

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI**

**İHA GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME
YAKLAŞIMLARI KULLANILARAK YG HAVAİ HATLARIN
GÖZLEMİ VE HATA TESPİTİ**

YÜKSEK LİSANS TEZİ

NAFİZ KESKİN

DENİZLİ, KASIM - 2024

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



İHA GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME
YAKLAŞIMLARI KULLANILARAK YG HAVAİ HATLARIN
GÖZLEMİ VE HATA TESPİTİ

YÜKSEK LİSANS TEZİ

NAFİZ KESKİN

DENİZLİ, KASIM - 2024

Bu tez çalışması herhangi bir kuruluş tarafından desteklenmemiştir.

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın dođrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.

NAFİZ KESKİN

ÖZET

İHA GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME YAKLAŞIMLARI KULLANILARAK YG HAVAİ HATLARIN GÖZLEMİ VE HATA TESPİTİ

YÜKSEK LİSANS TEZİ
NAFİZ KESKİN

PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI:DR. ÖĞR. Ü. H. HİLAL EZERCAN KAYIR)

DENİZLİ, KASIM - 2024

Enerji sektörü, sürdürülebilirlik ve güvenilirlik açısından dünyanın en kritik sektörlerinden biridir. Geleneksel yöntemlerle şebeke izleme, bakım ve yenileme karar mekanizmaları karmaşık hale gelmiştir. Bu bağlamda, görüntü işleme süreçleriyle farklı boyutlardaki nesnelerin tespiti ve arızaya neden olabilecek ekipmanların otomatik olarak belirlenmesi kritik önem taşımaktadır.

Bu tez çalışmasında, makine öğrenmesi aşamasında toplam 588 görüntü YOLOV5 ile eğitildi ve değerlendirme aşamasında 207 adet görüntü ile kesinlik belirlendi. Uygulanan model, izolatör nesneleri tespit ederken daha az yanlış pozitif üreterek daha fazla doğru tespit yapmaktadır. İzolatör sınıfında 0,5 eşik için mAP değeri 0,702 (% 70,2)'dir. Kırık izolatörlerde 0,5 eşik için ise mAP 0,507 olup izolatör sınıfına göre daha düşüktür. İzolatör sınıfında yüksek güven oranlarında bile nispeten daha yüksek duyarlılık değerleri görülmekte olup uygulanan modelin izolatör sınıfını tanımakta daha iyi olduğunu göstermektedir. Kırık izolatör sınıfının düşük güven oranlarında duyarlılık değerlerini daha yüksek elde ettiği, fakat güven oranı arttıkça duyarlılığın hızla düştüğü görülmekte olup uygulanan modelin kırık izolatörleri ayırt etmekte daha zorlandığı anlaşılmaktadır. Her iki sınıf birlikte değerlendirildiğinde ortalama performans olarak oldukça başarılı olan 0.96 duyarlılık değeri göstermektedir.

Uygulanan model, izolatör sınıfında kırık izolatör sınıfına göre daha iyi performans sergilemektedir. Modelin kırık izolatörleri tespit etmede gösterdiği nispeten düşük değerleri iyileştirmek için veri arttırmak, izolatör çeşitlerini farklı sınıflarda değerlendiren sınıflar oluşturmak gelecekte yapılacak çalışmalar için faydalı olacaktır.

ANAHTAR KELİMELELER: elektrik dağıtım hat gözlemi, enerji nakil hattı ekipman hata tespiti, bilgisayarlı görü, makine öğrenmesi, derin öğrenme

ABSTRACT

OVERHEAD POWER LINES INSPECTION AND DEFECT DETECTION BY USING DEEP LEARNING APPROACHES ON UAV IMAGES

MSC THESIS
NAFİZ KESKİN

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE
ELECTRICAL AND ELECTRONICS ENGINEERING

(SUPERVISOR:ASSIST. PROF. DR. H. HİLAL EZERCAN KAYIR)

DENİZLİ, NOVEMBER 2024

The energy sector is one of the most critical industries globally in terms of sustainability and reliability. Traditional methods for grid monitoring, maintenance, and renewal decision-making have become increasingly complex. In this context, using image processing techniques to detect objects of varying sizes and automatically identify equipment that may cause faults is of critical importance.

In this thesis study, a total of 588 images were used to train the YOLOV5 model during the machine learning phase, and accuracy was evaluated using 207 images during the testing phase. The applied model demonstrated better performance in detecting insulator objects by producing fewer false positives and achieving more correct detections.

The mAP@0.5 threshold is 0.702 for insulator class. For broken insulators, the mean average precision (mAP) at 0.5 confidence threshold was calculated as 0.507, which is lower compared to the insulator class. In the insulator class, relatively higher recall values were observed even at high confidence thresholds, indicating that the applied model is better at recognizing insulator objects. In contrast, for the broken insulator class, higher recall values were achieved at lower confidence thresholds. However, as the confidence threshold increased, the recall dropped sharply, showing that the model struggles to distinguish broken insulators effectively.

When both classes were evaluated together, the model demonstrated a strong average performance with a recall value of 0.96. This result indicates that the applied model performs better in the insulator class compared to the broken insulator class.

To improve the relatively lower performance of the model in detecting broken insulators, future work could focus on increasing the dataset size and creating new classes to evaluate different types of insulators. Expanding the dataset and diversifying the insulator types for classification are expected to enhance the model's detection capabilities and overall accuracy in future studies.

KEYWORDS: electric distribution line inspection, power line component defect detection, computer vision, machine learning, deep learning

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
TABLO LİSTESİ	v
SEMBOL LİSTESİ	vi
KISALTMALAR LİSTESİ	vii
ÖNSÖZ	viii
1. GİRİŞ	1
2. MEVCUT ÇALIŞMALAR	2
3. ELEKTRİK DAĞITIMI	6
3.1 Havai Hat Arızaları	7
3.2 İzolatör Türleri	8
3.2.1 Gerilim Seviyelerine Göre İzolatörler	9
3.2.2 Kullanım Yerlerine Göre İzolatörler.....	14
3.3 İzolatör Koruma Amaçlı Elemanlar	17
4. MAKİNE ÖĞRENMESİ	18
4.1 Derin Öğrenme ve Modelleri	19
4.1.1 Evrışimli Sinir Ağları.....	19
4.1.1.1 SSD	20
4.1.1.2 YOLO.....	21
4.1.2 Devirli Sinir Ağları (DSA)	21
4.1.3 Uzun Kısa-Sürelili Bellek	23
4.1.4 R-CNN.....	23
4.2 Makine Öğrenmesi ve Derin Öğrenmede Algoritmalar	24
4.2.1 Yapay Sinir Ağları	28
4.2.2 Rastgele Orman.....	29
4.2.3 Destek Vektör Makineleri.....	29
5. MAKİNE ÖĞRENMESİ İLE HATA TESPİTİ	30
5.1 Görüntü İşleme Süreci	30
5.2 Nesnelerin Tespiti Süreci	31
6. YÖNTEM	35
6.1 Görüntü İşleme	38
6.2 Nesne Tespiti	38
6.3 Değerlendirme	39
7. BULGULAR	43
8. SONUÇ VE ÖNERİLER	48
8.1 Sonuçlar	48
8.2 Öneriler.....	52
9. KAYNAKLAR	53
10. ÖZGEÇMİŞ	59

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Tırmanan robot.	2
Şekil 2.2: Otonom bir sistem şeması.....	5
Şekil 3.1: Üzerinde kırık arızası olan bir izolatör.	9
Şekil 3.2: VHD 35 izolatör örneği.	10
Şekil 3.3: VKS izolatör örneği.	11
Şekil 3.4: Zincir tipi cam malzemeden izolatör.	12
Şekil 3.5: Zincir tipi porselen izolatör.....	13
Şekil 3.6: Silikon (çubuk) izolatör örnekleri.....	14
Şekil 3.7: Dahili tip izolatörler (a) Bara mesnet (b) Pano tipi mesnet.	15
Şekil 3.8: Harici tip izolatör örnekleri.....	16
Şekil 3.9: Ark boynuz örneği ve korona halka uygulamaları.	17
Şekil 4.1: Gizli tek tabakası olan Devirli Sinir Ağları (RNN) şematığı.....	22
Şekil 4.2: Devirli Sinir Ağları (RNN) için kullanılan LSTM hücre şematığı... 22	
Şekil 4.3: Görüntü sınıflama esnasında zorluklar.	25
Şekil 4.4: En yakın komşu sınıflayıcı işleyişi.	26
Şekil 4.5: Doğrusal sınıflayıcılar için algoritmaya özellik dönüştürme işlemi. 27	
Şekil 4.6: Destek Vektör Makinesi (DVM) kayıp gösterimi 28	
Şekil 5.1: Nesnelerin tespitininin 2001-2023 arasındaki gelişimi..... 32	
Şekil 5.2: Tek aşamalı nesne tespiti işleyişi..... 32	
Şekil 5.3: İki aşamalı nesne tespiti işleyişi..... 32	
Şekil 6.1: Görüntüleri çeken İHA modeli (DJI-3 Pro)..... 36	
Şekil 6.2: YOLOV5 algoritmasını mimari yapısı. 36	
Şekil 6.3: YOLOV5 detaylı mimari yapısı (Web 7..... 37	
Şekil 6.4: YOLOV5 algoritma katmanları işleyiş akışı. 39	
Şekil 6.5: YOLOV5 tek aşamalı değerlendirme aşaması..... 40	
Şekil 6.6: İzolatör görüntüleri ve güven oranları. 41	
Şekil 6.7: Çeşitli izolatör görüntülerine ait güven oranları. 42	
Şekil 7.1: YOLOV5 ile elde edilen karışıklık matrisi..... 46	
Şekil 8.1: Tüm sınıflar için kesinlik (P)- duyarlılık (R) grafiği. 49	
Şekil 8.2: Uygulanan model için F1-güven oranı grafiği..... 49	
Şekil 8.3: Uygulanan modelin duyarlılık-güven oranı (R-C) eğrisi..... 50	
Şekil 8.4: Eğitim ve doğrulama kayıpları ölçütleri. 51	

TABLO LİSTESİ

Sayfa

Tablo 3.1: Havai enerji sınıflandırması.....	7
Tablo 3.2: Gerilim seviyelerine göre izolatör sınıflandırması.	9
Tablo 4.1: Makine öğrenmesi sınıflandırma grupları.	18
Tablo 4.2: R-CNN sinir ağı mimarisi çalışmasını oluşturan üç aşama.	24
Tablo 6.1: Kullanılan bilgisayara ait özellikler.....	35
Tablo 7.1: İzolatör sınıfında 0.5 güven eşiği için hesaplanan veriler.	46
Tablo 7.2: Kırık izolatör sınıfında 0.5 güven eşiği için hesaplanan veriler.	47

SEMBOL LİSTESİ

AG	:	Alçak-gerilim şebekesi
b	:	Düzeltilme faktörü
ÇYG	:	Çok-yüksek-gerilim şebekesi
$f(x, W)$:	Doğrusal sınıflayıcı
h_t	:	mevcut gizli durum
h_{t-1}	:	önceki gizli durum
I	:	giriş görüntüsü
i ve j	:	filtre pozisyonu
K	:	filtre
kV	:	Kilo Volt
L	:	Verilerdeki kayıp fonksiyonu
L_i	:	SVM'deki kayıp
P	:	maksimum havuzlama değeri
R(W)	:	Regülerizasyon
s	:	skorlar vektörü
YG	:	Yüksek-gerilim şebekesi
x_t	:	giriş
y_i	:	etiket
W	:	Parametreler (ağırlıklar)
W_h	:	h ağırlık matrisi
W_x	:	x ağırlık matrisi

KISALTMALAR LİSTESİ

CNN	:	Evrişimli Sinir Ağları
CPU	:	C++ Temelli Proses Planlama
DSA	:	Devirli Sinir Ağları
FPGA	:	Alan Programlı Çıkış Dizimi
FPN	:	Özellik Piramit Ağı
GPU	:	Donanım Hızlandırılmalı Zamanlama
İHA	:	İnsansız Hava Araçları
LSTM	:	Long Short-Term Memory
MLP	:	Çok Katmanlı Perceptron
NMS	:	Maksimum Olmayanları Eleme
R-CNN	:	Devirli Evrişimli Sinir Ağları
R-FCN	:	Bölge Temelli Tam Evrişimli Sinir Ağı
RNN	:	Devirli Sinir Ağları
SSD	:	Single Shot MultiBox Detector
SPF	:	En Kestirimci yol Önce
SSD	:	Kısa Sürede Belirleyici
SVM	:	Destek Vektör Makinesi
UKSB	:	Uzun Kısa Süreli Bellek
VGG	:	Çok Derin Evrişimli Ağ
YG	:	Yüksek Gerilim
YOLO	:	You Only Look Once
YZ	:	Yapay Zekâ

ÖNSÖZ

Yüksek Lisans eğitimim boyunca bana desteklerini, bilgilerini, tecrübelerini ve sonsuz hoş görüşünü esirgemeyerek bana yol gösteren değerli tez danışmanım Dr. Öğr. Ü. Hatice Hilal EZERCAN KAYIR'a teşekkürlerimi sunarım.

Tüm eğitim ve çalışma hayatım boyunca maddi ve manevi desteklerini esirgememiş olan ebeveynlerim, rahmetli babam İsmail KESKİN'e ve rahmetli annem Fikriye KESKİN'e minnettarım.

Tez çalışmalarım boyunca bana olan manevi destekleri nedeniyle ablam Dr. Öğr. Ü. Reyhan KESKİN ve sevgili eşim Yeliz KESKİN'e teşekkür ederim.

1. GİRİŞ

Enerji sektörü günümüzün en kritik sektörlerinden biri haline gelmektedir. Elektrik iletim ve dağıtım bu sektörün sürekli izlenmesi gereken ve güvenli bir şekilde sürdürülebilir enerji arzının ve tedarikinin yapılabilmesi için en önemli parçalarını oluşturmaktadır.

Günümüzde şebeke izleme modelleri, bakım ve şebeke yenileme karar mekanizmaları, şebeke sağlık ve kritiklik endeksi verilerinin güncel tutularak kestirimci, önleyici bakımların yapılabilmesi ve doğru yatırım kararlarının alınabilmesi geleneksel yöntemlerle yapılamayacak kadar karmaşık bir konu olarak önümüze çıkmaktadır. Bunun için enerji nakil hatları üzerinde sürekli gözlem ve tespit çalışmaları yapılması gerekmekte, bu da gerekli insan gücü ve ekipman ihtiyacı, iş sağlığı ve güvenliği riskleri dikkate alındığında önemli bir maliyet oluşturmaktadır. Günümüzde bu ihtiyacın maliyetinin daha düşük hale gelmesi ve daha kısa sürelerde ve belli bir kesinlikte şekilde yapılabilmesi sektörün öncelikleri haline gelmiştir.

Havai enerji nakil hatlarında gözlem ve tespitin makine öğrenmesi yoluyla alınan kaliteli fotoğraf görüntüleri üzerinden yapılabilmesi, geleneksel yöntemlere göre daha düşük maliyetle ve çok daha hızlı yapılmasını sağlama potansiyeline sahiptir. Dolayısıyla, görüntü işleme süreçleri sonucunda incelenecek olan farklı boyutlardaki nesnelere tespiti ve öğrenme sonucunda normal ve arızaya neden olabilecek ekipmanların otomatik olarak tespit edilebilmesi kritik bir önem taşımaktadır.

Modern dünyada elektriğin kullanımının sürdürülebilir olması için daha henüz enerji şebekesinde etkisi görülmeden ileride problem oluşturabilecek yerlerin ve arızaların tespiti büyük önem arz eder.

2. MEVCUT ÇALIŞMALAR

Martinez ve diğ. (2014) inceleme süreçlerinde gerçek zamanlı olarak elektrik direklerinin yerlerinin tespiti ve görüntülerden otonom şekilde nesne bulma, bilgisayar görmesi ve makine öğrenme stratejileri kullanılarak çalışılmıştır. Çalışmada iki aşamalı MLP (çok katmanlı perceptron) sinir ağı kullanılarak sınıflama yapılmıştır. Farklı çevre koşullarında helikopter üzerinden alınan video görüntülerinden elektrik direği tespit ve belirleme çalışmaları gerçek zamanlı şekilde yürütülmüştür.

İster tırmanan robotlar (Şekil 2.1) ister İHA'lar kullanılsın otonom sistemlerde çeşitli kısıtlar uygulama zorlukları oluşturabilmektedir [Chen ve diğ 2018].



Şekil 2.1: Tırmanan robot.

Nguyen ve diğ. (2019) tarafından yapılan çalışmada; elektrik dağıtım ve iletim şebekesinde farklı gözlem ve tespit çalışmaları incelenmiş, insansız hava araçlarıyla alınan görüntüler üzerinden öğrenmeye tabi tutularak veri analizi ve gözlem yapılması çalışılmıştır. Derin öğrenme konusunda Faster R-CNN (Daha Hızlı Devirli Evrişimli Sinir Ağları) gibi CNN (Evrişimli Sinir Ağları) temelli nesne tanımlama yaklaşımları, avantaj ve dezavantajları incelenmiştir.

Tan (2020) tarafından yapılan çalışmada; elektrik dağıtım şebekelerindeki ekipmanlar havadan alınmış görüntüler üzerinden SSD (Kısa Sürede Belirleyici) ve ilave olarak başka nesne belirleyici modelleri ile kıyaslamalı olarak çalışılmış, model

öğrenimi sağlandıktan sonra normal ve anomali tespit edilen ekipmanlara ait görüntüler sınıflanarak ayrıştırılmıştır.

Talbure ve diğ. (2021) derin öğrenme amaçlı evrişimli sinir ağlarını (CNN leri) incelemişler ve kusur tespit etme ile ilgili gözlemlerini paylaşmışlardır. R-CNN (Devirli Evrişimli Sinir Ağları), YOLO, SSD, Maske Devirli Evrişimli Sinir Ağları ve benzeri modelleri birbiriyle işlem hızı, nesne tespiti doğruluğu konularında kıyasladıkları bir çalışma yapmışlardır.

Alzubaidi ve diğ. (2021) tarafından yapılan çalışmada, sınıflama işlemlerinde kullanılan farklı derin öğrenme yaklaşımları incelenmiştir. CNN algoritmalarının yapısı, avantajları, katmanları, AlexNet, ResNet, VGG, DenseNet gibi model uygulama detaylarıyla birlikte detaylı şekilde anlatılmıştır. Derin öğrenme görevleri açıklanarak, sınıflama ve nesne tespit etme konuları özelinde CPU (C++ Temelli Proses Planlama), GPU (Donanım Hızlandırılmalı Zamanlama) ve FPGA (Alan Programlı Çıkış Dizimi) tabanlı uygulama yaklaşımları karşılaştırılmıştır.

Landwehr ve diğ. (2021), görüntü üzerinden farklı alanlarda farklı ekipmanların tespiti konusundaki yaklaşımları incelemiştir. CNN (Evrişimli Sinir Ağları) tabanlı modeller aracılığıyla yapılmış olan çalışmaları karşılaştırarak ve bir metodoloji önererek R-CNN (Devirli Evrişimli Sinir Ağları), SSD (Single Shot MultiBox Detector), VGG16 ve ResNet50 gibi mimarilerin sonuçları üzerinden görüntü işleme aşamalarını çalışmıştır.

Viraktamath ve diğ. (2021), görüntü üzerinden makine öğrenmesi ve derin öğrenme algoritmalarını karşılaştırmışlardır. Nesnelere hızlı tanıma yöntemi olarak önerdikleri YOLO algoritmasını ve SSD ile Faster R-CNN karşılaştırmalı test sonuçlarını yayınlamışlardır, YOLO algoritmasını daha başarılı bulmuşlardır ancak iki aşamalı nesne tespitinin çok uzun süre alması dolayısıyla günlük hayatta tek aşamalı nesne tespitine kıyasla pek kullanışlı olmadığını da belirtmişlerdir.

Foudeh ve arkadaşları (2021), havai elektrik hatlarının gözlemlenmesinde ve anomali tespitinde insansız hava araçları kullanımının (İHA'ların) gelişimini inceleyerek avantajlarını ve günümüzde yaygın mekanik yöntemle kıyasla

uygulamada İHA kullanmanın zorluklarını ve zorlukları aşmanın yollarını irdelemişlerdir.

İHA'larda dikey hız ölçümünün hassas olmaması (Davis ve Pound, 2017), İHA'ların çarpma ve çarpışma riskleri (Gageik ve diğ., 2015), hareket eden İHA'larda konum değişimine bağlı olarak gerçek zamanlı verinin kesintisiz elde edilebilmesi (Na ve Yoo, 2015) gibi oluşabilecek kısıtlardan dolayı otonom sistemlerde uygulama zorlukları vardır (Foudeh vd, 2021).

Ahmed ve diğ. (2022), hava görüntüleri üzerinden derin öğrenme çalışmasına dayalı iletim hatlarındaki izolatör anomalilerini tespit ettikleri ve sınıflandırdıkları bir inceleme yapmışlardır. Dört kademeli çalışmalarında modeli SSD kullanarak eğitime tabi tutmuşlardır. R-FCN, Faster R-CNN ve YOLO gibi algoritmaların sonuçlarını çalışmalarında karşılaştırmışlardır. Çalışmada önerilen yöntemle %92.31 kesinlikle ekipmanların tespitini sağlamışlardır.

Xu ve diğ. (2022) çalışmalarında, İHA görüntü alma yöntemleri ve bu görüntülerden havai hatları tespit etmek için önerilen end-to-end CNN algoritması incelenmiştir.

Yang ve diğ. (2022), havadan alınan görüntüler üzerinden, MobileNet ve SQP (Sıralamalı Dörtlü Programlama) omurga ağlarıyla önerdikleri YOLO algoritması üzerinden, elektrik iletim hatlarındaki izolatörlerde anomali tespiti incelemesinin basamaklarının ayrıntılarını paylaşmışlardır.

Maduako ve diğ. (2022), elektrik iletim ve dağıtım hatlarında ekipman anomali tespiti için derin öğrenme önerilerini paylaşmışlardır. Bu çalışmada, insansız hava araçlarıyla alınan görüntüler üzerinden SSD temelli algoritmanın kabiliyetlerini incelemişler ve çok katmanlı FPN (Özellik Piramit Ağı) temelli CNN algoritmalarını önerdikleri test sonuçlarını paylaşmışlardır.

Guo ve diğ. (2022), tramvay hatlarında kullanılan bazı ekipmanların sınıflaması ve tespiti için fotoğraf görüntüleri üzerinden farklı bir danışmansız öğrenme yöntemi uygulayarak önerdikleri YOLO algoritmasının sonuçlarını paylaşarak kıyaslamışlardır.

Li ve diğeri (2023) YOLOX (You Only Look Once X Versiyonu) algoritması ile yüksek gerilim hattının arıza tespitinde İHA'ların hız faktöründen dolayı oluşan kaybı modelleyerek geleneksel yöntemle kıyasla elektrik hattının kontrolünü daha etkin hale getirmiş ve maliyetleri düşürmüşlerdir (Li ve diğ., 2023). Şekil 2.2'de otonom bir sistem şeması görülmektedir (Li ve diğ., 2023).

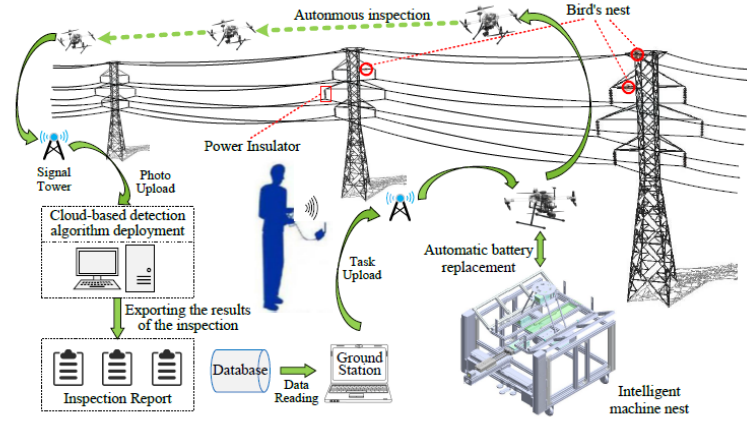


Figure 2. The structure of the system.

Şekil 2.2: Otonom bir sistem şeması.

3. ELEKTRİK DAĞITIMI

Günümüzde elektriğin ev ve işyerleri ile kamu binalarına iletilmesi önemli bir konu olup elektriğin dağıtımı için kullanılan yaygın iki yöntem: elektrik direkleri kullanılan havai elektrik dağıtımı ya da yeraltı elektrik hatları ile elektrik dağıtımıdır.

Elektrik Thomas Edison, Nikola Tesla ve nice bilim insanlarının çalışmaları ile 19. Yüzyıl sonlarından itibaren insanlığın günlük yaşantısının bir unsuru olmuştur. Enerji nakil hatları, elektrik enerjisini enerji üretim santrallerinden (kömür, nükleer ...) veya yenilenebilir enerji kaynaklarından (güneş, rüzgâr, vb.) trafo merkezlerine taşıyan fiziksel iletim ve dağıtım hatlarıdır.

Yeraltı enerji nakil hatları yerleşim bölgelerine daha estetik bir görünüm sağlarlar ve havai enerji nakil hatlarına kıyasla buza, şiddetli rüzgâr ve fırtınalara karşı daha az etkilenirler, dolayısıyla sert veya öngörülemez hava koşullarına sahip bölgeler için havai elektrik dağıtım hatlarına seçenek oluştururlar. Havai elektrik dağıtım hatları kırılıp düşme sonucu elektrik çarpması veya yangın riski taşırken toprak altında olan ve düzgünce yalıtılan yeraltı enerji nakil hatları tehlike ve riskleri en aza indirmek açısından da iyi bir seçenek durumundadırlar.

Ancak yeraltı enerji nakil hatlarının yatırım süreci, havai elektrik dağıtım hatlarındaki direklerin dikilmesinden daha karmaşık, emek isteyen, zaman alan, hendek açma veya sondaj gerekliliği dolayısıyla maliyeti daha yüksek bir süreçtir.

Her iki dağıtım hatlarının işletme ve bakımı kıyaslandığında ise yeraltı elektrik nakil hatlarındaki oluşabilecek sorunları belirlemek, tespit edilen sorunları düzeltmek, arızaları düzeltmek amaçlı yapılacak kazı çalışmalarından dolayı oluşabilecek elektrik kesintileri oldukça zorlayıcı unsurlardır. Elektrik dağıtım yöntemlerindeki gerek yatırım ve tesis gerek bakım aşamalarındaki maliyetler kıyaslandığında havai elektrik dağıtım hatlarına kıyasla yeraltı enerji nakil hatlarının maliyeti daha yüksektir. Havai elektrik dağıtım hatları ilk kurulum ve tamir-bakım maliyetleri açısından daha ekonomik bir yöntemdir.

Havai elektrik dağıtım hatlarındaki bakımlarla ilgili oluşabilecek sorunlar şunlardır: Reolojik süreçlere bağlı olarak enerji nakil hatlarında oluşacak değişimler, sıcaklık, rüzgâr ve buz yükü gibi hava koşullarının dağıtım hatlarında oluşturacağı değişimler, havai elektrik dağıtım hatları yakınlarındaki binalar ve bitki örtüsü ile öngörülemez kazalar sonucu oluşabilecek elektrik kesintileridir.

Artan yatırım ve bakım maliyetlerini optimize edebilmek için kullanılan polimerik yalıtkan malzemenin reolojik davranışını, akışkan halinde yalıtkan malzemelerdeki polimer davranışını, bilmek çok önemlidir.

Havai enerji nakil hatlarının gözlemi ve arıza tespiti elektrik iletim ve dağıtım hizmetleri sunan elektrik üretim, iletim ve dağıtım şirketleri için herhangi bir arıza kaynaklı kesintiyi önlemek, oluşan arızaları tespit ettikten sonra gidermek ya da ekonomik ömrünü tamamlamış şebeke envanterinin yenilenmesi bakımından önemlidir.

Havai enerji nakil hatları, hem iletim hem de dağıtım şebekelerinde kullanılır. İşletme gerilimine göre havai enerji sınıflandırması üç grup Tablo 3.1’de verilmiştir.

Tablo 3.1: Havai enerji sınıflandırması.

Şebeke Sınıfı	Tanım
Alçak-gerilim şebekesi (AG):	(0-1) kV arası gerilimler
Yüksek-gerilim şebekesi (YG):	(1-154) kV arası gerilimlerdir. Yüksek verimleri nedeniyle dünyada en çok kullanılan dağıtım hatlarıdır.

3.1 Havai Hat Arızaları

Havai enerji hatlarında oluşabilecek arızalar neredeyse sonsuz çeşittir.

Elektrik hattının sürdürülebilirliğini sağlamak için de gözlem, tespit ve bakım-onarım önemlidir. Günümüzde, dağıtım hatlarının gözlem ve kontrolü temel olarak üç yerde yapılmaktadır: havai hatlarda, transformatör merkezlerinde ve raylı

ulařım aralarında entegre edilen kamera sistemleriyle yapılmaktadır (Yang ve dię., 2020).


Elektrik sistemlerindeki hataları her iki hat türünün özellikleri farklı olduęu için iletim hatlarındaki hatalar ve dağıtım hatlarındaki hatalar olarak ayırmak mümkündür. Elektrik iletim hatlarında yüksek voltaj ve uzun mesafe vardır ve de büyük endüstriyel müşteriler arasında elektrik akış yönü her iki yönde de olabilmektedir. Elektrik dağıtım hatlarında daha düşük voltaj ve uzun mesafe vardır ve de enerjinin yönü çoęunlukla tek yönlü olmaktadır. Havai iletim hatlarında arızaya sebep olabilecek olası pek çok neden vardır: fırtına, şarjlı hava koşulları, buz yükü, sis, korona, yalıtım malzemelerinin hasar görmesi, kırılması, hatların üstüne ağaç devrilmesi, kuşlar veya yabancı cisimlerden dolayı kısa devre oluşması (Foudah ve dię., 2021).

İletim hatlarındaki arızalar yüksek bir akım oluşumuna neden olabilir, fazlar arası dengesizlik oluşturabilir ya da aşırı gerilimle sonuçlanabilir. Arıza oluşunca empedans değerlerinin karakteristięi ciddi şekilde olumsuz yönde deęişebilir ve elektrik hattının işletilmesinde kesintiye neden olabilir (Foudah ve dię, 2021). Ü fazlı iletim hatlarında arızalar ister iletim ister dağıtım hatlarında oluşsun, gözlemin amacı paralardaki anomalileri tespit etmek veya hatların etrafındaki çevre deęişimlerini belirlemektir (Foudah ve dię, 2021).

3.2 İzolatör Türleri

Elektrik şebekelerinde havai hatları veya baraları sabitlendikleri yerden yalıtım ve taşımak için kullanılan malzemelere izolatör denir.

İzolatörler elektrik diren değerleri yüksek olan, zorlu iklim ve atmosfer koşullarına oldukça mukavemetli davranan malzemelerden porselen, silikon, epoksi reçine ve camdan üretilirler. İzolatörlerin dağıtım şebekesinde elektriksel olarak iletkeni topraktan ayırmak ve iletken ağırlığını ve iletkene gelen ek yükleri karşılamak gibi iki ana görevi vardır. Şekil 3.1' de üzerinde kırık olmuş bir izolatör örneęi verilmiştir.



Şekil 3.1: Üzerinde kırık arızası olan bir izolatör.

3.2.1 Gerilim Seviyelerine Göre İzolatörler

Gerilim seviyelerine göre izolatörlerin sınıflandırması alçak gerilim ve yüksek gerilim olarak iki ana grup başlığında Tablo 3.2’de verilmiştir.

Alçak Gerilim İzolatörleri: Pin tipi alçak gerilim izolatörleri N-80, N-95 ve N-95/2’dir. Bu izolatörler, düşük gerilim taşıyan enerji dağıtan tel satırlarında, iletkenin direğe bağlantısının sağlanmasında kullanılırlar.

Tablo 3.2: Gerilim seviyelerine göre izolatör sınıflandırması.

İzolator Sınıfı	Özellikleri ve Türleri
Alçak Gerilim İzolatörleri:	Pin tipi alçak gerilim izolatörleri N-80, N-95 ve N-95/2’dir.
Yüksek Gerilim İzolatörleri:	Bu izolatörler; VHD, VKS, Zincir tipi (K1,K2,K3), silikon(çubuk) izolator olarak dört gruba ayrılır. VHD 10-15-20-35: 36 kV gerilim seviyesinde kullanılan hava hattı mesnet izolatörüdür.

Yüksek Gerilim (YG) İzolatörleri: YG izolatörleri, yüksek gerilim taşıyan enerji dağıtan tel satırlarında, iletkenin direğe bağlantısının sağlanmasında kullanılırlar.

Yüksek gerilim izolatörleri, dört kategoriye ayrılır: VHD izolatörler, VKS izolatörler, zincir ve silikon (çubuk) tipinde olan izolatörlerdir.

VHD İzolatörler

VHD izolatörleri şehir şebekelerinde kullanılırlar. [Web 4: <https://www.elektrikport.com/makale-detay/izolatorler-1-bolum-elektrikport-akademi/12138#ad-image-0>]. VHD izolatörler pin tipi izolatör olarak da bilinmektedirler. Şekil 3.2’ de VHD 35 izolatör örneği ve özellikleri verilmiştir.

İZOLATÖR TİPİ / INSULATOR TYPE			VHD-35
İmalat Numarası / Manufacture Number			502/720
Ölçüler / Dimensions	H	mm	270
	h	mm	141
	ØD	mm	260
	ØD ₁	mm	125
	R	mm	14
	r	mm	14

Şekil 3.2: VHD 35 izolatör örneği.

VKS İzolatörler

VKS izolatörler, dolu tip izolatörlerdir ve köy- kırsal kısımlarda ağaç direklerde kullanılan kendinden mesnet-bağlantı demiri olan izolatör çeşitleridir (web 4). VKS izolatör örneği Şekil 3.3’te verilmiştir (Web 5: <https://omeryalcin.com/product/vks-35/>).



Şekil 3.3: VKS izolatör örneđi.

Zincir İzolatörler

Zincir izolatörler, yalıtımı arttırmak ve kopma yüklerini istenilen düzeye çıkarabilmek için aynı türden malzemelerden yapılmış izolatörlerin birbirine eklenmesi sonucu oluşan izolatörlerdir. Zincir yapılırken her bir izolatör baklasının alt kısmında pim, üst kısmında ise bu pimin geçebileceđi yuva bulunmaktadır.


Porselen veya camdan yapılabilen zincir izolatörlerin uzunluđu kullanılacak olan gerilime göre deđişmektedir. Bu tip izolatörler, taşıyıcı ve durdurucu tertiplerde izolatör kırıldığında sadece hasar görenler deđiştirildiğinden oldukça kullanım için pratiktirler. Şekil 3.4'te ve Şekil 3.5'te sırasıyla cam malzemedeki ve porselen malzemedeki zincir izolatör örnekleri görülmektedir (Web 6).



Şekil 3.4: Zincir tipi cam malzemeden izolatör.

Zincir izolatörler yalıtımı arttırmak ve kopma yüklerini istenilen düzeye çıkarabilmek için aynı türden materyallerden yapılmış izolatörlerdir.

Porselen veya camdan yapılabilen zincir izolatörlerin uzunluğu değişmektedir. Bu tip izolatörler taşıyıcı veya durdurucu tertiplerde izolatör kırılmalarında sadece hasar görenler değiştirilebildiği için daha pratiktir. Zincir yapılırken her bir izolatör baklasının alt kısmında pin, üst kısmında ise bu pimin geçebileceği yuva bulunmaktadır.




Şekil 3.5: Zincir tipi porselen izolatör.

Silikon İzolatörler

Silikon izolatörlere silikon çubuk izolatörler de denir. Şekil 3.6'da silikon (çubuk) izolatör örnekleri verilmiştir (Web 6).

Çubuk izolatörler, enerji iletim hatlarında askı veya gergi olarak iletken ile konsol arasında kullanılan izolatörler olup kirli bölge ve özellikle deniz kıyısı bölgelerde çalışma şartlarını çok daha iyi sağlayan izolatör türleridir.

Porselenden çubuk izolatörler ise elektriksel olarak delinmez bir gövdeye sahip olmaları ve kısa devreye karşı daha dayanıklı olmaları yönlerinden tercih edilirler.



Şekil 3.6: Silikon (çubuk) izolatör örnekleri.

3.2.2 Kullanım Yerlerine Göre İzolatörler

Kullanım yerlerine göre ise izolatörler, dahili tip izolatörler (Şekil 3.7) ve harici tip izolatörler (Şekil 3.8) olarak iki ana gruba ayrılabilirler (Web 6).

Dahili izolatörlere örnekler olarak trafo bina içi izolatörler, geçit izolatörleri, panolarda kullanılan izolatörler; harici tip izolatörleri için ise transformatör buşing izolatörleri, duvar geçit izolatörleri ve ayırıcı mesnet izolatörleri örnek olarak gösterilebilirler.

Harici tip izolatörler, iletkenleri taşımak ve direklerden yalıtılmak üzere travers üzerine veya ağaç direklerde doğrudan direğin üzerine bağlanırlar.

Dahili tip izolatörler Şekil 3.7’de iki ayrı alt sınıfta (a) Trafo bina için bara mesnet izolatörleri ve (b) Pano tipi mesnet izolatörleri olarak görülmektedirler. Harici tip izolatörler ise Şekil 3.8’de örnekleri görüldüğü üzere dört ayrı alt sınıfa ayrılırlar. Bu dört sınıf sırasıyla (a) Harici mesnet, (b) duvar geçit, (c) ayırıcı mesnet ve (d) buşing izolatörleri olarak ayrılır.



(a)




(b)


Şekil 3.7: Dahili tip izolötörler (a) Bara mesnet (b) Pano tipi mesnet.



(a) Harici mesnet izolatörleri



(b) Duvar geçit izolatörleri



(c) Ayırıcı mesnet izolatörleri




(d) Buşing izolatörleri

Şekil 3.8: Harici tip izolatör örnekleri.

3.3 İzolatör Koruma Amaçlı Elemanlar

Enerji iletim ve dağıtım hatlarında izolatörleri ark (aşırı gerilim) tehlikelerinden korumak için ark boynuzları kullanılırken korona olayına karşı ise koruma halkası (korona halkası) kullanılır. Şekil 3.9’ da ark boynuz örneği ve korona halka uygulamaları görülmektedir.



(a) Ark boynuzu

(b) Korona halkası uygulamaları

Şekil 3.9: Ark boynuz örneği ve korona halka uygulamaları.

Ark boynuzlarına aşırı gerilim ulaştığında, atlama aralığı uygunsa gerilim boynuzlar arasından atlayarak topraklanır ve izolatöre zarar vermez. Topraklama esnasında koruma cihazları kısa devre ile kesicilerin açılmasını sağlar. Ark boynuzları özellikle transformatör buşinglerinde ve zincir izolatörlerinde çok yaygın kullanılırlar. Yüksek gerilimlerde havanın iyonize olması sonucu yüksek elektrik alanında “korona” olayı gerçekleşir. Korona halkası, yüksek gerilim sahalarında korona olayının mesnet izolatörlerinde, gerilim transformatörlerinde, bara bağlantılarında ve sivri uçlar civarında oluşmasını önler.

4. MAKİNE ÖĞRENMESİ

Uzun yıllardır, bilgisayar alanındaki arařtırmaların, tasarımların ve uygulamaların hedefinde “yapay zeka” (YZ) yer almaktadır (Minsky, 1963).

Yapay zekâ, insan zekâsının özelliklerini taşıyan akıllı makineler yaratmayı amaçlayan bir bilim ve mühendislik alanıdır. Yapay zekanın hedefi, insanlar gibi öğrenebilen, akıl yürütebilen ve kararlar alabilen sistemler geliřtirmektir.

Makine öğrenmesi bir yapay zeka dalı olup bilgisayarların verilerden öğrenerek ve deneyim yoluyla performanslarını artırarak belirli görevleri otomatik olarak gerçekleřtirebilmesidir.

Makine öğrenmesinde kullanılan algoritmalar, büyük veri setlerinden örüntüleri tanıyarak gelecekteki olayları tahmin edebilir.

Makine öğrenmesinin üç ana grubu Tablo 4.1’de özetlenmiřtir.

Tablo 4.1: Makine öğrenmesi sınıflandırma grupları.

Makine Öğrenmesi Sınıfı	Tanım
Denetimli öğrenme:	Etiketli veri kullanarak model eğitimi, veri sınıflandırma veya regresyon problemlerini çözmek için kullanılan makine öğrenmesidir (Mitchell, 1997).
Denetimsiz öğrenme:	Etiketsiz veri kullanarak örüntülerin keşfedilmesi, veri yapısının anlaşılması, kümelene veya boyut indirgeme gibi görevlerin gerçekleştirilmesi için kullanılan makine öğrenmesidir (Jain ve diğ., 1999).
Pekiřtirmeli öğrenme:	Robot, araç, cihaz, makine gibi bir ajanın, ödül ve ceza mekanizmaları yoluyla bir ortamda nasıl hareket edeceğini öğrenmesi hedefli makine öğrenme türüdür (Sutton ve Barto, 2018).

4.1 Derin Öğrenme ve Modelleri

İnsan eliyle işlenmesi mümkün olmayan devasa veri setlerinden öğrenen bir makine öğrenmesi çeşididir. Derin öğrenme modelleri, katmanlar arasında öğrenilen özellikleri temsil ederek veri analizini gerçekleştirir ve bu özellikleri kullanarak tahminlemeler yapar. Derin öğrenme, özellikle görüntü, ses ve metin verileri üzerinde oldukça başarı sağlamaktadır (LeCun ve diğ., 2015).

Derin öğrenmeye kıyasla makine öğrenmesi genel olarak daha basit algoritmalarından faydalanırken, derin öğrenme için oluşturulan sinir ağları ile daha karmaşık ve detaylı veri analizleri yapar. Derin öğrenme, büyük veri setleri üzerinde daha iyi performans gösterir ancak daha yüksek hesaplama gücü ve daha fazla veri gerektirir (Goodfellow ve diğ., 2016).

Görüntü üzerinden nesne sınıflama ve tespit etme ile ilgili yapay sinir ağlarını kullanarak derin öğrenme konusu son yıllarda birçok alanda yaygınlaşarak kullanılmaya devam etmektedir.

Derin öğrenme için kullanılan mimari ve modeller, özellikle nesnenin öznitelik bilgilerine ilişkin doğruluk ve kesinlik ile işlem zamanı özellikleri bazında birbirinden ayrılmakta ve rekabetçi bir gelişim göstermektedir.

4.1.1 Evrişimli Sinir Ağları

Evrişimli Sinir Ağları, öncelikle görüntü işleyen ve nesne tanıma görevlerinde kullanılan derin öğrenme modelleridir. CNN'ler, giriş verisini (örneğin bir görüntü) alır ve bu veriyi filtreler (evrişim işlemleri) ve havuzlama katmanları ile işler (LeCun ve diğ., 1998).

CNN'ler, görüntülerdeki özellikleri (kenarlar, köşeler, dokular) öğrenerek bu özellikleri sınıflandırma için kullanır. CNN'ler aynı zamanda SSD ve YOLO gibi ileri nesne tespit algoritmalarının temelini oluşturur.

Evrişimli Sinir Ağları (CNN), özellikle görüntü işleme ve nesne tanıma görevlerinde kullanılan derin öğrenme modelleridir.

CNN'ler, giriş verisini (örneğin bir görüntü) alır ve bu veriyi filtreler (evrişim işlemleri) ve havuzlama katmanları ile işler (LeCun ve diğ., 1998).

CNN için filtre Denklem 4.1' de verilmiştir (Goodfellow ve diğ., 2016):

$$(I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (4.1)$$

Burada:

I: giriş görüntüsü

K: filtre

i ve j: filtre pozisyonu

Evrişimli sinir ağlarında (CNN) havuzlama katmanındaki değer Denklem 4.2' de görülmektedir:

$$P(i, j) = \max\{I(2i, 2j), I(2i + 1, 2j), I(2i, 2j + 1), I(2i + 1, 2j + 1)\} \quad (4.2)$$

P: maksimum havuzlama değeri

CNN'ler, görüntülerdeki özellikleri (kenarlar, köşeler, dokular) öğrenerek bu özellikleri sınıflandırma için kullanır. CNN'ler aynı zamanda SSD ve YOLO gibi ileri nesne tespit algoritmalarının temelini oluşturur.

4.1.1.1 SSD

SSD, nesne bulmak için kullanılan bir CNN tabanlı modeldir. SSD, görüntüdeki farklı nesnelere ve bunların konumlarını tek bir geçişte tespit edebilir. SSD'nin avantajları şunlardır:

- Hızlıdır: Tek geçişte tüm nesnelere tespit eder, bu da anı anına olan uygulamalar için idealdir (Liu ve diğ., 2016).

- Doğrudur: Çeşitli ölçekte nesnelere tespit edebilir ve çeşitli tespit kutuları kullanarak daha doğru sonuçlar sağlar.

4.1.1.2 YOLO

YOLO, anı anına zaman olarak gecikmeksizin nesne bulmak için kullanılan bir başka evrişimli sinir ağıları (CNN) tabanlı modeldir. YOLO, bir görüntüyü tek bir geçişte işler ve bu sayede hızlı ve doğru nesne tespiti yapar. YOLO' nun avantajları şunlardır:

- Hızlıdır: Tek bir sinir ağı geçişi ile tüm nesnelere tespit eder (Redmon ve diğ., 2016).

- Doğrudur: Nesnelere sınıflandırılması ve konumlarının belirlenmesinde yüksek doğruluk sağlar.


YOLO algoritması, 1993'te Ben Zimmer tarafından ilk kez tanıtılmasından itibaren geliştirildikçe yeni özellikler ve yeni sürümler kazandı. 2020 yılında YOLOV4 piyasaya çıktıktan sadece iki ay sonra Ultralytics şirketinin yöneticisi Glenn Jocher YOLOV5 algoritmasını geliştirdi (Sirisha vd, 2023).

4.1.2 Devirli Sinir Ağları (DSA)

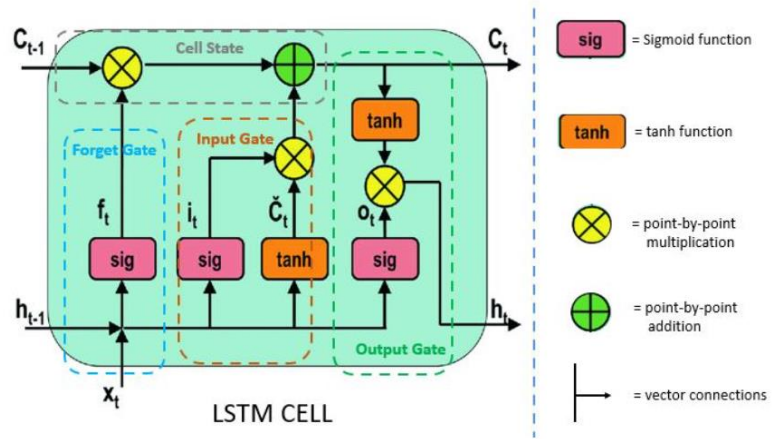
Devirli Sinir Ağları (DSA), zaman serilerinin verilerini analiz etmek için kullanılan sinir ağlarıdır. DSA' lar, önceki adımlardan gelen bilgileri hatırlayarak ve bu bilgileri kullanarak sonraki adımları tahmin eder. Sonraki adımları tahmin edebilme özellikleri DSA' ları dil modelleme, konuşma tanıma ve zaman serisi tahminlerinde oldukça etkili kılar (Elman, 1990).

Şekil 4.1.' de gizli tek tabakası olan Devirli Sinir Ağları (RNN) için grafik şematiği (Zakeri Nasrabadi ve diğ., 2021) görülmektedir.

Şekil 4.2.' de ise Devirli Sinir Ağları (RNN) için kullanılan LSTM hücre şematiği (Web 2) verilmiştir.



Şekil 4.1: Gizli tek tabakası olan Devirli Sinir Ağları (RNN) şematığı.



Şekil 4.2: Devirli Sinir Ağları (RNN) için kullanılan LSTM hücre şematığı.

Devirli sinir ağları (DSA) (RNN) için durum vektörü Denklem 4.3' te, görülmektedir (Hochreiter ve Schmidhuber, 1997):

$$h_t = f(W_h h_{t-1} + W_x x_t + b) \quad (4.3)$$

Burada:

h_t : mevcut gizli durum

h_{t-1} : önceki gizli durum

x_t : giriş

W_h : ağırlık matrisi

W_x : ağırlık matrisi

4.1.3 Uzun Kısa-Sürelili Bellek

Uzun Kısa Sürelili Bellek (UKSB), DSA'ların bir türü olup, uzun vadeli bağımlılıkların öğrenilmesinde oldukça etkilidir. UKSB'ler, içlerinde bulunan hücre durumları ve kapı mekanizmaları sayesinde bilgiyi daha uzun süre saklayabilir ve hatırlayabilir. Bu özellik, özellikle dil modelleme ve zaman serisi tahminlerinde UKSB'leri güçlü kılar (Hochreiter ve Schmidhuber, 1997).

4.1.4 R-CNN

R-CNN, nesne tespiti için kullanılan bir diğer CNN tabanlı modeldir. R-CNN, önce görüntüdeki olası nesne bölgelerini belirler ve ardından her bölgeyi bir CNN üzerinden geçirerek nesne tespiti yapar (Girshick ve diğ., 2014, Web 1).

R-CNN sinir ağı mimarisi çalışmasını oluşturan üç aşama Tablo 4.2' de özetlenmiştir.

R-CNN'nin farklı çeşitlerinin avantajları şöyle sıralanabilir:

- R-CNN: İlk model, yüksek doğruluk sağlar ancak yavaş olabilir.

-Fast R-CNN: R-CNN'nin geliştirilmiş versiyonu, daha hızlı ve daha verimlidir (Girshick, 2015).

- Faster R-CNN: Nesne bölgelerinin belirlenmesini de öğrenen bir sinir ağı, oldukça çabuk çalışan ve en başarılı R-CNN çeşididir (Ren ve diğ., 2015).

Tablo 4.2: R-CNN sinir ağı mimarisi çalışmasını oluşturan üç aşama.

R-CNN Çalışma Adı	Açıklama
1. Aşama: Bölge Önerisi	Görüntü üzerinde potansiyel nesne bölgeleri (region proposals) önerilir, “Anchor box” da bölge önerisi olarak kullanılabilir.
2. Aşama: Özellik Çıkartımı	Önerilen bölgeler bir CNN aracılığıyla özellik haritalarına dönüştürülür.
3. Aşama: Sınıflandırma	Özellik haritaları, nesnelere sınıflandırılması için kullanılır (Web 2)

4.2 Makine Öğrenmesi ve Derin Öğrenmede Algoritmalar

Nesne tespit algoritmalarının amacı, görüntü içinde bir nesne olup olmadığını belirlemek ve bu nesnenin görüntü içinde tam olarak neresinde yer aldığını belirlemektir. Görüntüde nesneyi ve nesnenin yerine belirlemek için kullanılan yöntem irdelenen nesnenin üzerine bir sınırlayıcı kutu (bounding box) çizmektir.

Makine öğrenmesi ile cisim tanımak için çeşitli algoritmalar kullanılır, ancak bir cismi tanıyacak algoritma için belli kesin bir yol yoktur. Algoritmalarda kullanılan görüntü sınıflayıcılar ile cisimde kenarları belirlemek, köşeleri bulmak gibi çeşitli denemeler yapılarak algoritma geliştirilir. Öncelikle, görüntü işlemede geliştirilecek algoritmanın ne yapması gerektiği belirlenir, görüntü sınıflama amaçlı ya da nesne tanıma amaçlı algoritma geliştirilebilir.

Veri Temelli Yaklaşım

Algoritma geliştirirken veri temelli yaklaşım kullanılabilir. Veri temelli yaklaşım üç aşamalıdır:

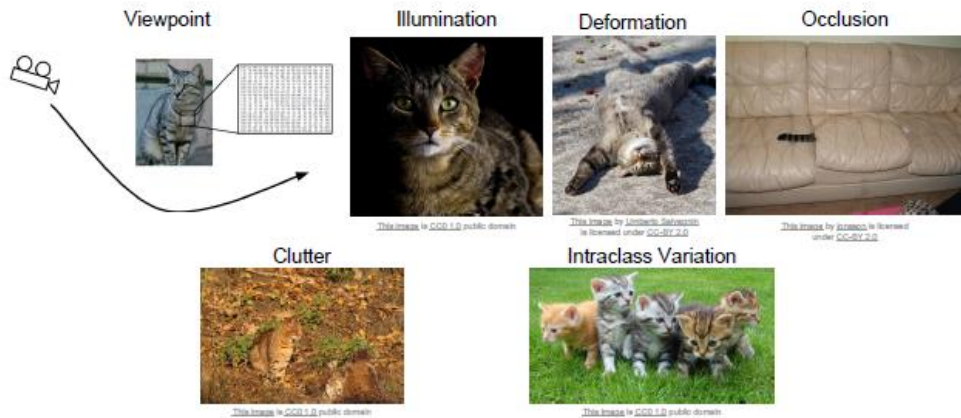
- 1) Görüntülerin ve etiketlerin veri setlerini biriktirmek
- 2) Bir sınıflayıcıyı eğitmek için makine öğrenmesi kullanmak
- 3) Yeni görüntüler üzerinde sınıflayıcıyı değerlendirmek.

Veri Temelli Yaklaşımda Sınıflayıcı Çeşitleri

Bilgisayarla görüntü işlemedeki ana görev “görüntü sınıflama”dır. Görüntü sınıflayıcı olarak yaygın kullanılan sınıflayıcılar şunlardır:

- En yakın komşu sınıflayıcı (Nearest neighbor classifier)
- Doğrusal sınıflayıcı
- Parametrik sınıflayıcı


Görüntü sınıflama esnasında da görüntüleme açısı, ışıklandırma, cismin çevre tarafından örtülmesi, arka zemindeki kalabalık, cismin deformasyona uğraması, hareket sınıflaması, hareketin hız değeri, nesnenin büyüklüğü ve nesnenin sınıf içi farklılıkları gibi çeşitli zorluklar vardır, bu zorluklar Şekil 4.3’te görselde görülmektedir (Web 3: <https://stanfordpython.com/#/>).



Şekil 4.3: Görüntü sınıflama esnasında zorluklar.

En yakın komşu sınıflayıcı

En yakın komşu sınıflayıcıda pikseller arası mesafe ile görüntü öğretilir (Şekil 4.4). Ancak çok uzun süre alması ve boyutlardaki değişkenlikler bu yöntemin kullanımını zorlaştırmaktadır (web 3: <https://stanfordpython.com/#/>).



Şekil 4.4: En yakın komşu sınıflayıcı işleyişi.

Doğrusal sınıflayıcı

Doğrusal sınıflayıcı denklemi Denklem (4.4)'te verilmiştir.

$$f(x, W) = Wx + b \quad (4.4)$$

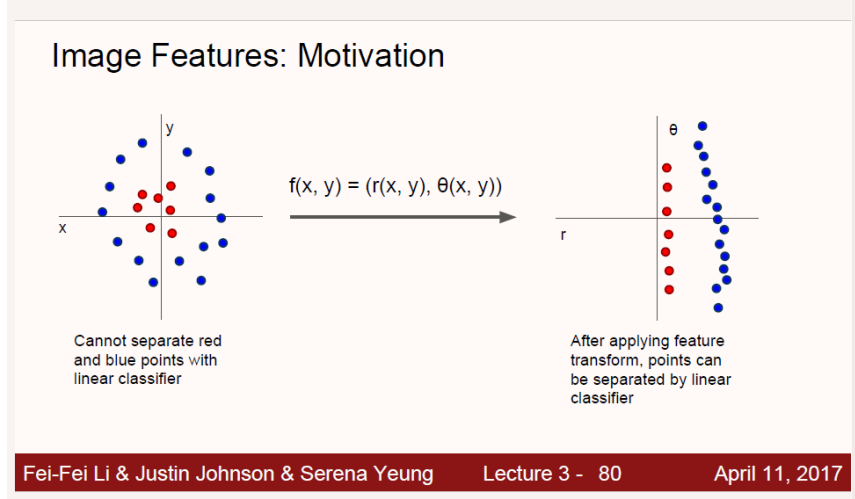
Burada:

W: parametreler veya ağırlıklar

x: piksel (örneğin 3072 x1)

b: düzeltme faktörü

Doğrusal sınıflayıcı verileri tam olarak birbirinden ayıramayabilir, bu durumda algoritmaya özellik dönüştürücü uygulayarak verileri birbirinden ayrıştırılabilmek sağlanabilir (Web 3). Şekil 4.5' te doğrusal sınıflayıcılarda özellik dönüştürme işlemi şematize edilmiştir.



Şekil 4.5: Doğrusal sınıflayıcılar için algoritmaya özellik dönüştürme işlemi.

Parametrik sınıflayıcı

Parametrik yaklaşımdaki sınıflayıcı için veri seti Denklem 4.5 'te verildiği üzere:

$$\{x_i, y_i\}_{i=1}^N \quad (4.5)$$

L verilerdeki kayıp fonksiyonu (data loss function) denklem 4.6' da verildiği üzere:

$$L = \frac{1}{N} \sum_i^N L_i(f(x_i, W), y_i) \quad (4.6)$$

$x_i =$ görüntü (*image*)


$y_i =$ etiket (*label, integer*)

$s =$ skorlar vektörü için kısa gösterim

$L =$ SVM deki loss

Skorlar vektör formülü ve Destek Vektör Makinesi kayıp formülleri sırasıyla denklem 4.7 ve denklem 4.8 'de verilmiştir:

$$s = f(x_i, W) \quad (4.7)$$



Şekil 4.6: Destek Vektör Makinesi (DVM) kayıp gösterimi (web 3).

Şekil 4.6' da şematize edilen SVM kayıp (Destek Vektör Makinesi (DVM) kayıp) hesaplaması Denklem 1.5' te görülmektedir:

$$L_i = \sum_{j \neq y_i} \max(0, s_j - s_{y_i} + 1) \quad (4.8)$$

$L_i = SVM \text{ loss kayıp değeri}$

Regülerizasyon ise denklem 4.9' da $R(W)$ olarak verilmiştir:

$$R(W) = \lambda R(W) \quad (4.9)$$

Model mümkün mertebe basit olmalı ve test verisinde model çalışmalı ve modelin ön görüleri eğitim verileri ile uyumlu olmalıdır (Web 3:Stanford, lecture 3-33). Veri kaybı ve regularizationu da göz önünde bulunduran kayıp fonksiyonu denklem 4.10' da görülmektedir:

$$L(W) = \frac{1}{N} \sum_i^N L_i(f(x_i, W), y_i) + \lambda R(W) \quad (4.10)$$

4.2.1 Yapay Sinir Ağları

Yapay Sinir Ağları, tıpkı insan vücudunda bulunan sinir ağlarını taklit eden ve öğrenme süreçlerini modelleyen algoritmalarıdır. Yapay sinir ağının temel yapısı,

giriş katmanı, gizli katmanlar ve çıkış katmanından oluşur. Her bir katmandaki nöronlar, önceki katmandaki nöronlardan gelen sinyalleri alır, işler ve sonraki katmana iletir. Yapay sinir ağları, verilerden öğrenerek örüntüleri tanır ve sınıflandırma, regresyon gibi görevleri yerine getirir (Rumelhart ve diğ., 1986).

4.2.2 Rastgele Orman

Rastgele Orman, birden çok karar ağacının birleşiminden oluşan ve sınıflandırma ve regresyon analizlerinde kullanılan bir makine öğrenmesi algoritmasıdır. Bu yöntem, overfitting problemini azaltır ve daha doğru tahminler yapar (Breiman, 2001). Rastgele Orman, veri setini rastgele alt örneklemelere bölerek her bir alt örneklem üzerinde karar ağaçları oluşturur ve bu ağaçların sonuçlarını birleştirerek nihai tahminleri yapar.

4.2.3 Destek Vektör Makineleri

DVM, veri noktalarını farklı gruplara ayıran en iyi üst düzlemi bulmayı amaçlayan bir denetimli öğrenme algoritması olup veriyi ayıran en büyük marjinal hiperdüzlemi bulur ve bu hiperdüzlem üzerinden sınıflandırma yapar. DVM, sınıflandırma ve regresyon analizlerinde kullanılır ve öncelikle oldukça büyük yer kaplayan veri setlerinde etkili sonuçlar verir (Cortes ve Vapnik, 1995).

5. MAKİNE ÖĞRENMESİ İLE HATA TESPİTİ

Derin Öğrenmeyi mümkün hale getiren, yapay sinir ağlarının gelişimi olmuştur. 2017’de geliştirilen bir “Transformer Mimarisi” dediğimiz yapay sinir ağı mimarisi bugünkü sohbet tabanlı “Yapay Zekâ”ları mümkün hale getirdi.

Bilgisayar yardımıyla oldukça zor bir problemi çözenin beş aşaması vardır: araştırma (search), desen tanım (pattern-recognition), öğrenme (learning), planlama ve çıkarsama aşaması (induction) (Minsky 1963).

Beyindeki nöronları ve ağları taklit eden bir yazılım şeklinde yapay sinir ağları oluşturulur. Boş bir sayfa olarak oluşan sistem ne ile istediğimize bağlı olarak eğitilir. Görüntü tanıma sistemleri elden geldiğince bol sayıda görüntü ile eğitilir.

Böylece tanıma, oluşturma ve problem çözme işlevlerini yerine getirir. Ne kadar ilgili ve yüksek kaliteli veriyle eğitilmesine bağlı olarak oldukça başarılı sonuçlar verebilir. YZ (yapay zeka) modelleri bir kere eğitildikten sonra o veride bulunan teknoloji çerçevesinde çalışır.

Makine öğrenmesi ile arıza tespitinde üç kritik süreç vardır:

- 1) Görüntü işleme süreci
- 2) Farklı boyuttaki nesnelerin tespiti süreci
- 3) Makine öğrenmesi sonucu arıza veya arızaya neden olabilecek ekipmanın tespiti

5.1 Görüntü İşleme Süreci

Görüntü işleme süreci görüntü verilerine işlemeye dayanmaktadır. Veri işleme, genellikle veri edinimi öncesi ön işleme ve veri edinimi sonrası son işlem olarak ikiye ayrılmaktadır. Derin öğrenme tekniklerinde genellikle veri edinimi sonrası son işlem daha yaygındır. Mevcut İHA tabanlı uzaktan algılama çalışmaları,

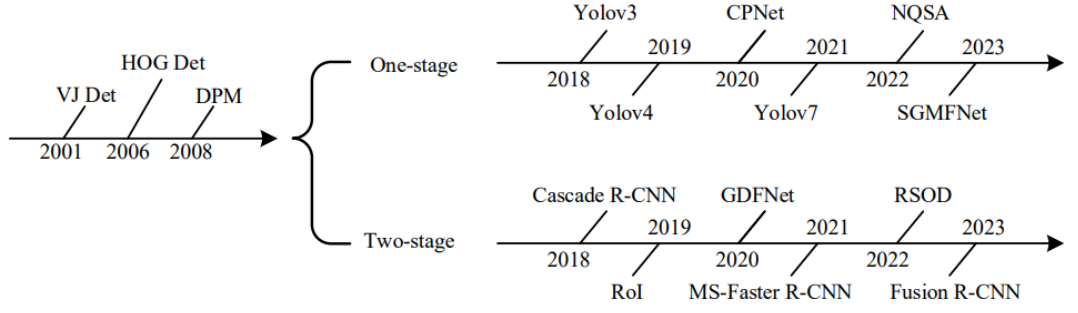
deneysel veri kümelerini ve uygun veri işleme tekniklerini sunmaktadır (Xia ve diğ., 2019). Bu çalışmalar, görüntü alımından sonra görüntülerin işlenmesi, eğitim örneklerinin sayısının artırılması, örnek boyutu ve yön çeşitliliğinin artırılması ve aydınlatma değişikliklerinin genişletilmesi gibi işlemleri kapsamaktadır. Ancak, bu tekniklerin etkinliği değişkenlik göstermektedir.

İHA uçuş yüksekliği ve yük sınırlamaları nedeniyle, yer nesnelerinin örtüşmesi, kaplanması ve yer değiştirmesi kaçınılmazdır. Xia ve diğerleri (2019), optik kameraları örnek alarak, İHA uzaktan algılama veri edinim sürecindeki çeşitli zorlukları ve sorunları ele almış ve veri işleme tekniklerini sistematik olarak tartışmıştır.


5.2 Nesnelerin Tespiti Süreci

İHALardan alınan görüntülerle nesne tespiti üzerine yapılan derin öğrenme tabanlı nesne tespiti çalışmaları, genellikle geleneksel dijital görüntü işleme yöntemlerinden faydalanmıştır. Bununla birlikte, küçük insansız hava aracı (İHA) platformları ve görüntüleme koşullarının getirdiği sınırlamalar, özel perspektif sorunları, karmaşık arka planlar, ölçek ve yön çeşitliliği ve küçük nesnelerle ilgili sorunlar gibi çeşitli zorluklar ortaya çıkarmaktadır.

Nesnelerin tespitinin 2001-2026 yılları arasındaki gelişimi Şekil 5.1’de görülmektedir (Li ve diğ., 2023). Nesnelerin tespiti tek aşamada hızlı ama doğruluk payı düşük olarak gerçekleşirken çift aşamada nesne tespiti daha uzun zaman alırken doğruluk daha yüksek olur (Tang ve diğ., 2024). Şekil 5.2 ve Şekil 5.3’ te sırasıyla tek aşamalı nesne tespiti ve çift aşamalı nesne tespiti için işleyiş şemaları görülmektedir.



Şekil 5.1: Nesnelerin tespitinin 2001-2023 arasındaki gelişimi (Li ve diğ., 2023).



Şekil 5.2: Tek aşamalı nesne tespiti işleyişi (Tang ve diğ., 2024).

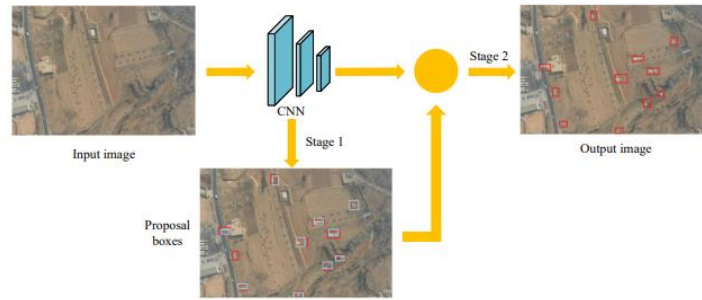


Figure 2. Two-stage object detection framework.

Şekil 5.3: İki aşamalı nesne tespiti işleyişi (Tang ve diğ., 2024).

İHA görüntülerindeki beş temel sorun: veri işleme, ölçek çeşitliliği, küçük nesnelere, yön çeşitliliği ve tespit hızıdır.

İHA verilerinin karmaşıklığı ve çeşitli zorluklarıyla (irtifa ve ölçek farkı, nesne küçüklüğü, yön farklılığı, tespit sırasındaki hızın etkisi ve diğer etmenler gibi) başa çıkmak için literatürde çeşitli yöntemler geliştirilmeye çalışılmaktadır.

İrtifa ve ölçek farkı etkisi

İHA uzaktan algılama görüntüleri, farklı irtifalarda alınabilir ve yer nesnelere her boyutta olabilir. Bu durum, geleneksel derin öğrenme yöntemleri için büyük bir engel oluşturur. İHA uzaktan algılama görüntülerinde, yer nesnelere genellikle 32×32 pikselden daha küçük alanlarda gösterilir. MS COCO veri kümesi, küçük nesnelere daha az belirgin özelliklere sahip olarak tanımlayarak daha fazla yanlış ve kaçırılan tespit hedeflerine neden olmaktadır (Chen ve diğerleri, 2019). İHA'ların çektiği görüntülerde, farklı irtifalardan alınan görüntülerdeki nesnelere boyutlarındaki çeşitlilik, tespit algoritmalarının etkinliğini zorlaştırmaktadır.

Nesnelere küçüklüğünün etkisi

Küçük nesnelere tespiti, İHA görüntülerinde büyük bir sorun oluşturur. Bu nesnelere, düşük çözünürlüklü görüntülerde daha az belirgin özelliklere sahiptir. Küçük nesnelere daha az belirgin özelliklere sahip olması, daha fazla yanlış ve kaçırılan tespit hedeflerine yol açmaktadır (Lin ve diğerleri, 2021). Küçük nesnelere tespiti için geliştirilen yöntemler, genellikle daha küçük boyutlu nesnelere belirlemek için özel olarak düşünülmüş derin öğrenme algoritmalarını içermektedir.

Yön farklılığının etkisi

İHA görüntülerindeki nesnelere yön çeşitliliği, nesne tespiti algoritmalarını zorlaştıran bir diğer faktördür. Yön çeşitliliği, nesnelere farklı açılardan görüntülenmesi nedeniyle ortaya çıkar. Bu durum, tespit algoritmalarının nesnelere doğru bir şekilde tanımlamasını zorlaştırır. Yön çeşitliliği sorununu aşabilmek için, derin öğrenme tabanlı yaklaşımlar, farklı yönlerdeki nesnelere tespit etmek için özel olarak tasarlanmış algoritmalar kullanılmaktadır (Kang ve diğerleri, 2022).

Tespit sırasında hızın etkisi

İHA'lar tarafından çekilen videolardaki nesnelerin tespiti, nesnelerin hızla ve doğru bir şekilde bulunmasını gerektirir. Gerçek zamanlı işleme performansı, bu tür sistemler için son derece önemlidir. İHA görüntülerindeki nesnelerin tespit hızını artırmak için geliştirilen yöntemler, genellikle hızlı ve verimli derin öğrenme algoritmalarını içerir. Gerçek zamanlı nesne tespiti, nesnelerin hızla bulunması ve gözlemlenmesi için hayati değere sahiptir (Yang ve diğerleri, 2019).

Nesne tespitinde diğer etmenler

Diğer tespit sorunları arasında, nesnelerin örtüşmesi, karmaşık arka planlar ve ışık koşullarındaki değişiklikler bulunur. Bu sıkıntıları aşabilmek için, derin öğrenme tabanlı yöntemler, genellikle bu tür zorlu durumları irdelemek için özellikle tasarlanmış algoritmalar kullanmaktadır (Chen ve diğerleri, 2019).

6. YÖNTEM

Bu tez çalışmasında veri temelli yaklaşım ile YOLOV5 algoritması kullanıldı. Bu çalışmada YOLOV5 için eşik 0.5 olarak alındı ve P-R eğrişinin eldesi için eşik en düşük sıfır (0) ve eşik en yüksek bir (1) olmak üzere binde bir aralıklarla (0,001) algoritma tespit yaptı. Çalışmada kullanılan bilgisayara ait özellikler Tablo 6.1^de verilmiştir.

Tablo 6.1: Kullanılan bilgisayara ait özellikler.

Model bilgisi	Bilgisayarın özellikleri
MONSTER Abra A7 17,3'' dizüstü bilgisayar	Intel® Alder Lake Core i7-12700H 14C/20T, 3200 MHz bellek hızı NVIDIA GeForce RTX4060 Max Performance 8 GB GDDR6 128-Bit DX12 32 GB DDR4 3200 MHz SODIMM

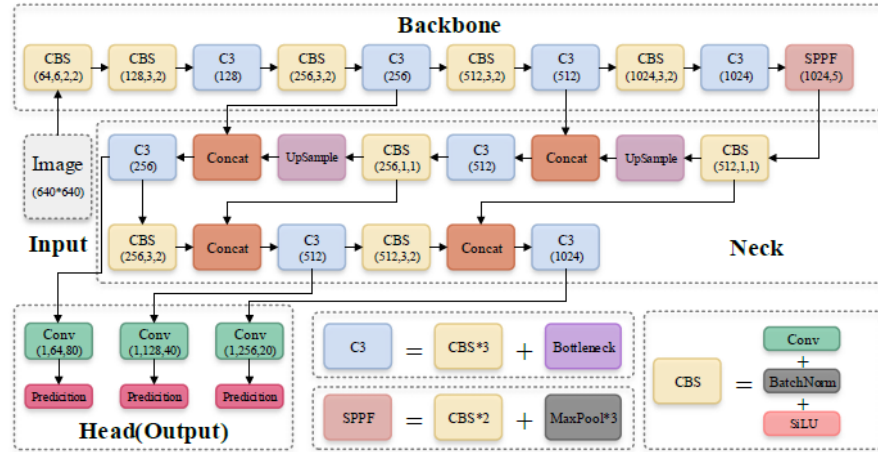
Çalışma üç aşamalı olup şu safhaları kapsamaktadır:

- 1) “Görüntü işleme” aşaması: Görüntülerin ve etiketlerin veri setlerini biriktirme sürecidir. Görüntüler DJI-3 Pro marka İHA (Şekil 6.1) ile çekilerek model geliştirildi.
- 2) “Nesne tespiti” aşaması: Makine derin öğrenmesi ile nesne tespitidir.
- 3) “Değerlendirme” aşaması: Derin öğrenme YOLOV5 algoritmasının görüntüler üzerinden hassasiyetinin değerlendirilmesi



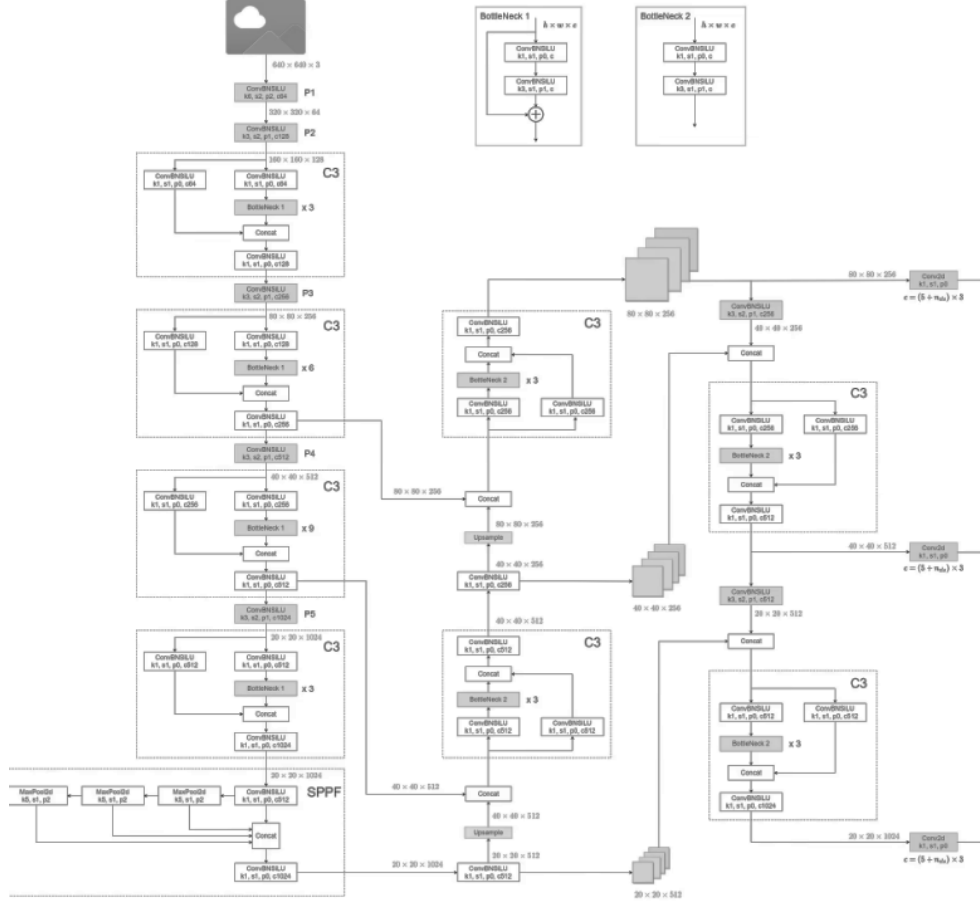
Şekil 6.1: Görüntüleri çeken İHA modeli (DJI-3 Pro).

Makine öğrenmesi, YOLOV5 algoritması ile derin öğrenme ve değerlendirme aşamaları gerçekleştirildi. YOLOV5 algoritmasına ait mimari yapı Şekil 6.2’ de görülmektedir (Liu vd, 2022).



Şekil 6.2: YOLOV5 algoritmasının mimari yapısı.

YOLOV5 algoritmasının detaylı mimarisi Şekil 6.3’te şematize edilmiştir (Web 7). YOLOV5’in mimari yapısı ,omurga, boyun ve kafa olmak üzere üç kısımdan oluşur (Web 8).



Şekil 6.3: YOLOV5 detaylı mimari yapısı (Web 7).

Omurga, görüntünün özelliklerini elde edip boyun tabakalarına gönderir. Boyun tabakalarında özellikler birleştirilir. Birleştirilen özellikler YOLOV5 algoritmasında büyük nesnelere için P5 özellikler haritasında 20x20 özelliklerde oluşturulurken, küçük cisimler için 80 x80 özellikte P3 özellik haritaları ve orta büyüklükte cisimler için ise 40 x40 özellikte P4 özellik haritaları oluşturulur. Özellik haritası kafa kısmına gönderildikten sonra, kafa kısmı tahminleme yapar. Özellik haritasındaki her bir piksel için güven oranı hesaplaması yapılır ve sınırlayıcı kutu regresyonu gerçekleştirilir. Bu aşamada, nesne sınıfı, sınıf güveni, kutu koordinatları, genişlik ve yükseklik bilgilerini içeren çok boyutlu bir sınırlayıcı dizi elde edilir (web N, Liu vd, 2022).

Çıktı verisini elde etmek için ise NMS (maksimum olmayanları eleme) işlemi için uygun eşik değerleri ayarlanır ve böylece sınırlayıcı kutu içerisindeki faydalanılmayacak bilgiler filtrelenir (Web 9, Liu vd 2022).

YOLO algoritmaları içerisinde YOLOV5'in en dikkat çekici özelliği YOLO algoritmalarının nesne tespitinde başarı grafiğini yukarı çekmesi (Web 8) olup bu başarıda YOLOv5'in 58 (elli sekiz) açık kod sağlayıcıdan faydalanması ve sürekli çaba sarf etmesidir (Ana vd, 2021, Sirisha vd, 2023, Web 7). Ancak, YOLOV5 algoritmasında hedef görüntüler pek çok küçük hedeflerden oluşuyorsa tespit edilen görüntü sonuçlarında istenen ideal başarı yakalanamayabilir (Liu vd, 2022).

6.1 Görüntü İşleme

Literatürde görüntü işleme için farklı nesne tespit algoritmaları kullanılan çalışmalar mevcuttur. Popüler olarak kullanılan CNN, R-CNN, Faster R-CNN, Mask R-CNN, SSD, YOLO (V1,V2,V3,V4) ve benzeri yapay sinir ağı algoritmalarının, istenilen nesnenin özniteliklerine ve boyut farklılıklarına, kullanılacak olan fotoğrafların boyutlarına ve görüntü kalitelerine bağlı olarak farklı omurga ağı modelleri kullanılarak doğruluk tespitinin kesinliği ve işlem hızlarından en verimli yöntemlere bağlı olarak uygulanan modeller literatürde mevcuttur.

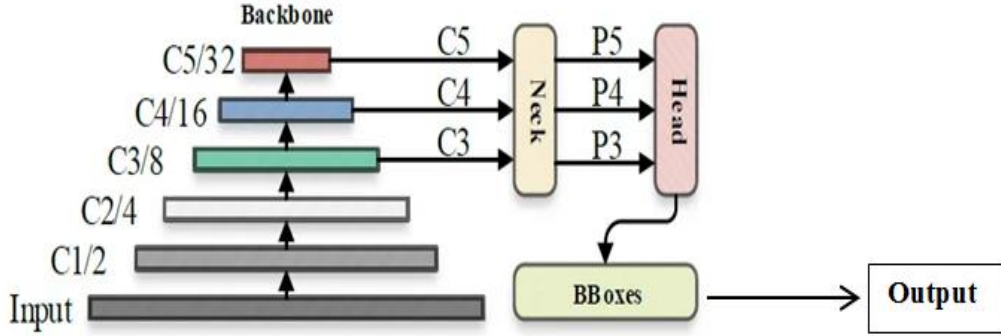
Bu tez çalışması kapsamında, YOLOV5 sinir ağı algoritması ile İHA ile fotoğraflanan toplamda 795 adet izolatör görüntüsü kullanıldı. Makine öğrenmesi aşamasında toplam 588 görüntü YOLO ile eğitildi ve değerlendirme aşamasında 207 adet görüntü ile kesinlik belirlendi.

Bu görüntüler, YG havai enerji nakil hatlarının DJI-3 Pro marka insansız hava aracı (İHA) ile alınan fotoğraflarından oluşmaktadır. Eğitim süreci için veri seti iki ana sınıfa ayrılmıştır: "İzolatör" ve "Kırık İzolatör" sınıfları. İzolatör sınıfında toplam 138 görüntü, kırık izolatör sınıfında ise toplam 69 görüntü değerlendirildi.

6.2 Nesne Tespiti

Makine öğrenmesi ile nesne tespiti aşamasıdır. Mevcut çalışmada kullanılan YOLOV5 algoritması tek aşamada nesne tespiti yapmaktadır.

Şekil 6.4'te YOLOV5'te girdi verisinin sırasıyla algoritmanın mimari yapısındaki omurga, boyun ve kafa kısımlarındaki işleyiş akışı görülmektedir. İşlenen görüntü, girdi verisi tabakası olarak özellik belirlemek için omurgaya gönderilir. (Liu vd, 2022)



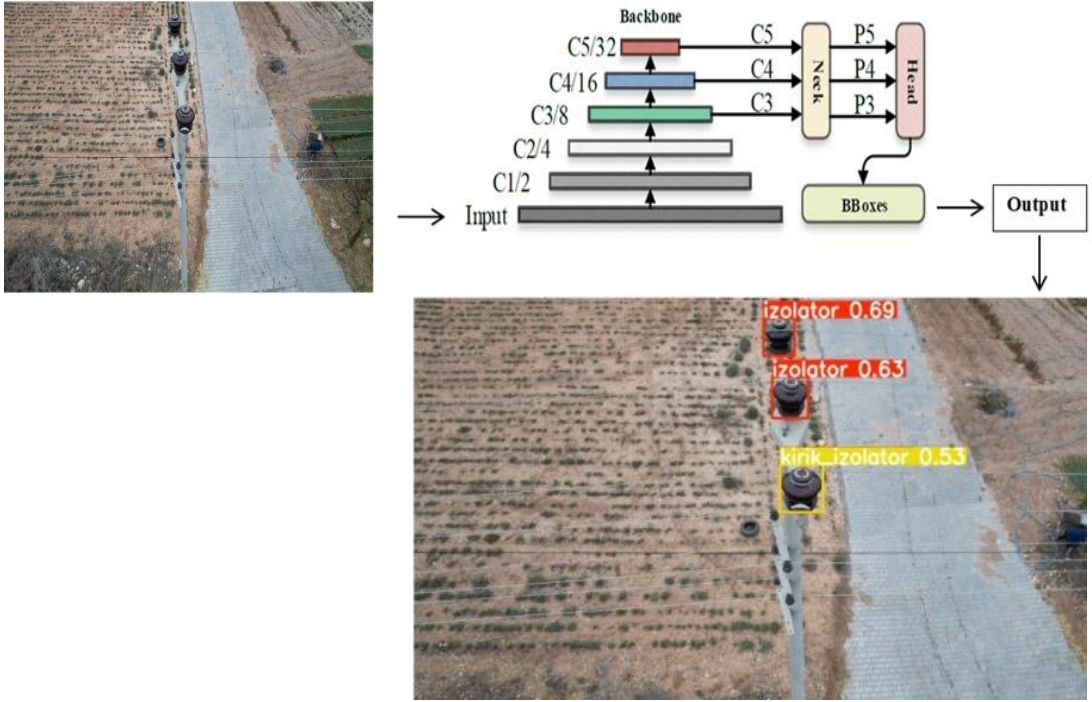
Şekil 6.4: YOLOV5 algoritma katmanları işleyiş akışı.

6.3 Değerlendirme

Bu aşamada görüntüler işlenerek YOLOV5 algoritmasından elde edilen hassasiyet değerleri ile her bir işlene görüntünün güven oranları belirlenir.

Bu tez çalışmasında nesne tespitinde kullanılan YOLOV5 algoritması ile tek aşamalı nesne tespiti yapıldı.

Şekil 6.5'te YOLOV5 algoritmasında tek aşamalı nesne işleme sonrası değerlendirme aşaması şematize edilmiştir (Liu vd, 2022).






Şekil 6.5: YOLOV5 tek aşamalı değerlendirme aşaması.

Görüntüler üzerinde sınıflayıcı değerlendirmesinde elde edilen güven oranlarını gösteren bazı görüntüler hem Şekil 6.6’da hem de Şekil 6.7’de verilmiştir.



Şekil 6.6: İzolator görüntüleri ve güven oranları.



Şekil 6.7: Çeşitli izolator görüntülerine ait güven oranları.

7. BULGULAR

İzolatör görüntülerinin işlenmesi sırasında elde edilen sonuçları kıyaslamak için mAP (ortalama hassasiyet değeri), APT (ortalama işleme süresi) değerlerinden ve görüntü sayılarından faydalanıldı.

Yapılan tez çalışmasında modelin tüm eğitim verileri üzerinden toplam 50 adet epoch turu geçiş yapılarak tüm veri baştan sona makine öğrenmesi aşamasında toplam 2,821 saat sürmüş olup hassasiyet rakamsal sonuçları Denklem 7.1 ve Denklem 7.2’de belirtilen yöntemlere göre hesaplandı.

Çalışma boyunca makine öğrenmesi aşamasında toplam 588 görüntü YOLOV5 ile eğitildi ve değerlendirme aşamasında 207 adet görüntü ile kesinlik belirlendi. Kesinlik, modelin ne kadar dikkatli olduğunu gösterir. F_p oranı düşük bir modelde kesinlik yüksek olur. Bu tez çalışmasında, izolatör ve kırık izolatör olarak tespit ettiği nesnelerin gerçekte doğru bir şekilde tespit edilme oranıdır.

Kesinlik hesaplamalarında Denklem 7.1 ve Denklem 7.2’den yararlanıldı (Zhao vd, 2020).

P: kesinlik

T_p : doğru pozitif değeri

F_p : yanlış pozitif değeri

Olmak üzere P (kesinlik) Denklem 1’e göre hesaplanır.

$$P = \frac{T_p}{T_p + F_p} \quad (7.1)$$

Duyarlılık (R) tespit edilmesi istenen gerçek nesnelerin model tarafından başarılı bir şekilde tespit edilme oranıdır. Bu tez çalışmasında, modelin kaç tane doğru izolatör ve doğru kırık izolatör yakaladığını ifade eder. Yüksek duyarlılık (R) modelin mümkün olduğunca fazla sayıda doğru nesneyi tespit ettiği anlamına gelir.

R: duyarlılık

T_p : doğru pozitif değeri

F_N : yanlış negatif değeri

Olmak üzere R (duyarlılık) Denklem 2'ye göre hesaplanır (Sirisha vd, 2023).

$$R = \frac{T_p}{T_p + F_N} \quad (7.2)$$

Yüksek kesinlik (P) ve düşük duyarlılık (R) değerleri uygulanan modelde yalnızca çok emin olduğu nesnelere tespit eder. Model yalnızca çok emin olduğu nesnelere tespit eder; yanlış tespitler azdır ama bazı gerçek nesnelere kaçırabilir. Yüksek duyarlılık (R) ve düşük kesinlik (P) durumunda model mümkün olduğunca fazla nesne tespit etmeye çalışır, ancak bu sefer yanlış tespit oranı artabilir.

AP_k : k sınıfının ortalama kesinliği

n: veri setindeki görüntü sayısı

Olmak üzere ise 0,507

(ortalama kesinlik değeri) Denklem 7.3'e göre hesaplanır (Zhang vd, 2022).

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (7.3)$$

mAP (mean Average Precision): Tüm sınıflar için AP değerlerinin ortalamasıdır. Eğer modeliniz birden fazla sınıf (örneğin "izolatör" ve "kırık izolatör") üzerinde eğitim aldıysa, kullanılan her bir sınıf için ayrı bir AP hesaplanır ve ortalaması alınarak mAP elde edilir. Farklı eşikler için mAP hesaplanabilir. Kodlama aşamasında algoritma 0.5 güven eşiği için oluşturulduysa mAP 0.5 eşiği için tüm sınıfların değerleri baz alınarak hesaplanır.

mAP@0.5: IoU = %50 eşik değerinde mAP hesaplanır, yani nesnelere %50 veya daha fazla örtüşme olduğunda doğru kabul edilir.

mAP@[0.5:0.95]: Farklı IoU eşiklerinde (0.5'ten 0.95'e kadar) mAP değerleri hesaplanarak bu değerlerin ortalaması bulunur (Terven vd, 2023). Bu yöntem daha zorlayıcıdır ve modelin daha yüksek doğrulukta tespit yapmasını gerektirir.

Nesne tespit modellerinde (YOLO veya R-CNN gibi) kullanılan ortalama kesinlik değeri (mAP), bir modelin tespit ettiği nesnelerin ne kadar doğru olduğunu ve uygulanan modelin tüm değerlendirilen görüntülerde cisimleri ne kadar başarı ile bulduğunu özetleyen bir ölçüttür. mAP, farklı IoU (kesişim bölü birleşim) eşik değerleri üzerinde, her sınıf için Average Precision (AP) değerlerinin ortalaması alınarak hesaplanır. AP, her bir veri seti için kesinlik ile duyarlılık (P-R) eğrisinin altındaki alanın ortalamasıdır (Sirisha vd, 2023).

Kesişim bölü birleşim olarak ifade edilebilen IoU (Intersection over Union) tespit edilen nesneyle gerçek nesne arasındaki örtüşme oranını ifade eder. IoU, “tahmin edilen sınırlayıcı kutu” ile “gerçek sınırlayıcı kutunun” kesişim alanının, birleşim alanına oranıdır.

F1 skoru Denklem 7.4'e göre hesaplanır (Haque vd, 2023).

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (7.4)$$

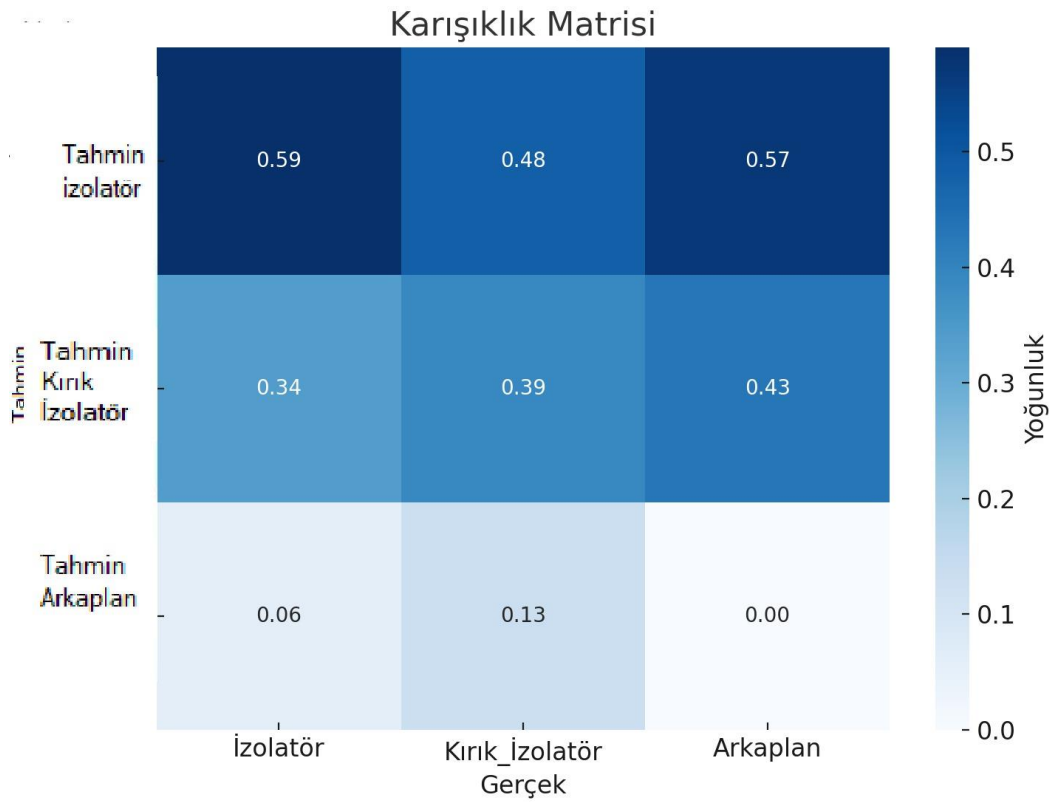
Genellikle, duyarlılık ve kesinlik oranlarını dengeleyen F1 Skoru adı verilen bir ölçüt kullanılır. F1 skoru, uygulanan modelin genel başarısını tartmak için sıkça kullanılan bir yöntemdir. Bu ölçütler, izolatör tespit modelimizin ne kadar etkili olduğunu ve eksiksiz çalışıp çalışmadığını değerlendirmek için oldukça önemlidir.

Değerlendirmede, 0.5 güven eşiği için izolatör ve kırık izolatör sınıflarına ait hesaplanan oranlar ve rakamsal değerler sırasıyla Tablo 7.1 ve 7.2'de listelenmiştir.

Tablo 7.1: İzolatör sınıfında 0.5 güven eşiği için hesaplanan veriler.

0.5 güven eşiği için:	İzolatör sayısı	İzolatör olarak tahminlenen izolatör görüntüsü	İzolatör olarak tahminlenen kırık izolatör görüntüsü	İzolatör olarak tahminlenen arka zemin görüntüsü	T_P oranı (%)	F_P oranı (%)	İzolatörlerde arka zemin hata oranı (%)
Toplam	138	80	47	11	58	34	8

Şekil 7.1' de verilen karışıklık matrisinde T_P , F_P , T_N , F_N oranları ile arka zemin hataları yüzdeler olarak görülmektedir.



Şekil 7.1: YOLOV5 ile elde edilen karışıklık matrisi

Tablo 7.2: Kırık izolatör sınıfında 0.5 güven eşiği için hesaplanan veriler.

0,5 güven eşiği için	Kırık izolatör numune görüntüsü	Kırık izolatör olarak tahminlenen kırık izolatör sayısı	Kırık izolatör olarak tahminlenen izolatör sayısı	Kırık zemin olarak tahminlenen arka zemin sayısı
	69	33	27	9
0,5 güven eşiği için	T_N	F_N	Kırık izolatörlerde arka zemin hata oranı	Toplamda ortalama arka zemin hata oranı
	% 48	% 39	% 13	% 9

Zhao ve arkadaşları (2020) mimari çizimleri sınıflamak için YOLO algortiması ile çizimleri ayırmayı hedeflemiş ve arka zemin hatalarını %8.03 olarak hesaplamışlardır. Bu çalışmada, kırık izolatörlerde arka zemin hata oranı % 13 olarak hesaplandı ancak toplamda arka zemin hatalarının ortalaması % 9 olarak Tablo 6.3' te görülmektedir.


8. SONUÇ VE ÖNERİLER

8.1 Sonuçlar


YOLO algoritmalarında P-R eğrişini çizmek için algortmada minimum eşik değeri ve maksimum eşik değeri belirtilerek bu iki eşik arasında belirlenen hassasiyet aralıklarında değerlerin tekrar hesaplanıp grafik oluşturulacağı kodlanır (Web 10). Bu çalışmada YOLOV5 için eşik 0.5 olarak alındı ve P-R eğrişinin eldesi için eşik en düşük sıfır (0) ve eşik en yüksek bir (1) olmak üzere binde bir aralıklarla (0,001) algoritma tespit yaptı.

Şekil 8.1'de verilen kesinlik- duyarlılık (P-R) grafiğinde izolatörler, kırık izolatörler ve tüm sınıfların kesinlik- duyarlılık (P-R) eğrileri görülmektedir. İzolatör sınıfında 0,5 eşik değeri için mAP değeri 0.702 (% 70.2)'dir. Bu grafikte en iyi mAP değerlerini gösteren izolatör sınıfıdır (Sirisha vd, 2023). Uygulanan model, izolatör nesnelere tespit ederken daha az yanlış pozitif üretmek daha fazla doğru tespit yapmaktadır (Zhang vd, 2022). Kırık izolatörler sınıfında 0,5 eşik değeri için ise mAP 0,507 olup izolatör sınıfına göre daha düşüktür. Görüntüsü incelenen yapının bileşen sayısı arttıkça izolatörlerdeki kırık hatasının tanımlanma başarısı düşmektedir (Zhao vd, 2020). Kırık izolatör sınıfına ait P-R eğrisi izolatör sınıf P-R eğrisine göre daha küçük değerler gösterirken eğride düşüş erken görülmektedir. Uygulanan modelin kırık izolatörleri tespit ederken daha fazla yanlış pozitif ürettiğini ve bazı kırık izolatör tespitlerini kaçırdığını göstermektedir. Tüm sınıflar için mAP değeri 0,604 olup modelin tüm sınıflar için ortalama performans değerini ifade eder. Uygulanan model izolatör sınıfı güçlü bir performans gösterirken kırık izolatör sınıfındaki düşük performans genel mAP değerini aşağı çekmiştir.

Model, "izolatör" sınıfında oldukça başarılı bir performans göstermiştir (70.2% mAP), ancak "kırık_izolator" sınıfındaki zayıf performans (50.7% mAP), genel başarıyı düşürmektedir. Modelin genel performansı ise ortalama düzeydedir (60.4% mAP). Özellikle düşük performans gösteren sınıfa odaklanarak, modelin başarısı daha da artırılabilir.




Şekil 8.1: Tüm sınıflar için kesinlik (P)- duyarlılık (R) grafiği.



Şekil 8.2: Uygulanan model için F1-güven oranı grafiği.

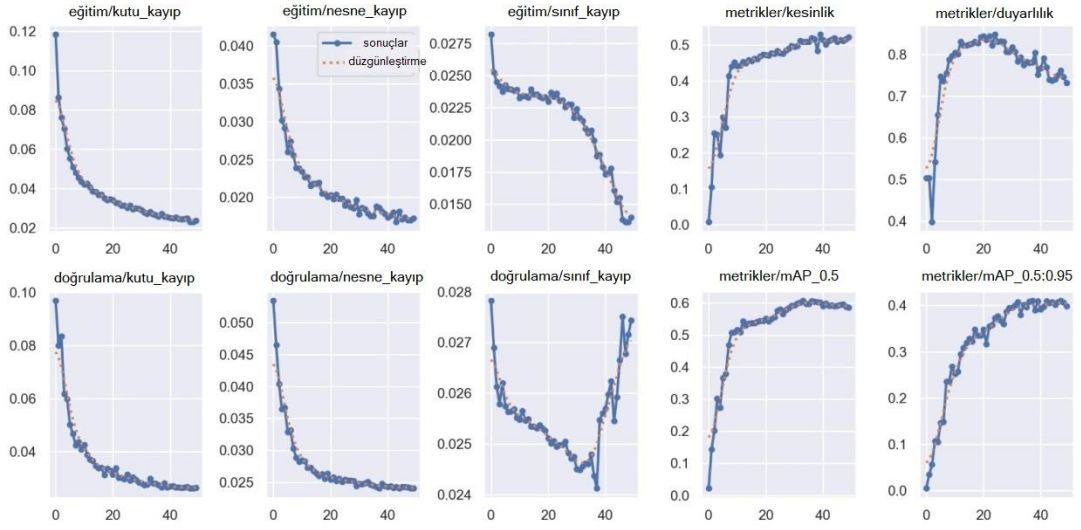
F1 skoru ve mAP değerleri uygulanan modelin performansını değerlendirirken kullanılan önemli ölçütlerdir (Haque vd, 2023, Hawaldar vd, 2023). Tüm sınıflar için F1 Skoru 0.62 olup ne çok yüksek oranda ne de çok düşük bir değerde nispeten ara düzey bir başarıyı göstermektedir. Ara düzeydeki başarı, uygulanan modelin kesinlik ve duyarlılık rakamsal sonuçlarının dengede olduğu anlamına gelmektedir. F1 skoru 0.7' ye yakın ve üzeri değerlerde olduğu için uygulanan model iyi performans göstermiş olarak kabul edilebilir (Haque vd, 2023). Ancak kırık izolator sınıfında, izolator sınıfına göre nispeten düşük F1 skoru gözlemlenmektedir.



Şekil 8.3: Uygulanan modelin duyarlılık-güven oranı (R-C) eğrisi.

Şekil 8.3' te verilen grafik, uygulanan modelin izolator sınıfı ve kırık izolator sınıfları için güven oranı arttıkça duyarlılık değerindeki değişimi göstermektedir. Grafikte güven oranı arttıkça duyarlılık değerinin düştüğü görülmektedir ki bu grafik modelin çalıştırılması için en ideal koşullara karar vermekte yardımcı olabilmektedir (Kumar M, 2024). İzolatör sınıfında yüksek güven oranlarında bile nispeten daha yüksek duyarlılık değerleri görülmekte olup uygulanan modelin izolator sınıfını tanımakta daha iyi olduğunu göstermektedir. Kırık izolator sınıfının düşük güven

oranlarında nispeten büyük duyarlılık değeri gösterdiği, fakat güven oranı arttıkça duyarlılığın hızla düştüğü görülmekte olup uygulanan modelin kırık izolatörleri ayırt etmekte daha zorlandığı anlaşılmaktadır (Yu ve Liu, 2023). Her iki sınıf birlikte değerlendirildiğinde ortalama performans olarak oldukça başarılı olan 0.96 duyarlılık değeri göstermektedir.



Şekil 8.4: Eğitim ve doğrulama kayıpları ölçütleri.

Şekil 8.4'te eğitim sürecindeki kayıplar ve doğruluk ölçütlerinin yer aldığı grafikler incelendiğinde modelin konum doğruluğu hatası (box loss) eğitim ve doğrulama setinde sürekli olarak azalmış olduğu ve modelin konumları öğrenmekte başarılı olduğu görülmektedir (Hawaldar vd, 2024). Nesne varlık kaybı (obj loss), modelin nesneleri algılama hassasiyetini göstermekte olup eğitim süresince bu değerde düşüş görülmesi uygulanan modelin öğrenme sürecinde iyileşme olduğunu belirtmektedir. Sınıf kaybı (cls loss) da azalma trendinde olup uygulanan modelin sınıfları daha doğru tanımaya başladığı değerlendirilmektedir. Kesinlik ve duyarlılık ölçütlerinde görülen artış uygulanan modelin doğruluk performansının gittikçe iyileşmiş olduğunu göstermektedir. Ortalama kesinlik puanları (mAP) %50 eşik değerinde ve %50-95 eşik değerleri arasında değişen kesişim bölü birleşim (IoU) eşliğinde uygulanan modelin doğruluğunu göstermektedir. Şekil 8.4'teki grafikler incelendiğinde uygulanan modelin doğruluğunun zamanla artış gösterdiği anlaşılmaktadır.

8.2 Öneriler

Uygulanan model, izolator sınıfında kırık izolator sınıfına göre daha iyi performans sergilemektedir. Modelin kırık izolatorleri tespit etmede gösterdiği nispeten düşük deęerleri iyileřtirmek için veri arttırmak, izolator çeřitlerini farklı sınıflarda deęerlendiren sınıflar oluřturmak gelecekte yurütülecek model oluřturma süreçlerinde irdelenerek eęitim parametrelerinin optimize edilmesi özellikle kırık izolator sınıfındaki performansı arttırabilecektir.

řekil 8.1'deki kırık izolator sınıfı için veriyi artırarak daha geniş ve dengeli veri seti oluřturarak kırık izolator sınıfında modelin daha iyi öęrenme yapması saęlanabilir. Ayrıca, IoU (kesiřim bölü birleřim) eřik deęerleri incelenerek, modelin bu kırık izolator sınıfında yanlış pozitif üretme nedenleri arařtırılabilir. Ayrıca, model uygulanırken birbirinden çok farklı tipte izolatorler kullanıldı, örneęin zincir izolator, mesnet tipi izolator, askı tipi izolator, beyaz izolator, kahverengi izolator kullanıldı. Bununla birlikte birbirine benzer yapıdaki nesnelerin içerisindeki çok küçük farklılıkları ayırt edecek řekilde saęlam ve kırık izolator tespitlerinin yapılmasının zorluęu özellikle kırık izolator sınıfında mAP deęerlerinin saęlam izolator sınıfına göre daha az çıkmasına yol açmıřtır.

Kırık izolator sınıfı için veri çoęaltarak bu sınıfta F1 skorunun daha yüksek deęerler verebilmesi amacıyla düzeltme ve iyileřtirme çalıřmaları önerilebilir.

Uygulanan modelde mAP deęerleri oldukça başarılı ancak, F1 skorunu özellikle kırık izolator sınıfında biraz daha arttırmak modelin performansını geliřtirmek için faydalı olabilir.

9. KAYNAKLAR

Ahmed, M.D.F., Mohanta, J.C. and Sanyal, A., “Inspection and identification of transmission line insulator breakdown based on deep learning using aerial images”, *Electric Power Systems Research*, 211, (2022).

Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaria, J., Fadhel, M.A., Al-Amisie, M. and Farhan L., “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions”, *Journal of Big Data*, 8, 1-74, (2021).

Bishop, C. M. and Nasrabadi, N. M., *Pattern recognition and machine learning*, New York: Springer. 84-92, (2006).

Breiman, L., “Random forests”, *Machine Learning*, 45, 5-32, (2001).

Chen, J., Liu, Z., Wang, H., Núñez, A. and Han, Z., “Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network”, *IEEE Transactions on Instrumentation and Measurement*, 67(2), 257-269, (2017).

Cortes, C. and Vapnik, V., “Support-vector networks”, *Machine Learning*, 20, 273-297, (1995).

Davis, E. and Pounds, P. E., “Direct sensing of thrust and velocity for a quadrotor rotor array”, *IEEE Robotics and Automation Letters*, 2(3), 1360-1366, (2017).

Elman, J. L., “Finding structure in time”, *Cognitive Science*, 14(2), 179-211, (1990).

Foudeh, H. A., Luk, P. C. K. and Whidborne, J. F., “An advanced unmanned aerial vehicle (UAV) approach via learning-based control for overhead power line monitoring: A comprehensive review”, *IEEE Access*, 9, 130410-130433, (2021).

Gageik, N., Benz, P. and Montenegro, S., “Obstacle detection and collision avoidance for a UAV with complementary low-cost sensors”, *IEEE Access*, 3, 599-609, (2015).

Girshick, R., “Fast R-CNN”, *In Proceedings of the IEEE international conference on computer vision*, 1440-1448, (2015).

Girshick, R., Donahue, J., Darrell, T. and Malik, J., “Rich feature hierarchies for accurate object detection and semantic segmentation”, *In Proceedings of the IEEE conference on computer vision and pattern recognition* (580-587), (2014).

Goodfellow, I., Bengio, Y. and Courville, A., “Deep learning”, *MIT press*, (2016).

Guo, W., Wang, H., Han, Z., Zhong, J. and Liu, Z., “A novel low-light catenary image enhancement approach for CSCs detection in high-speed railways”, *IEEE Open Journal of Instrumentation and Measurement*, 1, 1-7, (2022).

Haque, N., Serker, M. and Bin Bashir, T., “BdSpell: A YOLO-based Real-time Finger Spelling System for Bangla Sign Language”, *Cornell University arXiv*, (2023).

Hawaldar, V., Jain, R., Mengde, M. and Agrawal, S., “Revolutionizing Plant Disease Detection in Agriculture: a Comparative Study of Yolov5 and Yolov8 Deep Learning Models”, *ResearchSquare*, vol 1, 1-24, (2024).

Hochreiter, S. and Schmidhuber, J., "Long Short-Term Memory", *Neural Computation*, 9(8), 1735-1780, (1997).

Jain, A. K., Murty, M. N. and Flynn, P. J., “Data clustering: a review”, *ACM computing surveys (CSUR)*, 31(3), 264-323, (1999).

Kang, J., Tariq, S., Oh, H. And Woo, S. S., “A survey of deep learning-based object detection methods and datasets for overhead imagery”, *IEEE Access*, 10, 20118-20134, (2022).

Krizhevsky, A., Sutskever, I. and Hinton, G. E., “Imagenet classification with deep convolutional neural networks”, *Advances in neural information processing systems*, 25, (2012).

Kumar, M., “Advanced YOLO-Based Trash Classification and Recycling Assistant for Enhanced Waste Management and Sustainability”, *Second International Conference on Intelligent Cyber Physical Systems and Internet of Things (ICoICI 2024)*, Coimbatore, Tamil Nadu, (2024).

Landwehr, J.P., Kühl, N., Walk, J. and Gnadig, M., “Design Knowledge for Deep-Learning-Enabled Image-Based Decision Support Systems”, *Business & Information Systems Engineering*, 1-22, (2022).

LeCun, Y., Bottou, L., Bengio, Y. And Haffner, P., “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, 86(11), 2278-2324, (1998).

LeCun, Y., Bengio, Y. and Hinton, G. “Deep learning”, *Nature*, 521, 436–444, (2015).

Liu, H., Sun, F., Gu, J. and Deng, L., “SF-YOLOv5: A Lightweight Small Object Detection Algorithm Based on Improved Feature Fusion Mode”, *Sensors*, 22(15), (2022).

Li Z, Zhang Y, Wu H, Suzuki S, Namiki A. and Wang W., “Design and Application of a UAV Autonomous Inspection System for High-Voltage Power Transmission Lines”, *Remote Sensing*, 15(3):865, (2023).

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y. and Berg, A. C., “SSD: Single shot multibox detector. In *Computer Vision–ECCV 2016*”, *14th European Conference, Proceedings, Part I*, 14, Springer International Publishing, Amsterdam, The Netherlands, 21-37, (2016).

Maduako, I., Igwe, C.F., Abah, J.E., Onwuasaanya, O.E., Chukwu, G.A., Ezeji, F. and Okeke, F.I., “Deep learning for component fault detection in electricity transmission lines”, *Journal of Big Data*, 9, 1-34, (2022).

Malta, A., Mendes, M. and Farinha, T., “Augmented Reality Maintenance Assistant Using YOLOv5”, *Applied Sciences*, 11(11), (2021).

Martinez, C., Sampedro, C., Chauhan, A. and Campoy, P., “Towards autonomous detection and tracking of electric towers for aerial power line inspection”, *International Conference on Unmanned Aircraft Systems (ICUAS)*, 284-295, (2014).

Mitchell, T. M. and Mitchell, T. M., *Machine Learning*, New York: McGraw-hill, 43-57, (1997).

Na, H. J. and Yoo, S. J., “PSO-based dynamic UAV positioning algorithm for sensing information acquisition in wireless sensor networks”, *IEEE Access*, 7, 77499-77513, (2019).

Nguyen, V.N., Jenssen, R. and Roverso, D., “Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning”, *International Journal of Electrical Power & Energy Systems*, 99, 107-120, (2018).

Redmon, J., Divvala, S., Girshick, R. and Farhadi, A., “You only look once: Unified, real-time object detection”, In *Proceedings of the IEEE conference on computer vision and pattern recognition*, (779-788), (2016).

Ren, S., He, K., Girshick, R. and Sun, J., “Faster R-CNN: Towards real-time object detection with region proposal networks”, *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137-1149, (2016).

Rumelhart, D. E., Hinton, G. E. and Williams, R. J., “Learning representations by back-propagating errors”, *Nature*, 323(6088), 533-536, (1986).

Sirisha, U., Praveen, S.P., Srinivasu, P.N., Barsocchi, P. and Bhoi, A.K., “Statistical Analysis of Design Aspects of Various YOLO-Based Deep Learning Models for Object Detection”, *International Journal of Computational Intelligence Systems*, 16, (2023).

Sutton, R. S. and Barto, A. G., *Reinforcement Learning: An Introduction*, Cambridge, MA: MIT Press, (2018).

Szeliski, R., *Computer Vision: algorithms and applications*, New York: Springer Nature, 85-151, (2022).

Sutskever, I., Vinyals, O. and Le, Q. V., “Sequence to sequence learning with neural networks”, *Advances in neural information processing systems*, 27, (2014).

Tan, J., “Automatic insulator detection for power line using aerial images powered by convolutional neural networks”, *Journal of Physics: Conference Series*, 1748, 1-12, (2021).

Tang G, Ni J, Zhao Y, Gu Y. and Cao W., “A Survey of Object Detection for UAVs Based on Deep Learning”, *Remote Sensing*, 16(1), 149, (2024).

Terven, J., Córdova-Esparza, D. -M. and Romero-González, J. -A., “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS”, *Machine Learning and Knowledge Extraction*, 5(4), 1680-1716, (2023).

Tulbure, A.A. and Dulf, E.H., “A review on modern defect detection models using DCNNs – Deep convolutional neural networks”, *Journal of Advanced Research*, 35, 33-48, (2022).

Viraktamath, D. S., Navalgi, P. and Neelopant, A., “Comparison of YOLOv3 and SSD algorithms”, *International Journal of Enineering Research Technology*, 10(2), 193-196, (2021).

Werbos, P. J., “Backpropagation through time: what it does and how to do it”, *Proceedings of the IEEE*, 78(10), 1550-1560, (1990).

Web1: https://d2l.ai/chapter_computer-vision/rcnn.html, erişim tarihi: 01/07/2024

Web2: <https://www.pluralsight.com/resources/blog/guides/introduction-to-lstm-units-in-rnn>, erişim tarihi: 02/07/2024

Web3: <https://stanfordpython.com/#/>, erişim tarihi: 05/03/2024.

Web4:<https://www.elektrikport.com/makale-detay/izolatorler-1-bolum-elektrikport-akademi/12138#ad-image-0>, erişim tarihi: 04/08/2024

Web5: <https://omeryalcin.com/product/vks-35/> , erişim tarihi: 04/08/2024

Web6:https://eemtf.firat.edu.tr/ee.tek.firat.edu.tr/files/Enerji%20Sistemleri_4.pdf, erişim tarihi: 04/08/2024

Web7: https://github.com/bethusaisampath/YOLOv5_Openvino, erişim tarihi: 27/11/2024.

Web8:https://docs.ultralytics.com/tr/yolov5/tutorials/architecture_description/, erişim tarihi: 27/11/2024.

Web9: <https://sh-tsang.medium.com/brief-review-yolov5-for-object-detection-84cc6c6a0e3a>, erişim tarihi 27/11/2024

Web10: <https://medium.com/@douglaspsteen/precision-recall-curves-d32e5b290248>, erişim tarihi: 03/12/2024

Xu , C., Li , Q., Zhou, Q., Zhang, S., Yu, D. and Y. Ma., "Power line-guided automatic electric transmission line inspection system", *IEEE Transactions on Instrumentation and Measurement*, 71, 1-18, (2022).

Yang, L., Fan, J., Liu, Y., Li, E., Peng, J. and Liang, Z., "A review on state-of-the-art power line inspection techniques", *IEEE Transactions on Instrumentation and Measurement*, 69(12), 9350-9365, (2020).

Yang, L., Fan, J., Song, S. and Liu, Y., "A light defect detection algorithm of power insulators from aerial images for power inspection", *Neural Computing and Applications*, 34, 17951-17961, (2022).

Yu, L. and Liu, S., "A Single-Stage Deep Learning-based Approach for Real-Time License Plate Recognition in Smart Parking System", *International Journal of Advanced Computer Science and Applications*, vol 14, (2023).

Zakeri Nasrabadi, M., Parsa, S., and Kalae, A., "Format-aware learn&fuzz: deep test data generation for efficient fuzzing", *Neural Computing and Applications*, 33(5), 1497-1513, (2021).

Zhao, Y., Deng, X. and Huahui, L., "A Deep Learning-Based Method to Detect Components from Scanned Structural Drawings for Reconstructing 3D Models", *Applied Sciences*, 10, (2020).

Zhang, Y., Guo, Z., Wu, J., Tian, Y., Tang, H. and Guo, X., "Real-Time Vehicle Detection Based on Improved YOLO v5", *Sustainability*, 14, 12274, (2022).