

Enerji İletim Hatlarında Yapay Zeka ile Arıza Tespiti

Fault Detection in Power Transmission Lines with Artificial Intelligence

Emre Kılıcı¹, Eyüpcan Kara¹, Alper Kızılgil¹, Büşra Töre¹, Enes Dilsiz¹, İbrahim Bahçivan², Ali Efe²

¹ELTEMTEK

enes.dilsiz@eltemtek.com.tr

²Türkiye Elektrik İletim A.Ş. (TEİAŞ)

ali.ef@teias.gov.tr

Özet

Enerji iletiminde sürdürülebilirliğin sağlanması amacıyla enerji kesintilerine sebebiyet verebilecek olası arıza durumlarının önceden tespit edilebilmesi büyük önem arz etmektedir. Bu sebeple enerji iletim hatlarında periyodik olarak önleyici bakım ve kontrol çalışmalarını gerçekleştirilmektedir. ELTEMTEK tarafından yürütülen enerji iletim hatlarının havadan denetlenmesi faaliyeti, işletme gerilim seviyesi 170 kV ve 400 kV olan havai hatların, elektro optik sistemler entegre edilmiş hava araçları ile güzergahlar boyunca yapılan uçuşlar neticesinde elde edilen yüksek çözünürlüklü fotoğraf ve video verilerinin, analiz ve raporlama personelleri tarafından, şirket bünyesinde geliştirilen HABSİS (Havadan Arıza Bakım Sistemi) yazılımı kullanılarak arızalarının tespit edilip, Türkiye Elektrik İletim A.Ş.'nin hali hazırda kullanmış olduğu OYS (Operasyon Yönetim Sistemi)'ne entegre edilmesi şeklinde gerçekleştirilmektedir. Analiz ve raporlama ekiplerince gerçekleştirilen arızaların tespit edilip raporlanması sürecinde, insan faktörlü hata payını en aza indirmek ve birim zamanda gerçekleştirilen iş hacmini arttırmak motivasyonu ile iletim hatlarında en çok karşılaşılan fiziki arızaların yapay zeka ve görüntü işleme yöntemleri kullanılarak tespit edilebilmesi projesi hazırlanmıştır. Proje, problemin belirlenmesi, veri toplama, veri hazırlama, modelleme, değerlendirme, model iyileştirilmesi, dağıtım ve entegrasyon aşamalarını içermektedir.

Anahtar kelimeler: Enerji iletim hattı, yapay zeka, görüntü işleme, nesne tespiti

Abstract

In order to ensure sustainability in energy transmission, it is of great importance to detect possible fault situations that may cause energy interruptions in advance. For this reason, preventive maintenance and control studies are carried out periodically on energy transmission lines. Aerial inspection of energy transmission lines carried out

by ELTEMTEK, analysis and reporting personnel of high-resolution photo and video data obtained as a result of flights along routes with aircraft with integrated electro-optical systems of overhead lines with operating voltage levels of 170 kV and 400 kV, It is carried out by detecting the malfunctions by using the HABSİS (Airborne Breakdown Maintenance System) software developed within the company and integrating it into the OYS (Operation Management System) currently used by Türkiye Elektrik İletim A.Ş. In the process of detecting and reporting the malfunctions performed by the analysis and reporting teams, a project was prepared to detect the most common physical malfunctions in transmission lines by using artificial intelligence and image processing methods, with the motivation of minimizing the margin of error with human factor and increasing the volume of work performed in unit time. The project includes the stages of problem identification, data collection, data preparation, modelling, evaluation, model improvement, distribution and integration.

Keywords: Power transmission line, artificial intelligence, image processing, object detection

1. Giriş

Enerji iletim hatlarında meydana gelen arızalar elektrik kesintilerine sebep olabilmektedir. Kesintisiz iletimi sağlamak için, enerji iletim hatlarının belirli periyotlarla düzenli olarak kontrol edilmesi, hatlarda oluşabilecek arızaların önceden tespit edilmesi ve bu arızalar meydana gelmeden giderilmesi gerekmektedir. ELTEMTEK tarafından yürütülen çalışmayla, işletme sorumluluğu TEİAŞ'ın uhdesinde bulunan enterkonnekte şebekedeki iletim hatlarında ve trafo merkezlerinde, elektro optik sistemlerin entegre edilmiş olduğu hava araçları tarafından ifa edilen uçuşlardan elde edilen yüksek çözünürlüklü görüntü ve videoların incelenip, olası arıza durumlarının tespitleri yapılarak, sorumluluk sahasına göre TEİAŞ Bölge Müdürlüklerine iletilmesi sağlanmaktadır. Arızaların tespit edilmesi ve

raporlanması sürecinde, birim zamanda yapılan iş hacmini arttırmak ve insan faktörlü hata payını en aza indirmek için, alternatifli senaryolar ile çalışan yapay zeka modelleri geliştirilip faaliyete geçirilmesi hedeflenmiştir.



Şekil 1 Uçuştan elde edilen direk görüntüsü

İletim hatlarında kontrolü yapılan 60'ın üzerinde arıza tipi bulunmaktadır. Bu çalışmada öncelikli olarak en sık karşılaşılan ve nesne tespit algoritmalarıyla tespit edilebilecek arızalara öncelik verilmiştir. Bu arızalar; direklerde kuş yuvası, izolatörlerde kırık-eksik izolatör ve izolatörlerde ark izi arızalarıdır.


Bu çalışmada, kuş yuvası arızalarının tespiti, izolatörlerin türlerine (cam, silikon, porselen) göre tespiti, izolatör kırıklarının ve eksiklerinin tespiti, izolatörlerde ark izi arızalarının tespiti amacıyla derin öğrenme modelleri geliştirilmesi ve HABSİS sistemi ile entegre edilerek canlı sistem üzerinde çıkarım yapması ve tespit edilen arızaların TEİAŞ'ın OYS sistemine kaydının açılması süreçlerini içermektedir.

2. Nesne Tespit Algoritmaları

Bilgisayarlı görü, doğal dil işleme, ses teknolojileri, zaman serileri gibi bazı problemlerin çözümünde derin öğrenme algoritmalarından yararlanır. Bilgisayarlı görü algoritmaları arasında nesne tespiti, nesne takibi, görüntü sınıflandırma, görüntü bölütleme gibi alt başlıklar bulunmaktadır. Bu çalışmada tespit edilmek istenen arızalar birer nesne olarak kabul edilmiş olup bu alt başlıklardan olan nesne tespit yöntemleri ile tespitinin yapılması hedeflenmiştir.

Nesne tanıma modelleri tek aşamalı ve iki aşamalı olarak ayrılmaktadır. İki aşamalı nesne tespit modellerinde çıkarılan özellikler nesne sınıflandırılmasında kullanılmadan önce tespit edilecek nesnelere için sınırlayıcı kutu önerilmesi işlemi gerçekleştirilir. (Bkz. Şekil 2) Nesne bulunması muhtemelen alanlar belirlenip ayrı ayrı evrişimsel katmanlardan geçirilir. Tek aşamalı nesne tespit modellerinde ise iki aşamalı modellerin aksine bölge önerme adımı olmadan direkt olarak

görüntü üzerinde sınırlayıcı kutuları tahmin eder. Bu işlem iki aşamalı modellere göre daha az zaman alır ve bu nedenle özellikle gerçek zamanlı uygulamalarda kullanımı daha çok tercih edilir.



Şekil 2 Tek ve iki aşamalı ağ yapısı [3]

En önemli iki aşamalı nesne tespit modellerinin başında RCNN, Fast RCNN, Faster RCNN, Pyramid Networks gibi modeller yer almaktayken tek aşamalı model olarak da YOLO, SSD, RetinaNet gibi modeller yer almaktadır.

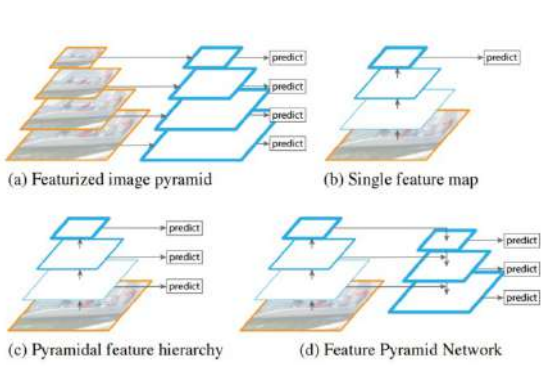
2.1. YOLO Algoritması

YOLO (You Only Look Once) algoritması tek aşamalı, gerçek zamanlı ve görüntüleri bir ızgara sistemine bölen bir nesne tespit algoritmasıdır. Izgaradaki her hücre kendi içindeki nesnelere algılamaktan sorumludur. Nesne tespitini tek bir regresyon problemi gibi ele almaktadır. Hızlı çalışması ve yüksek doğruluk oranı sebebiyle dünya üzerinde en çok kullanılan nesne tespit algoritmalarından birisidir.

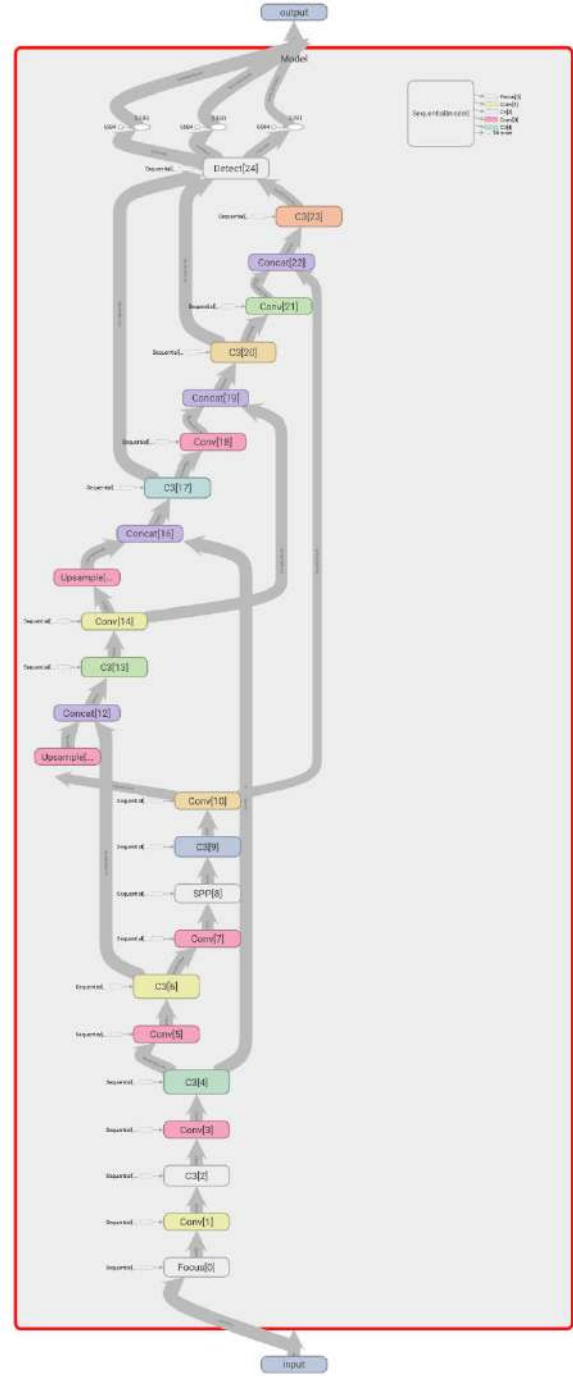
Zaman içerisinde farklı versiyonları geliştirilmiştir. Bu çalışmada, yüksek başarı oranı, iki aşamalı ağlara göre daha hızlı çalışması ve kullanımı kolaylığı sebeplerinden ötürü Ultralytics firması tarafından geliştirilen Yolo'nun 5. Versiyonu baz alınmıştır.

2.1.1. YOLOv5

Yolo v5 diğer tek aşamalı nesne tespit algoritmaları gibi üç parçadan oluşur. Bunlar; omurga(backbone), neck(boyun), baş(head). Omurga, görüntüden önemli özelliklerin çıkarılmasını sağlar. Yolo v5'te omurga olarak CSP (Cross Stage Partial Networks) kullanılmıştır. Model boynu özellik piramitleri oluşturmak için kullanılır. Özellik piramidi, girdi olarak rastgele boyutta tek ölçekli bir görüntü alan ve evrişimsel bir yapıda, orantılı olarak boyutlandırılmış özellik haritalarını birden çok düzeyde çıkaran bir özellik çıkarıcıdır. (Bkz. Şekil 3) Özellik piramitleri modellerin nesne ölçekleme konusunda geliştirilmesini sağlar. Aynı nesnenin farklı boyut ve ölçeklerde tanımlanmasına yardımcı olur. Özellik piramitleri modellerin daha önce hiç görmedikleri veriler üzerinde iyi performans sergilemesi konusunda çok kullanışlıdır. Yolo v5 özellik piramidi çıkarmak için PANet kullanır. Baş kısmı ise modelde son kısımdır ve tespit kısmında kullanılır. Bu kısımda sınırlayıcı kutularla beraber sınıf olasılıkları ve nesnelik puanlarını barındıran bir çıktı vektörü oluşturulur. Yolo v5'te, v3 ve v4'te kullanılanla aynı yapıda bir baş kısmı kullanılmıştır.



Şekil 3 Özellik piramidi ağı [2]



Şekil 4 YOLOv5 Mimarisi

Aktivasyon fonksiyonu olarak gizli katmanlarda Leaky ReLU, final tespit katmanında ise Sigmoid aktivasyon fonksiyonu kullanılmıştır. Optimizasyon fonksiyonu olarak SGD veya Adam fonksiyonları kullanılabilir.

Yolo v5, Pytorch framework üzerine kurgulanmış bir sistem olarak sunulmuştur. Bu çalışmada, Huawei Atlas 800 Yapay Zeka sunucuları kullanıldığı için orijinal Yolo v5 kodlarının kullanılan sunuculara uyarlanmış hali kullanılmıştır.


3. Model Geliştirme

İlk aşamada tespit edilecek arıza tipleri kuş yuvası, izolatör kırıkları ve izolatörde ark izi arızaları olarak belirlenmiştir. Bu doğrultuda uçuş sonucu toplanıp arıza tespit edilen görüntüler, geliştirilecek modeller için veri seti oluşturmak amacıyla kullanılmıştır. Görüntülerde tespit edilen arızaların sınırlayıcı kutu içerisinde etiketlenmesi yapılmıştır. Sınıf başına ortalama 1000 adet ile 5000 adet arasında etiketleme yapılmıştır. Verilerin yetersiz olduğu sınıflarda veri zenginleştirme yöntemleri ile veri sayısı sentetik olarak artırılmıştır.

Kuş yuvası arızalarının tespitinde direkt olarak uçuştan elde edilen orijinal fotoğraf üzerinde işlem yapılmaktadır. İzolatörlerin tespiti de orijinal boyutlu görüntü üzerinde gerçekleştirilmektedir. İzolatörler türlerine göre (porselen, cam, kompozit) farklı sınıflarda tespit edilmektedir. İzolatörlerde arıza tespiti aşamasında doğruluk oranını ve performansı artırmak için girdi olarak orijinal boyutlu fotoğraf yerine daha küçük boyutlu olarak kırılmış izolatör tespit modelinin çıktıları kullanılmaktadır.



Şekil 5 Farklı türdeki izolatörlerin tespiti



Şekil 6 Kuş yuvası arızasının tespiti



Şekil 7 İzolatörde eksik parça arızası



Şekil 8 İzolatörde kırık parça arızası



Şekil 9 İzolatörde ark izi arızası


Tüm model geliştirme faaliyetleri Huawei Atlas 800 Training sunucusu üzerinde, çıkarım ve entegrasyon süreçleri ise Huawei Atlas 800 Inference sunucusu üzerinde gerçekleştirilmiştir. Model eğitim işlemi NPU

(Neural Processing Unit) kartları kullanarak gerçekleştirilmektedir.

Model olarak MS COCO veri seti üzerinde önceden eğitilmiş Yolov5x modeli kullanılmıştır. Eğitim sürecinde önceden eğitilmiş modeller verilerle eğitime başlandığı için 20-50 iterasyon (epoch) arasında eğitimler gerçekleştirilmiştir. Tekli ve çoklu (dağıtık) NPU'lar üzerinde veriler 32-64'lik yığınlar halinde (batch-size) eğitilmiştir.

4. Entegrasyon Süreci

Enerji iletim hatlarında arıza tespiti yapılması ve tespit edilen arızaların TEİAŞ'a internet üzerinden iletilmesi için Eltemtek tarafından geliştirilen HABSİS yazılımı kullanılmaktadır. Arıza tespiti için tarama yapılacak verilerin bu uygulamanın çalıştığı sunucudan çıkarım işlemlerinin yapılacağı Inference sunucusuna aktarılması ve burada tespit edilen arızaların web uygulaması üzerinde arıza kaydının açılması için tekrar bu sunucuya aktarılması için gerekli entegrasyon süreçleri yürütülmüştür. Verilerin aktarımı ayrı bir sunucuda RabbitMq üzerinden yürütülen kuyruk yönetimi ile sağlanmıştır.



Şekil 10 Sistem Genel Görünümü

5. Çıkarım

Oluşturulan modeller birtakım başarı metriklerine göre değerlendirilmiştir. Bu başarı metriklerinin hesaplanmasında Tablo 1'de yer alan karışıklık matrisinden (confusion matrix) yararlanılmıştır.

Tablo 1. Karışıklık Matrisi

Tahmin/ Gerçek	Pozitif	Negatif
Pozitif	TP	FP
Negatif	FN	TN

Doğruluk (Accuracy): Doğru tahmin edilen sınıfların veri sayısının o sınıfın tüm verilerine oranıdır.

$$Accuracy = (TP + TN)/(TN + FP + TP + FN) \quad (1)$$

Kesinlik (Precision): Pozitif olarak tahmin edilen sınıfların gerçekte kaç tanesinin pozitif olduğunu gösterir.

$$Precision = (TP)/(FP + TP) \quad (2)$$

Duyarlılık (Recall): Pozitif olarak tahmin edilmesi gereken işlemlerin kaç tanesinin pozitif olarak tahmin edildiğinin oranını verir.

$$Recall = (TP)/(TP + FN) \quad (3)$$

Tablo 2. Başarı Oranları

Metrik/Arıza Türü	Kuş Yuvası	İzolatör'de Kırık	İzolatör'de Ark izi
Doğruluk	%75	%100	%60
Kesinlik	%73	%35	%30

Derin öğrenme modellerinde başarılı modeller geliştirmek için sınıf başına en az 5000-10000 arası etiketlenmiş veri önerilmektedir. Ark izi gibi bazı arıza türlerinde yeterli veri olmaması veya kırık izolatör gibi arıza türlerinde görüntü üzerinde arızaya çok benzer durumların oluşup model tarafından gerçek arıza olarak algılanması başarı durumlarını olumsuz olarak etkilemektedir.

Kuş yuvası arızalarında karşılaşılan zorluklardan biri kuş yuvalarının birbirinden çok farklı karakteristiklere sahip olabilmesidir. Hem boyut olarak hem materyal olarak farklı bir sürü kuş yuvası olması, genellenebilir bir model ortaya konulmasını güçleştirmektedir. İzolatörde kırık parça arızalarında, özellikle çözünürlüğün düşük olduğu görüntülerde güneş ışığının yaptığı parlamalar ve izolatör üzerindeki lekeler, izolatörde kırık arızası olarak algılanmasına sebebiyet verebilmektedir. İzolatörlerin bağlantı noktalarındaki boşluklar bazı durumlarda izolatörde eksik arızası olarak algılanmaktadır. Yine güneş parlamaları, lekeler ve izolatör üzerindeki yazılar görüntünün ark izi arızası olarak algılanmasına sebep olabilmektedir.

Sınıf olasılıklarındaki eşik değerleri artırılıp azaltılarak TP ve FP oranlarında değişiklik yapılabilir. Bu durum doğruluk ve kesinlik değerlerini de etkileyecektir.

Uçuşlar proje bazlı gerçekleştirilmekte olup farklı bölgelerden farklı karakterde görüntüler gelmektedir. Bu

yüzden veri seti farklı bölgelerden gelen veriler ile genişletildiğinde daha genellenebilir ve başarı oranı daha yüksek modeller elde edilecektir.

6. Sonuçlar

Yapay zeka, diğer alanlarda olduğu gibi enerji sektöründe de gün geçtikçe daha fazla uygulama alanı bulmaktadır. Bu çalışmada enerji iletim hatlarında arıza tespit işlemlerinin yapay zeka yardımı ile başarı oranlarının artırılıp arıza tespiti için harcanan sürenin azaltılarak sürecin daha verimli bir hale getirilmesi üzerine bir uygulama geliştirilmiştir. İletim hatları üzerinde en çok karşılaşılan bazı arızaların geliştirilen yapay zeka modelleri ile tespit edildiği görülmüştür. Bir sonraki aşamada elde edilen daha fazla veri ile daha başarılı ve hızlı çalışan modeller kurularak daha fazla arıza türünün tespit edilmesi hedeflenmektedir.

7. Kaynaklar

- [1] Joseph Redmon, Ali Farhadi, “YOLOv3: An Incremental Improvement”
- [2] Tsung-Yi Lin, Piotr Dollár, Ross Girshick, Kaiming He, Bharath Hariharan, Serge Belongie , “Feature Pyramid Networks for Object Detection”
- [3] Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection”
- [4] Syed Sahil Abbas Zaidi, Mohammad Samar Ansari, Asra Aslam, Nadia Kanwal, Mamoona Asghar, Brian Lee, “A Survey of Modern Deep Learning based Object Detection Models”
- [5] <https://docs.ultralytics.com/>
- [6] <https://github.com/ultralytics/yolov5>