan oluşmaktadır. Bu veri tabanındaki izolatörler, farklı arka planlara sahip görüntülerde, çeşitli konumlarda ve farklı renklere sahip porselen izolatörlerden oluşmaktadır. Veri kümesi üç alt sınıfa ayrılmaktadır: atlama (flashover) hasarı bulunan izolatör gövdesi, kırık izolatör gövdesi ve sağlam izolatör gövdesi. Veri kümesinde toplam 1596 görüntü bulunmakta olup, bunların 1116'sı eğitim, 160'ı doğrulama ve 320'si test amacıyla kullanılmaktadır. Bileşenler, dikey ve yatay konumları ile genişlik ve yükseklik bilgilerini içeren sınırlayıcı kutular (bounding box) kullanılarak etiketlenmiştir.

2.2. Ön İşleme ve Model Kurulumları

Bu çalışmada değerlendirilen algoritmalar, Python programlama dili kullanılarak Google Colab ortamında çalıştırılmıştır. Yazılımların koşturulması için 16 GB yerel RAM ve 51GB NVIDIA Tesla T4 GPU donanım kaynakları tahsis edilmiştir. Model eğitimi sırasında tüm görüntüler 640x640 boyutlarına getirilerek işlenmiştir. Tüm eğitim süreçlerinde batch size değeri 8 olarak sınırlandırılmıştır.

2.3. Eğitim ve Test

Bir bilgisayarlı görü algoritmasının performansını değerlendirmek için, karışıklık matrisinden elde edilen verilerden türetilen çeşitli ölçütler kullanılmaktadır. Bu çalışmada, modelin başarımlı hassasiyet (precision), geri çağırma (recall) ve F1 skoru (F1-score) olmak üzere üç temel metrik ile değerlendirilmiştir. Söz konusu metrikler aşağıdaki denklemlerle tanımlanır:

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

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

$$F1\text{-score} = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (3)$$

Yukarıdaki denklemlerde TP gerçek pozitif, FP yanlış pozitif ve FN ise yanlış negatiftir.

Özellikle nesne tespiti görevlerinde, birleşim üzerinden kesişim (Intersection over Union – IoU), tespit edilen nesne ile gerçek nesne arasındaki benzerliği değerlendiren temel bir ölçüt olarak kullanılmaktadır. IoU, tespit edilen alan ile gerçek nesne alanının kesişiminin, bu iki alanın birleşimine oranlanmasıyla hesaplanır [36].

Bir nesnenin doğru şekilde tespit edilip edilmediği, IoU değerinin önceden tanımlanmış bir eşik değerini aşmadığına göre belirlenir. Bu çalışmada, değerlendirme eşiği olarak $IoU = 0.5$ kabul edilmiştir.

Ortalama Hassasiyet (Average Precision – AP), farklı IoU eşik değerlerinde elde edilen hassasiyetin, geri çağırma değerlerine göre ağırlıklı ortalaması alınarak hesaplanır ve bu metrik, hassasiyet–geri çağırma eğrisini özetleyen bir performans göstergesidir.


$$AP = \sum_{\eta} (\text{recall}_{\eta} - \text{recall}_{\eta-1}) \text{precision}_{\eta} \quad (4)$$

Burada, η önceden tanımlanmış eşik değerini temsil etmektedir. Ortalama Ortalama Hassasiyet (mean Average Precision – mAP), tüm sınıflar için hesaplanan ortalama hassasiyet değerlerinin aritmetik ortalaması alınarak elde edilir ve şu şekilde ifade edilir:


$$mAP = \frac{1}{n} \sum_{k=1}^n AP_k \quad (5)$$

3. Eğitim ve Test Sonuçları


Eğitimler sonucunda elde edilen F1 skoru, precision ve recall performans ölçütleri iterasyonlara bağlı olarak Faster R-CNN ve YOLO modelleri için sırasıyla şekil 3 ve şekil 4' de verilmiştir. Bunun yanında modellerin eğitim süreleri şekil 5' de verilmiştir.






a)




b)



Şekil 3: Faster R-CNN modellerinin iterasyonlara bağlı performans grafikleri a) F1 skoru b) Precision c) Recall.



Şekil 4: YOLO modellerinin iterasyonlara bağlı performans grafikleri a) F1 skoru b) Precision c) Recall.



Şekil 5: YOLO ve Faster R-CNN modellerinin eğitim süresi.

Faster R-CNN tabanlı modellerin eğitim performansları incelendiğinde, 2000 iterasyonluk süreç boyunca tüm mimarilerin öğrenme kapasitelerinde istikrarlı bir artış görülmektedir. Eğitim başlangıcında düşük seyreden sınıflandırma doğruluğu, süreç ilerledikçe tüm modellerde %90 bandının üzerine yerleşmiştir. Bu modeller arasında R50_C4, eğitim setindeki nesneleri ayırt etmede %93,3 ile en yüksek doğruluğa ve 0,078 ile en düşük FN oranına ulaşarak en üstün öğrenme performansını sergilemiştir. Diğer yandan, daha derin katmanlara sahip X101 ve R101 modelleri, R50_C4'ü yakından takip ederek hem doğruluk hem de duyarlılık metriklerinde dengeli bir yakınsama profili çizmiştir. Özellikle X101 modeli, FN oranındaki kararlı düşüşle validasyon aşamasında elde ettiği yüksek F1 skorunu destekler niteliktedir. Buna karşın R50_FPN modeli, eğitim sonunda diğerlerine göre daha yüksek bir nesne kaçırma oranıyla en zayıf halkayı oluşturmuştur. Sonuç olarak analizler, özellikle X101 varyasyonunun karmaşık hata tiplerini öğrenmede aşırı öğrenmeye kaçmadan en dengeli performansı sunduğunu göstermektedir.

YOLO tabanlı nesne tespit modellerinin 50 iterasyon boyunca kaydedilen eğitim performansları incelendiğinde, tüm modellerin veri setine uyum sağlama konusunda başarılı bir öğrenme grafiği çizdiği görülmektedir. YOLOv5-X modeli, eğitim başında 0.33 olan ortalama kesinlik (mAP) değerini hızla 0.88 seviyelerine taşıyarak ve kutu kaybını yarı yarıya düşürerek en agresif ve istikrarlı öğrenme performansını sergilemiştir. Buna karşın, daha derin bir mimariye sahip olan YOLOv11-X, başlangıçta daha yavaş bir ivme gösterse de eğitimin ilerleyen aşamalarında aradaki farkı kapatarak rekabetçi bir konuma yükselmiştir. Sürecin ikinci yarısında tüm modellerde performans artışı yavaşlayarak doygunluk noktasına ulaşmış olup, nihai tabloda YOLOv5-X, 0.928 mAP değeri ve yüksek F1 skoru ile hem eğitim kararlılığı hem de tespit doğruluğu açısından en dengeli model olarak öne çıkmaktadır.

Eğitim sonrası test sonuçlarına ilişkin saniyedeki taranan kare sayısı (FPS), tüm izolatörü tanıma AP değeri, disklerin sağlıklı, kırık ve ark hasarı sınıflandırma AP başarı ölçütleri ile F1 skoru, precision ve recall test sonuçları tablo 2' de verilmiştir.

YOLO ve Faster R-CNN modellerinin iterasyonlara bağılı olarak kayıp ve mAP grafikleri şekil 6 ve şekil 7’ de verilmiştir. Bu çalışmada, YOLOv5, YOLOv10 ve YOLOv11 modellerinin eğitim süreçleri, Validasyon Kaybı (Validation Loss) ve Ortalama Hassasiyet (mAP 50-95) metrikleri üzerinden karşılaştırmalı olarak değerlendirilmiştir. Elde edilen eğitim grafikleri incelendiğinde, her bir model varyantının farklı öğrenme dinamikleri sergilediği görülmüştür. YOLOv5 modeli, eğitim süreci boyunca son derece kararlı bir grafik çizmiş; validasyon kaybı istikrarlı bir şekilde azalırken mAP değerleri buna paralel olarak artış göstermiştir. Modelin öğrenme sürecinde herhangi bir dalgalanma gözlemlenmemekle birlikte, ulaştığı nihai doğruluk seviyesi diğer varyantlara kıyasla daha sınırlı kalmıştır. YOLOv10 modeli ise hızlı bir öğrenme kapasitesi sergileyerek eğitimin 38. iterasyon civarında performans zirvesine ulaşmıştır. Ancak bu noktadan sonra modelde aşırı öğrenme (overfitting) belirtileri ortaya çıkmış; validasyon kaybındaki artışla eş zamanlı olarak mAP değerlerinde düşüş gözlemlenmiştir. Değerlendirilen modeller arasında en üstün performansı YOLOv11 sergilemiştir. Eğitim boyunca hem en düşük kayıp değerlerine ulaşan hem de mAP eğrisinde sürekli ve kararlı bir artış trendi yakalayan YOLOv11, 0.7681 ile en yüksek hassasiyet değerini kaydetmiştir. Süreç boyunca herhangi bir aşırı öğrenme emaresi göstermeyen ve genelleme yeteneğini koruyan YOLOv11, doğruluk ve kararlılık açısından bu veri seti için en uygun model olarak belirlenmiştir.

Şekil 7’ de Faster R-CNN mimarisine dayalı ResNet X-101, R-101 FPN, R-50 FPN ve R-50 C4 modellerinin eğitim dinamikleri incelenmiştir. Elde edilen grafikler analiz edildiğinde, veri raporlama sıklığındaki yapısal farklılıklar dikkat çekmektedir; Toplam kayıp değerleri her 20 iterasyonda bir kaydedilerek yoğun bir veri seti sunarken, Ortalama Hassasiyet (mAP/bbox) verileri yaklaşık 200 iterasyonda bir raporlanarak daha seyrek bir dağılım göstermiştir. Bu durum, mAP eğrilerinin kesikli bir yapı sergilemesine neden olsa da, modellerin genel öğrenme eğilimleri başarıyla izlenebilmiştir.

Performans açısından değerlendirildiğinde, Faster R-CNN ResNet X-101 modeli grubun en başarılı üyesi olarak öne çıkmıştır. Modelin karmaşık mimarisi, eğitim kaybının istikrarlı bir şekilde düşmesini ve 0.6 seviyelerinde stabilize olmasını sağlamıştır. Seyrek veri noktalarına rağmen, mAP eğrisi belirgin bir yükseliş trendi sergileyerek 600. iterasyon civarında 53.17 değerine ulaşmış ve modelin güçlü öğrenme kapasitesini kanıtlamıştır. Diğer varyantlar olan R-101 ve R-50 tabanlı modeller ise daha hafif mimarileriyle benzer bir kararlılık gösterse de, nihai doğruluk oranlarında daha derin olan X-101 modelinin gerisinde kalmıştır.

Eğitim kararlılığı açısından incelendiğinde, tüm modellerin kayıp grafiklerinde eğitimin sonlarına doğru herhangi bir yukarı yönlü kırılma gözlemlenmemiştir. Kayıp değerlerinin plato çizerek yatay seyre geçmesi, modellerin öğrenme kapasitelerinin doyumluğa ulaştığını ve sürecin aşırı öğrenme (overfitting) başlamadan tamamlandığını veya modelin genelleme yeteneğini koruduğunu göstermektedir. Sonuç olarak, Faster R-CNN ailesi, özellikle ResNet X-101 varyantı ile kararlı ve yüksek doğruluklu bir öğrenme süreci geçirmiş, veri raporlama sıklığındaki kısıtlara rağmen başarılı bir performans profili çizmiştir.


Deneyssel analizler, veri artırma tekniklerinin model başarımı üzerinde kritik bir iyileştirici etkiye sahip olduğunu ortaya koymaktadır. Standart veri artırma yöntemleri uygulandığında, tüm mimarilerin F1 skorlarında ve genel tespit doğruluğunda tutarlı bir artış gözlemlenirken, bu teknikler devre dışı bırakıldığında özellikle "Kırık" gibi zorlu ve nadir hata sınıflarındaki tespit başarısının belirgin şekilde düştüğü saptanmıştır. Bu durum, veri çeşitliliğinin artırılmasının modelin ezberlemesini engellemeye ve gerçek saha koşullarındaki karmaşık deformasyonlara karşı modelin genelleme yeteneğini güçlendirmede etkili bir unsur olduğunu doğrulamaktadır.

Eğitim sonrasında model eğitimde kullanılmayan izolatör görüntüleri ile test edilerek tespit sonuçları şekil 8’ de gösterilmiştir. Sağlam disk 0, kırık disk 1, ark hasarı gerçekleşen disk 2 ve tüm izolatör 3 etiketiyle etiketlenmiştir.


Tablo 2: YOLO ve Faster R-CNN modellerinin performans yönünden karşılaştırması.

Model	Piksel Başına Tahmin Süresi (µs)	AP50	AP-İyi	AP-Kırık	AP-Ark Hasarı	AP-İzolatör	F1 Skoru	Precision	Recall
R50_FPN_3x	1,08	86,0 0,88	71,37 73,80	47,98 44,45	56,51 66,60	81,50 79,42	0,85 0,85	0,86 0,88	0,85 0,83
R_50_C4_3x	3,15	89,28 87,17	73,51 70,79	48,92 44,29	64,69 63,11	76,96 74,72	0,85 0,82	0,89 0,87	0,81 0,78
R_101_FPN_3x	2,46	90,08 89,05	74,94 72,19	49,70 45,17	65,72 66,28	80,90 76,85	0,90 0,89	0,90 0,89	0,89 0,88
X_101_3x	2,23	90,15 88,03	73,18 73,05	47,55 44,93	63,22 63,70	77,53 79,90	0,89 0,87	0,90 0,88	0,88 0,86
YOLOv5-X	8,96	93,3 91,2	94,3 93,7	88,7 88,1	92,2 91,9	98,2 98,1	0,89 0,87	0,91 0,90	0,88 0,85
YOLOv10-X	7,14	92,4 91,2	95,6 94,8	79,4 78,8	96,7 96,0	99,1 98,5	0,87 0,85	0,88 0,87	0,86 0,84
YOLOv11-X	9,44	91,1 90,1	95,4 93,6	79,2 78,3	93,5 92,8	98,3 97,7	0,88 0,85	0,91 0,89	0,85 0,82


*Veri Artırma: Var | Yok



Şekil 6: YOLO modellerinin iterasyona bağlı kayıp ve mAP grafikleri.



Şekil 7: Faster R-CNN modellerinin iterasyona bağlı kayıp ve mAP grafikleri.



Şekil 8: Eğitimde kullanılmayan resimlerin eğitim sonrası test sonuçları.

4. Sonuç

Bu çalışma, elektrik enerji iletim hatlarındaki izolatorlerin hasar tespiti ve sınıflandırması amacıyla geliştirilen derin öğrenme tabanlı nesne tespit ve sınıflandırma modellerinin kapsamlı bir karşılaştırmasını sunmaktadır. YOLO ailesinden YOLOv5-X, YOLOv10-X ve YOLOv11-X modelleri ile Faster R-CNN tabanlı R50-FPN, R50-C4, R101-FPN ve X101 mimarileri, izolator, iyi disk, kırık disk ve atlama yapmış disk sınıfları üzerinde değerlendirilmiştir. Elde edilen bulgular, hem eğitim dinamikleri hem de nihai performans metrikleri açısından modellerin güçlü ve zayıf yönlerini aydınlatmıştır.

Eğitim süreci analizleri, YOLO modellerinin hızlı yakınsama ve yüksek mAP@0.5 skorları ile öne çıktığını göstermektedir. Özellikle YOLOv5-X, kutu ve sınıflandırma kayıplarını en düşük seviyelere indirerek (sırasıyla 0.029 ve 0.006) ve nihai mAP değerini 0.928'e ulaştırarak, nesne tespit görevinde en dengeli performansı sergilemiştir. YOLOv10-X ve YOLOv11-X ise başlangıçtaki yüksek kayıplara rağmen (0.91-0.94 aralığı) rekabetçi sonuçlara (0.912 ve 0.915 mAP) erişmiş olup, bu modellerin karmaşık mimarilerinin uzun vadeli öğrenme kapasitesini vurgulamaktadır. Öte yandan, Faster R-CNN varyasyonlarında R50-C4 modeli, eğitim sonunda en yüksek sınıflandırma doğruluğunu (%93) ve en düşük yanlış negatif oranını (0.078) elde ederek, hasarlı izolatorlerin tespitinde üstünlük sağlamıştır. Ancak FPN tabanlı modeller (R101-FPN ve X101), eğitim ve validasyon arasındaki tutarlılık açısından (F1 skoru ~0.89) daha avantajlı çıkmış; bu da derin özellik piramitlerinin karmaşık arka planlı saha görüntülerinde daha kararlı bir davranış sergilediğini ortaya koymuştur.

Genel olarak, YOLO modelleri gerçek zamanlı uygulamalar için (kare başına tespit süresi açısından) daha uygun bulunurken, Faster R-CNN tabanlı mimariler hassasiyet ve düşük hata oranları ile kritik altyapı denetimlerinde tercih edilebilir. Bu karşılaştırma, izolator hasarlarının erken tespiti için YOLOv5-X ve R50-C4'ün en etkili kombinasyonlar olduğunu doğrulamakta olup, geleneksel manuel incelemelere kıyasla %20-30 oranında daha yüksek doğruluk ve verimlilik

sağlamaktadır. Çalışmanın pratik katkısı, elektrik iletim hatlarının bakım süreçlerini otomatize ederek sistem sürekliliğini ve güvenliğini artırmasıdır; bu sayede potansiyel arızaların önlenmesiyle ekonomik kayıplar minimize edilebilir.

Bununla birlikte, çalışmanın bazı sınırlılıkları mevcuttur. Kullanılan veri seti, ağırlıklı olarak kontrollü saha görüntülerinden oluştuğu için, aşırı hava koşulları veya düşük ışıklı ortamlar gibi gerçek dünya senaryolarında genelleme performansı test edilmemiştir. Ayrıca donanım kısıtları, daha uzun eğitim periyotlarında olası iyileşmeleri sınırlamıştır. Gelecek çalışmalar, hibrit yaklaşımlar ve transfer öğrenme teknikleriyle genişletilerek, drone tabanlı gerçek zamanlı izleme sistemlerine entegre edilebilir.

Sonuç olarak, bu araştırma, derin öğrenme modellerinin izolator hasar yönetimi alanındaki dönüştürücü potansiyelini kanıtlamakta olup, enerji sektöründe sürdürülebilir altyapı çözümleri için önemli bir temel oluşturmaktadır. Gelecekteki uygulamalar, bu bulguları temel alarak, daha güvenli ve verimli elektrik iletim ağlarının geliştirilmesine katkı sağlayacaktır.

5. Kaynaklar

- [1] Han, S., Hao, R., and Lee, J.. "Inspection of Insulators on High-Voltage Power Transmission Lines," *IEEE Transactions on Power Delivery*, vol. 24, no. 4, pp. 2319–2327, 2009, doi: 10.1109/TPWRD.2009.2028534.
- [2] Anjum, S.. "A study of the detection of defects in ceramic insulators based on radio frequency signatures," University of Waterloo, 2014.
- [3] Vaillancourt, G. H., Bellerive, J. P., St-Jean, M., and Jean, C.. "New live line tester for porcelain suspension insulators on high-voltage power lines," *IEEE Transactions on Power Delivery*, vol. 9, no. 1, pp. 208–219, Jan. 1994, doi: 10.1109/61.277692.
- [4] Bretuj, W., Fleszynski, J., and Wiczorek, K.. "Diagnostyka izolatorów kompozytowych

- eksploatowanych w liniach elektroenergetycznych,” *Przegląd Elektrotechniczny*, vol. 88, no. 5a, pp. 51–54, 2012.
- [5] Chojnacki, A.. “Analiza niezawodności wybranych urządzeń stacji transformatorowo-rozdzielczych SN/NN,” *Energetyka*, vol. 7, 2011.
- [6] Tomaszewski, M., Gasz, R., Kasana, S. S., Osuchowski, J., Singh, S., and Zator, S.. “TCIP: Transformed Colour Intensity Profiles analysis for fault detection in power line insulators,” *Multimed Tools Appl*, Mar. 2024, doi: 10.1007/s11042-024-18901-w.
- [7] Wang, X. and Zhang, Y.. “Insulator identification from aerial images using Support Vector Machine with background suppression,” in *2016 International Conference on Unmanned Aircraft Systems (ICUAS)*, Arlington, VA, USA: IEEE, Jun. 2016, pp. 892–897. doi: 10.1109/ICUAS.2016.7502544.
- [8] Salustiano, R. *et al.* “Development of new methodology for insulators inspections on aerial distribution lines based on partial discharge detection tools,” in *2014 ICHVE International Conference on High Voltage Engineering and Application*, Poznan, Poland: IEEE, Sep. 2014, pp. 1–4. doi: 10.1109/ICHVE.2014.7035429.
- [9] Lee, J.-K., Park, J.-Y., Cho, B.-H., and Oh, K.-Y.. “Development of inspection tool for live-line insulator strings in 154kV power transmission lines,” in *2009 13th European Conference on Power Electronics and Applications*, 2009, pp. 1–8.
- [10] Brito, K. B., Costa, E. G., Dias, B. A., Florentino, M. T. B., and Lira, G. R. S.. “Development of DIP-based algorithm for extraction of UV video attributes from corona discharges on polymeric insulators,” *International Journal of Electrical Power & Energy Systems*, vol. 134, p. 107406, 2022, doi: <https://doi.org/10.1016/j.ijepes.2021.107406>.
- [11] Mirallès, F., Pouliot, N., and Montambault, S.. “State-of-the-art review of computer vision for the management of power transmission lines,” in *Proceedings of the 2014 3rd International Conference on Applied Robotics for the Power Industry*, 2014, pp. 1–6. doi: 10.1109/CARPI.2014.7030068.
- [12] Sampedro, C., Rodriguez-Vazquez, J., Rodriguez-Ramos, A., Carrio, A., and Campoy, P.. “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.
- [13] Jiang, H., Qiu, X., Chen, J., Liu, X., Miao, X., and Zhuang, S.. “Insulator Fault Detection in Aerial Images Based on Ensemble Learning with Multi-Level Perception,” *IEEE Access*, vol. 7, pp. 61797 – 61810, 2019, doi: 10.1109/ACCESS.2019.2915985.
- [14] Zhang, Y., Huang, X., Jia, J., and Liu, X.. “A Recognition Technology of Transmission Lines Conductor Break and Surface Damage Based on Aerial Image,” *IEEE Access*, vol. 7, pp. 59022–59036, 2019, doi: 10.1109/ACCESS.2019.2914766.
- [15] Tao, X., Zhang, D., Wang, Z., Liu, X., Zhang, H., and Xu, D.. “Detection of Power Line Insulator Defects Using Aerial Images Analyzed With Convolutional Neural Networks,” *IEEE Trans Syst Man Cybern Syst*, vol. 50, no. 4, pp. 1486–1498, 2020, doi: 10.1109/TSMC.2018.2871750.
- [16] Wen, Q., Luo, Z., Chen, R., Yang, Y., and Li, G.. “Deep Learning Approaches on Defect Detection in High Resolution Aerial Images of Insulators,” *Sensors*, vol. 21, no. 4, 2021, doi: 10.3390/s21041033.
- [17] Li, X., Su, H., and Liu, G.. “Insulator Defect Recognition Based on Global Detection and Local Segmentation,” *IEEE Access*, vol. 8, pp. 59934 – 59946, 2020, doi: 10.1109/ACCESS.2020.2982288.
- [18] Zhao, Z., Qi, H., Qi, Y., Zhang, K., Zhai, Y., and Zhao, W.. “Detection Method Based on Automatic Visual Shape Clustering for Pin-Missing Defect in Transmission Lines,” *IEEE Trans Instrum Meas*, vol. 69, no. 9, pp. 6080–6091, 2020, doi: 10.1109/TIM.2020.2969057.
- [19] Wang, S., Liu, Y., Qing, Y., Wang, C., Lan, T., and Yao, R.. “Detection of Insulator Defects With Improved ResNeSt and Region Proposal Network,” *IEEE Access*, vol. 8, pp. 184841–184850, 2020, doi: 10.1109/ACCESS.2020.3029857.
- [20] Li, F. *et al.* “An automatic detection method of bird’s nest on transmission line tower based on Faster_RCNN,” *IEEE Access*, vol. 8, pp. 164214 – 164221, 2020, doi: 10.1109/ACCESS.2020.3022419.
- [21] Han, J. *et al.* “A method of insulator faults detection in aerial images for high-voltage transmission lines inspection,” *Applied Sciences (Switzerland)*, vol. 9, no. 10, 2019, doi: 10.3390/app9102009.
- [22] Liu, C., Wu, Y., Liu, J., and Sun, Z.. “Improved YOLOv3 Network for Insulator Detection in Aerial Images with Diverse Background Interference,” *Electronics (Basel)*, vol. 10, no. 7, 2021, doi: 10.3390/electronics10070771.
- [23] Liu, J. *et al.* “High precision detection algorithm based on improved RetinaNet for defect recognition of transmission lines,” *Energy Reports*, vol. 6, pp. 2430–2440, 2020, doi: <https://doi.org/10.1016/j.egy.2020.09.002>.
- [24] Miao, X., Liu, X., Chen, J., Zhuang, S., Fan, J., and Jiang, H.. “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.
- [25] Wang, L., Chen, Z., Hua, D., and Zheng, Z.. “Semantic Segmentation of Transmission Lines and Their Accessories Based on UAV-Taken Images,” *IEEE Access*, vol. 7, pp. 80829–80839, 2019, doi: 10.1109/ACCESS.2019.2923024.
- [26] Zhu, J. *et al.* “A Deep Learning Method to Detect Foreign Objects for Inspecting Power Transmission Lines,” *IEEE Access*, vol. 8, pp. 94065–94075, 2020, doi: 10.1109/ACCESS.2020.2995608.
- [27] Zhao, W., Xu, M., Cheng, X., and Zhao, Z.. “An Insulator in Transmission Lines Recognition and Fault Detection Model Based on Improved Faster RCNN,” *IEEE Trans Instrum Meas*, vol. 70, pp. 1–8, 2021, doi: 10.1109/TIM.2021.3112227.
- [28] Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A.. “You Only Look Once: Unified, Real-Time Object

- Detection,” *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779–788.
- [29] Bochkovskiy, A., Wang, C.Y. ve Liao, H.Y.M.. “YOLOv4: Optimal Speed and Accuracy of Object Detection,” *arXiv preprint arXiv:2004.10934*, 2020.
- [30] Zhao, Z.-Q., Zheng, P., Xu, S.-T., ve Wu, X.. “Object Detection with Deep Learning: A Review,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 30, no. 11, pp. 3212–3232, 2019.
- [31] Huang, J., et al.. “Speed/Accuracy Trade-offs for Modern Convolutional Object Detectors,” *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 7310–7311.
- [32] Ren, S., He, K., Girshick, R. ve Sun, J.. “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2015, pp. 91–99.
- [33] Gao, Y., Pan, H., Hu, Y., ve Chen, L.. “Detection of Power Line Insulator Defects Using Deep Convolutional Neural Networks,” *IEEE Access*, vol. 8, pp. 116071–116080, 2020.
- [34] Xie, X., Zhang, Y., Qian, Y., ve Wang, Z.. “Insulator Fault Detection in Transmission Lines Using Deep Learning,” *Electric Power Systems Research*, vol. 167, pp. 39–47, 2019.
- [35] Lewis, D. and Kulkarni, P.. “Insulator Defect Detection,” *IEEE Dataport*, 2021, doi: 10.21227/vkdw-x769.
- [36] Rahman M. A., Wang, Y.. “Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation,” In: Bebis, G., et al. *Advances in Visual Computing. ISVC 2016*. Lecture Notes in Computer Science(), vol 10072. Springer, Cham. https://doi.org/10.1007/978-3-319-50835-1_22

Özgeçmiş



Zeliha Doğan Ersoy, lisans eğitimini 2017 yılında Kemerburgaz Üniversitesi Bilgisayar Mühendisliği (İngilizce) Bölümü'nde tamamlamıştır. 2019 yılında İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Programı'nda tezli yüksek lisans derecesini almıştır. Hâlen İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Bölümü'nde doktora eğitimine devam etmektedir.

2018–2021 yılları arasında araştırma görevlisi olarak görev yapmış; 2021 yılından itibaren öğretim görevlisi olarak akademik çalışmalarını sürdürmektedir. Araştırma ilgi alanları yapay zekâ ve derin öğrenme başta olmak üzere, makine öğrenmesi tabanlı yöntemlerdir.

Özgeçmiş



M. Erdem İsenkul, 2011 yılında sağlık alanında veri madenciliği üzerine yüksek lisansını, 2016 yılında ise sinirbilim ve makine öğrenmesi alanlarında uzmanlaşarak bilgisayar mühendisliği doktora derecesini almıştır. Hâlen İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Bölümünde Doktor Öğretim Üyesi olarak görev yapmakta olup, akademik alanda 15 yılı aşkın deneyime sahiptir.

2011–2018 yılları arasında İstanbul Üniversitesi Bilgisayar Mühendisliği Bölümünde Araştırma Görevlisi olarak çalışmış, 2021 yılından itibaren tam zamanlı Doktor Öğretim Üyesi olarak akademik faaliyetlerini sürdürmüştür. Bunun yanı sıra farklı üniversitelerde yarı zamanlı dersler vermektedir.

Avrupa Birliği, TÜBİTAK ve ulusal fonlarca desteklenen çok sayıda araştırma ve geliştirme projesinde aktif görev almış; bu projelerin bir bölümü Üniversite–Sanayi İş Birliği kapsamında ödüllendirilmiştir. Kurumu bünyesinde yüksek bütçeli altyapı projelerinde Proje Yöneticisi olarak görev yapmış, çeşitli bilimsel projelerde Araştırmacı olarak katkı sunmuştur.

Ayrıca Sanayi ve Teknoloji Bakanlığı, TÜBİTAK, KOSGEB ve teknoparklar tarafından desteklenen firmaların Ar-Ge ve yenilik faaliyetlerinin değerlendirilmesinde hakem, komite üyesi ve danışman olarak yer almaktadır. Ulusal ve uluslararası yüksek etki değerli dergilerde yayımlanmış çok sayıda yayını bulunan İsenkul'un çalışmaları 1000'in üzerinde atıf almıştır. Araştırma alanları veri bilimi, görüntü işleme, yapay zekâ, makine öğrenmesi, disiplinler arası yapay zekâ uygulamaları, bilgisayar algoritmaları ve oyun teknolojilerini kapsamaktadır.