



Sonay ŞENGÜL

HESAPLAMALI BİLİMLER VE MÜHENDİSLİK ANABİLİM DALI

Yüksek Lisans Tezi
2024

T.C.
KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK
ANABİLİM DALI

COĞRAFİ BİLGİ SİSTEMLERİNDE ELEKTRİK
DİREKLERİNİN DERİN ÖĞRENME YÖNTEMLERİYLE
TESPİT EDİLMESİ

Hazırlayan
Sonay ŞENGÜL

Danışman
Doç. Dr. Bahatdin DAŞBAŞI
Dr. Öğretim Üyesi Murat TAŞYÜREK

Yüksek Lisans Tezi

Ağustos 2024, KAYSERİ

T.C.
KAYSERİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK
ANABİLİM DALI

COĞRAFİ BİLGİ SİSTEMLERİNDE ELEKTRİK DİREKLERİNİN
DERİN ÖĞRENME YÖNTEMLERİYLE TESPİT EDİLMESİ
(Yüksek Lisans Tezi)

Hazırlayan
Sonay ŞENGÜL

Danışman
Doç. Dr. Bahatdin DAŞBAŞI
Dr. Öğretim Üyesi Murat TAŞYÜREK

Ağustos 2024, KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Sonay ŞENGÜL



T.C.
KAYSERİ ÜNİVERSİTESİ
Lisansüstü Eğitim Enstitüsü Müdürlüğü

Anabilim Dalı : Hesaplamalı Bilimler ve Mühendislik
Program Adı : Yüksek Lisans
Tez Başlığı : Coğrafi Bilgi Sistemlerinde Elektrik Direklerinin Derin Öğrenme Yöntemleriyle Tespit edilmesi

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 38 sayfalık kısmına ilişkin 21/07/2024 tarihinde Turnitin intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı: % 17' dir.

Uygulanan filtrelemeler:

- 1- Giriş dâhil
- 2- Ana Bölümler dâhil
- 3- Sonuç dâhil
- 4- Alıntılar dâhil
- 5- Kapak hariç
- 6- Önsöz ve Teşekkür hariç
- 7- İçindekiler hariç
- 8- Kaynakça hariç
- 9- Özet hariç
- 10- Yedi (7) kelimedenden daha az örtüşme içeren metin kısımları hariç

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Önerisi Hazırlama, Tez Yazma ve Teslim Yönergesini inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 01/08/2024

Danışman:
Doç. Dr. Bahatdin DAŞBAŞI

Öğrenci:
Sonay ŞENGÜL

YÖNERGEYE UYGUNLUK ONAYI

"Coğrafi Bilgi Sistemlerinde Elektrik Direklerinin Derin Öğrenme Yöntemleriyle Tespit edilmesi" adlı yüksek lisans tezi, Kayseri Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi 'ne uygun olarak hazırlanmıştır.

Hazırlayan

Sonay ŞENGÜL

Danışman

Doç. Dr. Bahatdin DAŞBAŞI

Hesaplamalı Bilimler ve Mühendislik Anabilim Dalı Başkanı

Prof. Dr. Ercan KARAKÖSE

KABUL VE ONAY TUTANAĞI

Doç. Dr. Bahatdin DAŞBAŞI danışmanlığında **Sonay ŞENGÜL** tarafından hazırlanan "**Coğrafi Bilgi Sistemlerinde Elektrik Direklerinin Derin Öğrenme Yöntemleriyle Tespit Edilmesi**" adlı bu çalışma jürimiz tarafından Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Hesaplamalı Bilimler ve Mühendislik Anabilim Dalında **Yüksek Lisans Tezi** olarak kabul edilmiştir.

01 /08/ 2024

JÜRİ:

Danışman :Doç. Dr. Bahatdin DAŞBAŞI

Üye :Dr. Öğretim Üyesi Nuh AZGINOĞLU

Üye :Dr. Öğretim Üyesi Bilge Kağan DEDETÜRK

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun tarih ve sayılı kararı ile onaylanmıştır.

...../...../.....

Doç. Dr. Ahmet TERZİ

Enstitü Müdürü

ÖNSÖZ/TEŞEKKÜR

Yüksek lisans tez çalışmam süresince yardımlarını esirgemeyen ve tez çalışmamı tamamlamamda her zaman desteklerini hissettiren danışman hocalarım Sayın Doç. Dr. Bahatdin DAŞBAŞI ve Sayın Dr. Öğr. Üyesi Murat TAŞYÜREK' e, ayrıca her koşulda yanımda olan aileme en derin teşekkürlerimi sunarım.

Sonay ŞENGÜL, Kayseri 2024



COĞRAFİ BİLGİ SİSTEMLERİNDE ELEKTRİK DİREKLERİNİN DERİN ÖĞRENME YÖNTEMLERİYLE TESPİT EDİLMESİ

Sonay ŞENGÜL

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü

Yüksek Lisans Tezi, Ağustos 2024

Danışman: Doç. Dr. Bahatdin DAŞBAŞI

İkinci Danışman: Dr. Öğr. Üyesi Murat TAŞYÜREK

ÖZET

Fotoğraflandırılmış doğal görüntülerden nesne tanıma işi ışığın geliş açısı, derinlik kavramı, görüntüde birden fazla nesne olması ve görüntü çözünürlüğü gibi etkenler göz önünde bulundurulduğunda oldukça zor ve karmaşık bir süreçtir. Fotoğraflandırılmış doğal görüntülerden elektrik direklerinin tespit edilmesi bir bilgisayar ve makine öğrenmesi işidir. Makine öğrenmesi veya derin öğrenme (DL) ile görüntü sınıflandırma süreçlerinde en sık kullanılan yöntemlerden biri Evrişimsel Sinir Ağı (convolutional neural network-CNN) modelidir.

Bu çalışmada doğal görüntülerden oluşan direk fotoğraflarından direk nesnelere belirlenmiş ve bunun için öncelikle CNN temelli DL yöntemi kullanılmıştır. Ancak, görüntünün birden fazla direk içerdiği ve derinliğin farklılaştığı durumlarda istenilen etkili sonuçlara ulaşılamamıştır. Bu nedenle hem doğruluğu arttırmak, hem başarılı sonuçlara ulaşmak hem de doğal görüntülerden oluşan bu kütüphanede daha küçük veri boyutlarıyla çalışmış olmak için üç farklı CNN modeli kullanılarak yeni bir DDL (Deep in Deep Learning) yaklaşımı sunulmuştur.

Sunulan bu DDL yönteminde sahadan çekilen ve konum bilgisi içeren 1 GB boyutunda 2343 adet direk fotoğrafı kullanılarak önerilen üç farklı yaklaşımın bu direk görüntülerini tanıması ve belirlemedeki başarısı ve performansı karşılaştırılmıştır.

Yapılan çalışmalar sonucunda DDL yönteminin DL yöntemine göre daha yüksek performans sergilediği, daha kısa sürede daha başarılı sonuçlar ürettiği ve veri depolama için daha az alana ihtiyaç duyduğu görülmüştür.

Anahtar Kelimeler: Derin Öğrenme, Coğrafi Bilgi Sistemleri, YOLO, ResNet, MobileNet

DETECTION OF ELECTRIC POLES IN GEOGRAPHIC INFORMATION SYSTEMS USING DEEP LEARNING METHODS

Sonay ŞENGÜL

Kayseri University, Institute of Graduate Education

Master Thesis, August 2024

Supervisor: Doç. Dr. Bahatdin DAŞBAŞI

Second Supervisor: Dr. Öğr. Üyesi Murat TAŞYÜREK

ABSTRACT

Recognizing objects such as electric poles from photographed natural scenes is a challenging and complex process, considering factors like lighting angles, depth, multiple objects in the image, and image resolution. Identifying electric poles from photographed natural scenes is a task involving computer vision and machine learning techniques. One of the most commonly used methods in image classification tasks using machine learning or deep learning (DL) is the Convolutional Neural Network (CNN) model.

In this study, electric poles were identified from natural scene photographs using a CNN-based DL method. However, achieving desired effective results proved difficult when images contained multiple poles with varying depths. Therefore, to improve accuracy, achieve successful outcomes, and work with smaller data sizes from this library of natural images, a new approach called Deep in Deep Learning (DDL) was introduced using three different CNN models.

In this proposed DDL approach, the success and performance of three different approaches in identifying and determining these pole images were compared using 2343 pole photographs, each sized at 1 GB and containing location information collected from the field. The studies revealed that the DDL method outperformed traditional DL methods by producing higher performance, yielding more successful results in less time, and requiring less storage space for data.

Overall, the research concluded that the DDL approach offers enhanced performance compared to conventional DL methods, achieving better results more efficiently while utilizing less storage space.

Keywords: Deep Learning, Geographic Information Systems, YOLO, ResNet, MobileNet

İÇİNDEKİLER

COĞRAFİ BİLGİ SİSTEMLERİNDE ELEKTRİK DİREKLERİNİN DERİN ÖĞRENME YÖNTEMLERİYLE TESPİT EDİLMESİ

BİLİMSEL ETİĞE UYGUNLUK	i
TEZ İNTİHAL RAPORU TESLİM FORMU	ii
YÖNERGEYE UYGUNLUK ONAYI	iii
KABUL VE ONAY TUTANAĞI	iv
ÖNSÖZ/TEŞEKKÜR	v
ÖZET	vi
ABSTRACT	vii
KISALTMALAR VE SİMGELER LİSTESİ	x
TABLolar LİSTESİ	xi
ŞEKİLLER LİSTESİ	xii
GİRİŞ	1

BİRİNCİ BÖLÜM LİTERATÜR TARAMASI

İKİNCİ BÖLÜM

EVRIŞİMLİ SINIR AĞI TABANLI DERİN ÖĞRENME YÖNTEMLERİ İLE ELEKTRİK DİREKLERİNİN TESPİT EDİLMESİ

2.1. Derin Öğrenme	9
2.1.1. Derin Öğrenmenin Uygulama Alanları	11
2.1.2. Derin Öğrenmenin Çalışma Prensipleri	12
2.2. Elektrik Direklerinin Derin Öğrenme Yöntemleriyle Tespit edilmesi	14
2.2.1. YOLO Yöntemi	14
2.2.2. ResNet Yöntemi.....	18
2.2.3. MobileNet Yöntemi	23

ÜÇÜNCÜ BÖLÜM
DERİN ÖĞRENME TABANLI YAKLAŞIMLA ELEKTRİK DİREKLERİNİN
TESPİT EDİLMESİ

DÖRDÜNCÜ BÖLÜM
YÖNTEM ve DENEYSEL ÇALIŞMALAR

4.1. Veri Seti.....	28
4.2. Yapılan Deneyler ve Kullanılan Yöntemlerin Doğrulukları	29
SONUÇLAR VE TARTIŞMA	30
KAYNAKÇA	31
ÖZ GEÇMİŞ.....	36
TEZ İNTİHAL RAPORU	37

KISALTMALAR VE SİMGELER LİSTESİ

- CBS** : Coğrafi Bilgi Sistemleri
- CNN** : Convolutional Neural Network (Evrişimsel Sinir Ağı)
- DL** : Deep Learning (Derin Öğrenme)
- GPS** : Global Positioning System
- MobileNet** : Mobile Network
- ResNet** : Residual Network
- YOLO** : You Only Look Once

TABLÖLAR LİSTESİ

Tablo 2.1.	<i>YOLO Yöntemi F1 Güven Skoru (YOLO Method F1 Confidence Score)</i>	18
Tablo 2.2.	<i>ResNet Yöntemi F1 Güven Skoru (ResNet Method F1 Confidence Score) .</i>	22
Tablo 2.3.	<i>MobileNet Yöntemi F1 Güven Skoru (MobileNet Method F1 Confidence Score).....</i>	25
Tablo 3.1.	<i>DL Yöntemleriyle Direk Objelerinin Tespiti (Detection Of Electric Poles With DL Models)</i>	27
Tablo 4.1.	<i>Yöntemlerin Karşılaştırması(Comparison of Methods)</i>	29

ŞEKİLLER LİSTESİ

Şekil 1.1.	<i>CBS Uygulaması Fotoğraf Görüntüleyici(GIS App Photo Viewer)</i>	<i>5</i>
Şekil 2.1.	<i>YOLO CNN Mimarisi (YOLO CNN Architecture)</i>	<i>15</i>
Şekil 2.2.	<i>Giriş Görüntüsü (Input Image).....</i>	<i>16</i>
Şekil 2.3.	<i>Tahminleme Yapılmayan Görüntü (Image Without Prediction)</i>	<i>17</i>
Şekil 2.4.	<i>ResNet Mimarisi (ResNet Architecture)</i>	<i>20</i>
Şekil 2.5.	<i>ResNet Girdi Görüntüsü (ResNet Input Image)</i>	<i>21</i>
Şekil 2.6.	<i>Birden Fazla Nesne Olan Görüntü (Image with Multiple Objects)</i>	<i>22</i>
Şekil 2.7.	<i>MobileNet Mimarisi (MobileNet Architecture)</i>	<i>24</i>
Şekil 2.8.	<i>Derinliğin çok olduğu görüntü (The image with a lot of depth).....</i>	<i>25</i>

GİRİŞ

Coğrafi Bilgi Sistemleri (CBS), yeryüzündeki nesnelere ait bilgileri belirli bir amaç dahilinde toplayıp, bilgisayar ortamında depolama, güncelleme, görüntüleme, kontrol ve analiz etme gibi işlemlere yarayan bir karar destek mekanizmasıdır [1]. İş hayatında ve sosyal yaşamda karşılaşılan karmaşık sorunlara yönelik konuma dayalı karar verme aşamalarında kullanıcılara, vatandaşlara ve iş yerlerine yardımcı olan, konuma dayalı gözlemlerden elde edilen grafik veya grafik olmayan bilgilerin saklanması, yönetilmesi, işlenmesi ve sunulmasına yarayan bir yöntemler bütünüdür [2].

Coğrafi bilgi sistemleri (CBS), yer tabanlı verilerin toplanması, depolanması, yönetilmesi, analiz edilmesi ve görselleştirilmesi için kullanılan bir teknoloji ve disiplindir. Bu bağlamda, coğrafi bilgi sistemlerinin temel bileşenleri;

- Veri: Coğrafi konum bilgilerini içeren veri setleri (örneğin, nokta, çizgi, alan verileri),
- Yazılım: Verilerin analiz edilmesini, yönetilmesini ve görselleştirilmesini sağlayan yazılımlar (ArcCBS, QCBS, MapInfo gibi),
- Donanım: Veri toplamak ve işlemek için kullanılan bilgisayarlar, GPS(Global Positioning System) cihazları, sensörler gibi donanımlar.
- Personel: Verilerin toplanması, yorumlanması ve kararların alınması için uzmanlık gerektiren insan kaynağı.olarak sıralanabilmektedir [3]. Ayrıca coğrafi bilgi sistemleri;
- Belediye hizmetleri alt yapı (Su, elektrik, telefon, kanalizasyon) ve ulaşım planlama,
- Arazi yönetimi ve arazi kullanım planlaması,
- Kentsel planlama ve ormancılık,
- Askeri uygulamalar
- Bilgisayar destekli harita üretimi

gibi çok çeşitli uygulama alanlarına sahip olmasıyla ve günümüz teknolojik gelişmeleriyle birlikte hemen her kurum ve kuruluşun ihtiyaç duyduğu bir sistemler bütünü haline gelmiştir [4].

CBS, günümüzde veri odaklı karar almayı güçlendiren ve karmaşık sorunların çözümüne yardımcı olan önemli bir araç haline gelmiştir. Hem kamu sektöründe hem de özel sektörde geniş bir uygulama alanına sahiptir ve teknolojinin ilerlemesiyle birlikte daha da yaygınlaşmaktadır.

Elektrik Dağıtım Şirketleri için ise CBS, elektrik şebekesini oluşturan trafo, hat, direk gibi varlıklara ve bu varlıklara ilişkin arıza, bakım, onarım, kesinti gibi olaylara ait coğrafi, sözel, sayısal ve öznitelik bilgilerin saklanması, birbirleriyle ilişkilendirilmesi ve yönetilmesi işlemlerini sağlamaktadır. Ayrıca bu bilgiler üzerinden sorgulamalar ve analizler yaparak sorunlara dair çeşitli stratejiler üretilmesine olanak sağlamaktadır [5].

Elektrik dağıtım şirketleri için oldukça önem arz eden şebeke bağlantı modelinin, coğrafi bilgi sistemleri veri tabanlarına işlenirken, şebeke envanter unsurlarının (hat, direk, kesici, ayırıcı, trafo vb.) güncel ve doğru bir şekilde aktarılabilmesi oldukça önemlidir.

Bir dağıtım şebekesi basit anlamda; direk, hat, trafo, kesici, ayırıcı gibi şebeke unsurlarının birbirlerine ne şekilde ve hangi şatlarda bağlı olduklarını ve kullanıcıların dağıtım şebekesine nerden bağlı olduklarını gösteren bir yapıdır. Coğrafi bilgi sistemleri bu yapının kullanıldığı harita tabanı ile şebeke varlıklarının belirtilmesi ve güncel tutulması için kullanılır [6]. Dolayısıyla elektrik dağıtım şirketlerinde CBS' nin kullanıldığı alanlar ise şu şekilde sıralanabilir:

- Ağ Yönetimi: Elektrik dağıtım şirketleri, oldukça geniş bir ağ üzerinde elektrik dağıtımını yapmaktadırlar. CBS bu elektrik dağıtım şebekesinin haritalanması, yönetilmesi ve güncellenmesi için çok kritik bir rol oynamaktadır. Elektrik ağı üzerindeki trafolar, iletim hatları, dağıtım hatları, direkler ve diğer altyapı unsurları CBS kullanılarak detaylı bir şekilde takip edilebilmektedir [7].
- Planlama ve Optimizasyon: CBS elektrik şirketlerine altyapı genişletme, bakım planlama ve yük yönetimi gibi önemli konularda stratejik kararlar almaları için yardımcı olmaktadır. Örneğin, yeni bir trafo istasyonu veya dağıtım hattı planlandığında, en uygun yeri bulmak adına CBS kullanılarak ideal konum belirlenmekte ve bu altyapının mevcut ağa entegrasyonu analiz edilebilmektedir [8].

- Arıza Yönetimi ve Bakım: Elektrik dağıtım şirketleri, olası bir arıza durumunda oldukça hızlı müdahale etmek zorundadırlar. CBS, arıza bildirimleri alındığında, ekiplerin olay yerine en hızlı şekilde yönlendirilmesine yardımcı olabilmektedir. Ayrıca, bakım programları düzenlenirken, altyapılardaki kritik noktalar ve yaşanan şebeke unsurlarının belirlenebilmesi için CBS kullanılmaktadır [7].
- Müşteri Hizmetleri Operasyonları Yönetim Süreçleri: Elektrik dağıtım şirketleri, sorumlu oldukları bölgelerdeki abonelerin bilgi, istek ve taleplerini etkin bir şekilde karşılamak durumundadırlar. CBS müşteri hizmetleri departmanlarına, abonelerin konumlarına göre elektrik kesintisi durumları hakkında doğru ve hızlı bilgi sağlayabilmekte ve ayrıca abonelerin yeni bağlantı talepleri veya altyapı değişiklik istekleri de CBS kullanılarak değerlendirilebilmektedir [7].
- Güvenlik ve Risk Yönetimi: Elektrik dağıtım şebekeleri, çeşitli çevresel risklere karşı korunmak durumundadır. CBS ile doğal afetlerin etkileri analiz edilerek olası bir afet durumunda riskli bölgeler belirlenebilir ve bu bölgelerde alınması gereken önlemlerin planlaması konusunda yardımcı olabilir. Ayrıca, güvenlik açısından kritik olan tesislerin tespit edilmesi ve bu tesislerin korunması amacıyla da CBS kullanılabilir [9].

Elektrik dağıtım şirketleri için CBS, operasyonel verimliliği artırmanın yanı sıra, hizmet kalitesini iyileştirmek ve maliyetleri azaltmak için de önemli bir araçtır. Doğru ve güncel coğrafi verilere dayanan kararlar, şirketlerin rekabet avantajı sağlamasına ve sürdürülebilirliklerini artırmasına yardımcı olur. Bu nedenle, modern elektrik dağıtım şirketleri için CBS, stratejik bir yatırım olarak değerlendirilir.

Coğrafi bilgi sistemleri, coğrafi olarak oldukça dağınık bölgelerde hizmet veren elektrik dağıtım şirketleri için şebeke envanterlerini öznitelik bilgileri ile beraber coğrafi olarak sayısal bir harita veri tabanı üzerinde tutulmasına hizmet etmektedir. Daha önceleri planlarda, projelerde, kâğıt ortamında ya da sayısal ortamda bulunan tüm veriler sayısallaştırılıp coğrafi bilgi sistemleri ile birlikte çok katmanlı, sorgulanabilir ve analiz edilebilir bir hale getirilmiştir. Böylelikle elektrik dağıtım şebekesi daha verimli olarak kullanılabilir ve gerçek zamanlı olarak izlenebilir hale gelmiştir [10].

Aynı zamanda CBS elektrik şebekesine ait envanterlerin sistematik şekilde kayıt altına tutulup, kişilere bağlı bilgi bağımlılığının engellenmesi ve önüne geçilmesi, tek

kaynaktan güncel bilgiye erişim gibi çeşitli faydalarının yanında operasyon ve planlama süreçlerine de çeşitli olanaklar sağlamaktadır [5].

Bu kapsamda Coğrafi Bilgi Sistemleri ile harita üzerinde belirtilecek şebeke varlıkları belirlenerek veri mimarisi yapısı oluşturulur. Şebeke varlıklarını kaydetme süreci ise birçok alt süreçten etkilenir. Bu süreçler dahilinde, şebekeye dahil olan varlıkların bilgilerinin periyodik olarak güncellenip veri setinin de güncel tutulması gereklidir. Verilerin güncel tutulması çalışmalarını yine şirketlerin kendi personelleri (Coğrafi Bilgi Sistemleri Uzmanları vs.) üstlenmektedirler. Bu personeller güncel veriler içeren bir veri tabanı oluşturup güncelliğini korumak için farklı kaynaklardan veriler kullanılmaktadırlar. Bu kaynakların başında yine personeller tarafından alınan günlük, haftalık, aylık ve yıllık olarak sistemlere işlenen veriler gelmektedir [11].

Sistemlere işlenen bu verilerin doğruluğu ise yaşanan, değişen ve her geçen gün gelişen dağıtım şebekelerinin veri tabanlarının doğruluğunu belirlemektedir. Bir elektrik dağıtım şebekesi coğrafi bilgi sistemlerine ne kadar doğru işlenmişse ve arazi üzerindeki şebeke envanterlerini ne kadar doğru yansıtıyorsa o dağıtım şebekesini yönetmek de o derece kolay olmakta, mekânsal verileri depolamak, analiz etmek ve görüntülemek için geliştirilen coğrafi bilgi sistemlerinin kalitesi artmaktadır [12].

Çoğunlukla manuel olarak cihazlara işlenen bu şebeke envanterleri yanlış işlenip sistemlere yanlış aktarıldığı takdirde silsile halinde son kullanıcıya kadar bu yanlışlık sirayet edebilmekte ve pek çok sorunu da beraberinde getirebilmektedir. Bu tezde şebeke envanter unsurlarından, elektriğin iletimi ve dağıtımını için iletken ve hatları taşıyan, birbirine bağlayarak enerji akışının son kullanıcıya kadar ulaşmasını sağlayan elektrik dağıtım şebeke unsurlarının en önemlilerinden biri olan direk unsurlarının Coğrafi Bilgi Sistemleri'ne işlenirken sahadaki personeller tarafından kullanılacak olan konumsal tabanlı tabletlerden çekilecek fotoğraflarla mevcuttaki direği tanıyıp belirtebilmesi adına derin öğrenme yöntemine başvurulmuştur.

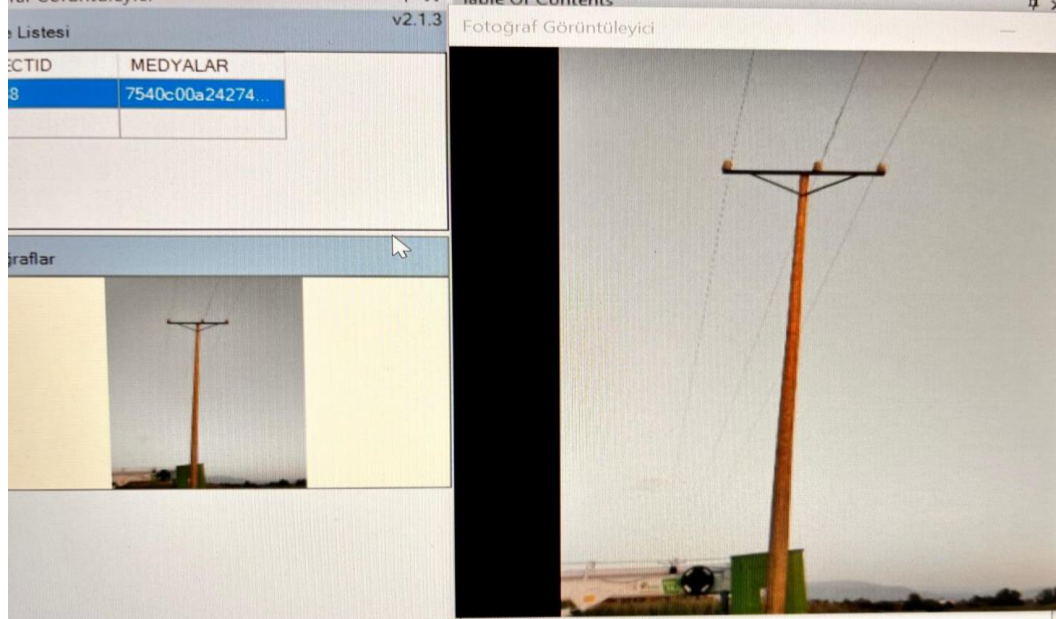
Saha görüntülerinden elektrik direklerinin tespit edilmesi doğal sahne tanıma sınıfına giren bir bilgisayarlı görme problemidir [12]. Derin öğrenme yöntemi görüntü sınıflandırmada, nesne izlemede, poz tahmini ve görsel belirginlik algılamada çokça kullanılan bir modeldir [12].

Sahada mevcut olan bir direğin CBS veri tabanına işlenmiş olmaması durumunda EPDK, TEİAŞ gibi kurumlar tarafında yapılan denetimlerde elektrik dağıtım şirketleri ihtar alabilmektedirler ve bu kurumlara yapılan raporlamalar yanlış olabilmektedir. Bir başka zorluksa enerji müsaadeleri verilirken yaşanmaktadır.

Kullanıcılar elektrik dağıtım şirketlerine enerji kullanımı müsaadesi için başvurduklarında enerji müsaadeleri genellikle evlere en yakın direktan iletken çekilecek şekilde verilmektedir. Bu noktada sistemde kullanıcıya enerji aktarımı sağlaması için sahada mevcut olan direğin CBS’de işlenmiş olmaması durumunda vatandaşların enerji müsaadeleri gerekli düzeltmeler ve güncellemeler sağlanıp, sahada mevcut olan direk CBS’de görülmeyene dek verilememekte, bu durum ise ikinci bir iş yüküne ve zaman kayıplarına sebebiyet vermektedir. Ayrıca yeni abonelik almak isteyen vatandaşları zor bir duruma sokmaktadır.

Verilen örnekten yola çıkılarak, sahadaki ve sistemdeki şebeke unsurlarının birebir örtüşebilmesi için saha personellerinden bahsi geçen direğin konumsal tabanlı tabletlerin içerisinde yüklü bulunan CBS uygulamasıyla sisteme işlenmesi ve bu direkleri ait görüntülerin de yüklenmesi istenmektedir. Direğin doğruluğu ve istenilen konumda var olduğu, sahaya çıkmayan ve tabletlerdeki bilgileri CBS veri tabanlarına işleyen ofis personelleri tarafından, tabletlerden çekilecek bu direk görüntüleri kontrol edilerek tespit edilmektedir.

Şekil 1.1. CBS Uygulaması Fotoğraf Görüntüleyici (GIS App Photo Viewer)



Şekil 1.1' deki gibi bir fotoğraf görüntüleyiciye yüklenecek yazılımlarla bu nesneyi direk nesnesi olarak tanıyıp sistemlere aktarırken kontrol sağlanabilecek olması manuel veya çevresel faktörlerden oluşabilecek yanlışların önüne geçebilecek olması neticesinde, gerek denetlemelerde, gerek enerji müsaadelerinde, gerekse sistemin güncel ve doğru tutulması aşamalarında çalışan personellere kolaylık sağlanmış olacaktır. İlgili kurum ise kaliteli ve daha etkin bir coğrafi bilgi sistemleri veri tabanına sahip olacaktır.

Aynı zamanda sistemin doğruluğu yapılacak ağ analizleri, açma-kesme kontrolü, şebeke bağlantı modeli oluşturma, kayıp kaçak tespitleri gibi elektrik dağıtım şirketlerini ilgilendiren pek çok konuda fayda sağlanmış olacaktır.

Bu makalenin ilerleyen bölümlerinde sırasıyla literatür taraması, CNN (Evrişimli Sinir Ağı) tabanlı DL (Deep Learning) yöntemiyle ilgili bilgiler, üç farklı CNN modeli ile kurulmuş DL yöntemleri anlatılmış, deneysel değerlendirmeler aktarılmış, sonuçlar ortaya konmuş ve gelecekte bu yöntemlerle ilgili yapılması planlanan çalışmalar anlatılmıştır.

BİRİNCİ BÖLÜM

LİTERATÜR TARAMASI

Yapılan literatür değerlendirmesinde elektrik direklerinin tespit edilmesi ve tespit edilmesinde derin öğrenme ve görüntü sınıflandırması yöntemlerine dayalı bir çalışmaya rastlanmamış olup, elektrik direklerinin DL yöntemlerinden YOLO, ResNet ve MobileNet mimarileri yardımıyla belirlenecek olmasının literatüre yeni ve özgün bir çalışma katacağı düşünülmektedir. Bununla birlikte derin öğrenme yöntemlerinin doğal görüntülerden nesnelerin tespit etmesi konusundaki başarısı da azımsanamayacak kadar çoktur ve yüksek performans göstermesi nedeniyle pek çok farklı alanda derin öğrenme yöntemi etkin bir şekilde kullanılmaktadır. Özellikle derin öğrenme yöntemlerinden birisi olan CNN yöntemi son yıllarda görüntü algılamada yaygın olarak kullanılan yöntemlerden biridir [12].

Aşağıda DL yöntemiyle görüntü ve nesne tespiti ile ilgili literatürde bulunan bazı çalışmalar sunulmuştur.

Nina [13] çalışmasında, derin öğrenme tekniklerini görüntü analizinde kullanmış ve derin öğrenme kullanarak görüntüleri analiz etmenin nesne tespitinde en hızlı ve doğru yollarından biri olduğu kanaatine varmıştır.

Algur vd. [14] çalışmalarında dış ortam görüntülerindeki insanların tespit edilmesi ve tespit edilen görüntülerinden insan hareketlerinin sınıflandırılması için hibrit bir derin öğrenme yöntemine başvurmuş ve nesnelerin tespitinde YOLO aracını kullanmışlardır.

Toroman [15] çalışmasında, insansız hava araçlarından çekilen doğal görüntüleri kullanarak yayaların ve görüntüdeki diğer öğelerin tespit edilip sınıflandırılması için derin öğrenme yöntemleri kullanmış ve farklı türdeki nesneleri ayırt edebilmesi yeteneklerinden dolayı derin öğrenme yöntemini önermiştir.

Barışçı ve Sarıkaya [16] çalışmalarında video ve kamera görüntülerinden oluşan veri setindeki nesneleri tespit etmek ve sınıflandırmak için derin öğrenme yöntemlerinden

YOLO ve ResNet mimarilerini bu görüntüler üzerinde uygulamışlardır. Bu yöntemlerin gerçek zamanlı çoklu nesne tanıma işlemleri üzerindeki performanslarını kıyaslamış ve YOLO mimarisini önermişlerdir.

Resul vd. [17] çalışmasında, hareketli nesne tanıma ve nesne takibi için derin öğrenme yöntemlerini kullanmışlardır. Söz konusu çalışmada durağan görüntüler, video kayıtları ve webcam görüntüleri üzerinde nesne tanıma işlemleri gerçekleştirmişlerdir. Derin öğrenme algoritmalarının görüntü işleme alanında kullanılmasıyla birlikte nesne tespitinde yüksek başarı oranlarının elde edildiği ve karmaşık görüntü işleme sorunlarının etkin bir şekilde çözülebildiği sonucuna varmışlardır.

Bayram [18]'deki çalışmasında kamera görüntülerinden otomatik olarak araç plakalarını tanıyabilen bir sistem geliştirmiş, geliştirilen sistem bilgisayarla görü alanındaki ileri derin öğrenme yöntemleri kullanılarak eğitilmiş ve sonuç olarak derin öğrenmeyle plaka görüntülerinin tespitinde %98 doğruluğa ulaşılmıştır.

Yavuz [19] araç kameralarının çektiği trafik işaret ve levhalarından oluşan görüntüleri görüntü işleme ve derin öğrenmeye dayalı modellerle eğitmiştir. Bu modelleri trafik işaret ve levha nesnelere otomatik olarak algılanıp tanınmasında kullanmış, yapılan çalışmalarla oldukça başarılı sonuçlar elde etmiştir.

Sarıoğlu ve Güngör [20] yüksek mekânsal çözünürlüğe sahip uydu görüntülerinden derin öğrenme yöntemi ile otomatik bina tespitinin yapılmasını amaçlamışlardır. Etiketlenmiş bina görüntülerinden oluşan test ve eğitim veri setlerini derin öğrenme yöntemleriyle eğitmiş ve %88 değerinde bir doğrulukla bina tespitinin yapılabildiğini görmüşlerdir.

Saygılı ve Özmen [21] insansız hava araçlarında gömülü olan bir sistem üzerinden çekilen görüntülerden nesne tespiti yapmışlardır. Hava koşulları ve çözünürlük gibi faktörlerden dolayı anlık nesne tespiti yapmanın zorluklarını giderebilmek adına derin öğrenme yöntemlerinden MobileNet nesne mimarisini kullanmışlar ve %95 oranında kesinlik elde etmişlerdir.

İKİNCİ BÖLÜM

EVİRİŞİMLİ SİNİR AĞI TABANLI DERİN ÖĞRENME YÖNTEMLERİ İLE ELEKTRİK DİREKLERİNİN TESPİT EDİLMESİ

2.1. Derin Öğrenme

Makine öğrenimi, bilgisayarların açık bir şekilde programlanmadan deneyimlerinden yararlanarak öğrenmelerini ve gelişmelerini sağlayan bir yapay zekâ alt alanıdır. Geleneksel programlamada, bir programcı belirli bir işlevi yerine getirmek için kod yazar. Ancak makine öğreniminde sistem, verileri analiz ederek ve istatistiksel algoritmalar kullanarak zamanla performansını artırır.

Makine öğrenimi algoritmaları, verilerdeki desenleri ve ilişkileri tanımlayabilir, tahminlerde bulunabilir ve bu verilere dayanarak karar verme yeteneği kazanır. Bu yöntem, önceden belirlenmiş kurallara ve algoritmalara dayanan geleneksel bilgisayar programlamasından farklıdır; zira geleneksel yaklaşımlar yeni verilere veya değişen koşullara adapte olamaz. Basit görevler için bilgisayarlara sorunu çözmek için gerekli tüm adımları belirten algoritmalar yazmak mümkündür; bu durumda bilgisayarın öğrenmesine ihtiyaç yoktur. Ancak daha karmaşık görevlerde, bir insanın gerekli algoritmaları oluşturması zor olabilir. İşte bu noktada makine öğrenimi devreye girerek, açıkça programlanmadan da görevleri yerine getirebilir [22]. Makine öğrenimi modellerini temelde Denetimsiz Öğrenme, Denetimli Öğrenme, Yarı Denetimli Öğrenme ve Pekiştirmeli Öğrenme olarak dörde ayırmak mümkündür.

Denetimsiz öğrenme, veri kümesindeki bilinmeyen örüntüleri bulmak için oldukça faydalıdır. Özellikle, kategorizasyon için gereken özelliklerin keşfedilmesine yardımcı olur ve verilerin etiketlenmiş olmasına gerek kalmaz. Bu yönüyle, veri bilimi alanında yeni başlayanlar için de önemlidir, çünkü ham verilerin analizi süreçlerini gösterir.

Denetimsiz öğrenmenin iki ana bölümü vardır: kümeleme ve ilişkilendirme. Kümeleme, kategorize edilmemiş verilerde örüntü bulmayı amaçlar. Bu algoritmalar, verileri işleyerek doğal kümeleri tanımlar ve kullanıcılar kaç küme oluşturulacağına dair ayarlamalar yapabilir [22].

Kümeleme yöntemlerinden biri olan hiyerarşik kümeleme, önceden küme sayısını belirlemeye gerek kalmadan benzer özneliklerin bir araya gelmesine veya ayrılmasına dayanan yaygın bir kümeleme yöntemidir.

Hiyerarşik kümeleme analizinde, veriler arasındaki benzerlik ve uzaklık hesaplamaları sürekli güncellenir. Hesaplanan uzaklık/benzerlik değerlerinden oluşan matris, seçilen bağlantı yönteminin uygulanmasında temel bir rol oynamaktadır. Hiyerarşik kümelemeyle ilgili bir şöyle bir örnek verilebilir:

Otobüs durak montajı sırasında, şehir içi otobüs durak ihtiyacını karşılamak amacıyla yeni bir durak eklendiğinde, verilen numaralar genellikle rastgele belirlenmektedir. Bu durum, mekânsal olarak yakın olan duraklar arasında büyük numara farkları oluşmasına yol açmakta ve vatandaşların durak numaralarını öğrenmesini zorlaştırmaktadır. Böyle bir problemin önüne geçmek ve birbirine yakın duraklara yakın numaralar verilmesini sağlamak adına hiyerarşik kümeleme yöntemi önerilmekte ve klasik numaralandırma yöntemlerine göre hiyerarşik kümeleme yönteminin oldukça bariz şekilde mesafeye uyarlı olduğu ve bu yöntemle yapılan durak numaralandırmalarının daha düzenli olduğu görülmektedir [23].

Denetimsiz ve denetimli öğrenme arasındaki temel fark, algoritmaların eğitim şeklidir. Denetimli öğrenme, verileri keşfetme konusunda daha basit bir yaklaşım sergilerken, denetimsiz öğrenme algoritmaları etiketlenmemiş verilerle çalışır. Bu nedenle, denetimsiz öğrenme çıktıları bilinmediğinden eğitim süreci daha karmaşık hale gelir; çok sayıda sınıflandırılmamış veri ile yeni örüntüler tanımlanması gerekir.

Denetimli öğrenme geçmiş deneyimlerden (etiketli veriler) yararlanarak çıktı üretmeye dayanır. Denetimli bir öğrenme algoritması, eğitim verilerini analiz ederek yeni örneklerle eşleşmek için kullanılabilir bir çıkarım işlevi oluşturur [22]. Denetimli öğrenme yöntemlerini ise Lojistik Regresyon, Doğrusal Regresyon Destek Vektör Makinesi, Sınır Ağları, Karar Ağaçları olarak sıralamak mümkündür. Derin öğrenme ise

çok katmanlı sinir ağıları geliştirmeyi içeren ve en sık kullanılan denetimli öğrenme modellerinden biridir.

Derin öğrenme, makine öğrenmesinin bir alt dalı olarak, nesnelere özelliklerini çıkarmak ve dönüştürmek için birçok doğrusal olmayan işlem birimi katmanı kullanmaktadır. Bu yöntem, çoklu özelliklere sahip verilerin seviyelerini veya temsil biçimlerini öğrenmeye dayanan bir prensip üzerine kurulmuştur [24].

Derin öğrenme, özellikleri önceden tanımlanmış denklemlerle işlem yapmak yerine, verilerin temel parametreleri üzerinde çalışır. Birçok işlem katmanı ile bu verileri işleyerek tanımlar ve bilgisayarın kendi kendine öğrenmesini mümkün kılar. Derin öğrenmeyi standart yapay sinir ağlarından ayıran en önemli unsur, katmanların kendi içlerinde özellik haritaları çıkarabilme yeteneğidir [25].

Klasik makine öğrenme teknikleriyle bir model tanımlamak veya makine öğrenimi sistemi kurmak için başlangıçta bir özellik vektörü çıkarmak gerekmektedir. Bahsi geçen bu işlemler zaman almakta, ham verileri işlemek ve bu verilere uygun özellikleri çıkarmak içinse bir uzman müdahalesine ihtiyaç duyulmaktadır. Derin öğrenmeyle birlikte bu tür zorlukları aşmak için önemli bir ilerleme sağlanmıştır. Geleneksel yöntemlerden farklı olarak, derin ağlar ham veriyi kullanarak öğrenme yapabilmekte ve farklı katmanlarda temsiller oluşturarak gerekli bilgileri elde edebilmektedirler. Derin öğrenme, özellikle 2012 yılında ImageNet gibi büyük ölçekli görsel tanıma yarışmalarında elde ettiği başarı ile dikkat çekmiştir. Bu başarıda, derin öğrenmenin eğitim için yeterli miktarda veriye sahip olması ve bu veriyi işleyecek donanım altyapısının bulunması önemli bir etkiye sahiptir. Derin öğrenme teknikleri, geçmişteki temellerinden günümüzdeki popüleritesine kadar uzanan bir gelişim sürecinden geçmiştir ve makine öğrenimi alanında önemli bir rol oynamaktadır [26].

2.1.1. Derin Öğrenmenin Uygulama Alanları

Derin öğrenme mimarileri ile birlikte yapay zekâ problemlerinin çözümü için pek çok derin öğrenme yaklaşımı geliştirilmiştir. Geliştirilen bu yaklaşımlarla, endüstri, tıp, robotik, görüntü işleme, bilgisayar görmesi, nesne tespiti, ses işleme-tanıma, çeviri, gelecek tahmini, finans gibi oldukça çeşitli alanda pek çok akıllı ve kalıcı çözümler üretilebilmektedir [27].

Derin öğrenme tekniklerinin birçok uygulama alanında etkileyici çözümler sunduğu da bilinmekte olup bu alanlar şu şekilde sıralanabilir:

- Ünlü kişilerin sesleri, farklı görüntülerle kullanılarak sentezlenebilmektedir.
- Resim ve videolardaki renk restorasyonu yapılabilmektedir.
- Düşük çözünürlüklü resimlerden daha anlaşılabilir görüntüler elde edilebilmektedir.
- Gerçek zamanlı çoklu insan hareketleri tahmin edilebilmektedir.
- Resimlerdeki nesnelere metin haline getirilebilmektedir
- Fotoğraflardaki insanların bakış yönü değiştirilebilmektedir.
- Videolardaki görüntülerin davranışları gerçek zamanlı olarak analiz edilebilmektedir.
- Fotoğrafların tekrarlanması ile yeni nesnelere oluşturulabilmektedir
- Galaksilerin fotoğrafları oluşturulabilmektedir.
- Resimlerdeki yazılar bir dilden başka bir dile çevrilebilmektedir.
- Nesli tükenen hayvanlar tespit edilebilmekte, böylelikle bu hayvanların korunması sağlanabilmektedir.
- Var olan görüntülerden yeni modeller elde edilebilmektedir.
- Fotoğraflardaki ve/veya videolardaki metinler okunabilmektedir.
- Güneş enerjisi potansiyeli tahmin edilebilmektedir.
- İleriye yönelik deprem ve seçim tahminleri gibi tahminlerde bulunabilmektedir [28].

Verilen bu örnekler, derin öğrenmenin ne kadar geniş bir uygulama alanına sahip olduğunu ve yeni bir yöntem olmasına rağmen ne sıklıkta kullanıldığını göstermektedir.

2.1.2. Derin Öğrenmenin Çalışma Prensipleri

Derin öğrenmenin çalışma prensibi genel itibarıyla şöyledir:

Elimizdeki veri kümesini eğitim seti ve test seti olmak üzere ikiye ayırıp derin öğrenme modellerini verinin bir kısmıyla eğitip, eğitilmeyen ve modellerin hiç görmediği test verisi üzerinde derin öğrenmenin doğru tahminler yapmasını bekleriz.

Derin öğrenme modellemesi yapmak için belirli adımlar ve faktörler önem taşımaktadır. Bu adımlar ve faktörler şu şekilde sıralanabilmektedir:

- Problemin Tanımı ve Uygunluk Tespiti: Öncelikle çözülmek istenen problem tanımlanmalı ve derin öğrenmenin bu probleme uygun olup olmadığı değerlendirilmelidir.
- Veri Kümesi Seçimi ve Hazırlığı: Çalışma yapılmak istenen ilgili veri kümeleri belirlenmeli ve analiz için uygun hale getirilmelidir. Veri ön işleme adımları bu aşamada uygulanmaktadır.
- Algoritma Seçimi: Çalışma için kullanılacak derin öğrenme algoritması veya algoritmaları belirlenmelidir. Seçilecek algoritmalar problem tipine ve veri setinin özelliklerine bağlı olarak seçilmekte ve değişkenlik gösterebilmektedir.
- Model Oluşturma ve Eğitim: Belirlenen veri kümeleri kullanılarak seçilen algoritma ile analitik model oluşturulur bu model eğitilir ve gerektiğinde revize edilebilir.
- Ağ Yapısı ve Gizli Katmanların Tespit edilmesi: Oluşturulan modelin yapılandırılması için gerekli ağ yapısı belirlenir. Bu aşamada gizli katmanların sayısı ve her katmandaki düğümlerin (nöronların) sayısı önem arz etmektedir.
- Aktivasyon Fonksiyonu Seçimi: Her gizli katman için kullanılacak aktivasyon fonksiyonunun türü seçilmelidir. Bu işlem, modelin öğrenme yeteneği ve performansı üzerinde oldukça önemli bir etkiye sahiptir.
- Eğitim ve Test: Oluşturulan model eğitim verileri üzerinde eğitilir ve test verileri üzerinde doğruluğu değerlendirilir. Modelin performansı test skorlarıyla ölçülür ve gerektiğinde iyileştirmeler yapılabilir [29].

Derin öğrenme modellerinin yapısı genellikle girdi katmanı, gizli katman(lar) ve çıktı katmanından oluşur. Her bir katman için sayısal değerler verilir ve bu değerler, modelin kompleksliği ve performansı üzerinde belirleyici olabilir. Gizli katmandaki düğümler (nöronlar), modelin eğitim süreci, ağ yapısı ve kullanılan aktivasyon fonksiyonları gibi faktörlerden etkilenir.

Gizli katmanlardaki düğüm sayısını belirlemek için genellikle farklı ağ yapılarını eğiterek ve test verisindeki performans hatalarını değerlendirerek bir karar verilir. Bu süreç,

optimal model yapılandırmasını bulmak için önemli bir adımdır ve genellikle deneme-yanılma yöntemleriyle gerçekleştirilir.

2.2. Elektrik Direklerinin Derin Öğrenme Yöntemleriyle Tespit edilmesi

Bu çalışmada elektrik şebekesi unsurlarından biri olan direk nesnelere tespit edilmesi ve coğrafi bilgi sistemlerine doğru bir şekilde aktarılıp sahaya sistemin uyumlu hale getirilebilmesi adına CNN tabanlı derin öğrenme (DL) yöntemlerinden YOLO, ResNet ve MobileNet yöntemleri kullanılmıştır.

Bu bölümde YOLO, ResNet ve MobileNet yöntemlerinin ne olduğu açıklanmış, çalışma prensiplerinden bahsedilmiş, sonrasında bu derin öğrenme yöntemleriyle direk cinslerinin tespit edilmesi süreçleri anlatılmıştır.

2.2.1. YOLO Yöntemi

You Only Look Once yani YOLO yaklaşımı sadece bir kez bakarsın anlamına gelmektedir [12] [30]. YOLO yaklaşımı adından da anlaşılacağı üzere görüntüdeki nesnenin ne olduğunu ve nerede olduğunu görüntüyü sadece bir kez görmeyle tahmin edebilmektedir [12] [31].

YOLO yöntemi, bir görüntüdeki birden fazla nesnenin tespitini mümkün kılmakta ve nesnelere ayırt ederken CNN yöntemi kullanmaktadır. YOLO, görüntüyü küçük parçalara böler, bu parçaları CNN ile analiz eder ve nesne olarak tanımlanabilecek herhangi bir özellik tespit ettiğinde o parçayı işaretler. Bu işaretlenen alanlar nesnenin yer aldığı bölgeleri ifade eder [32].

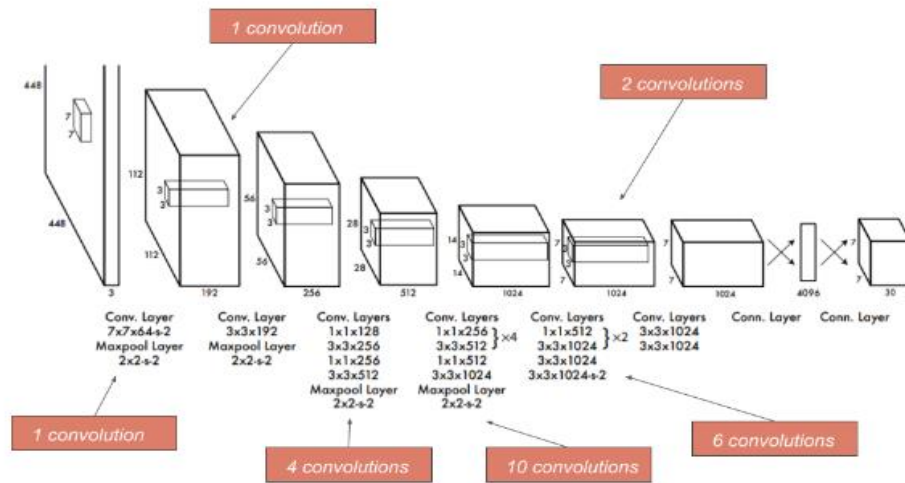
Bir görüntüden bir nesnenin ne olduğu ve nerede olduğunun tahmin veya tespit edilebilmesi bir bilgisayarlı görme problemi olarak ifade edilebilir. Bu problemde nesnenin nerede olduğu da tahmin edilmeye çalışıldığından bilgisayarlı görme problemleri herhangi bir sınıflandırma problemine göre çok daha karmaşık yapılara sahiptirler. Özellikle görüntüde birden fazla nesnenin tespiti varsa sınıflandırma problemleri işe yaramamaktadırlar [12].

Derin Öğrenme alanında kullanılan birçok algoritma vardır. Bu algoritmalarından YOLO (You Only Look Once) algoritması yüksek işleme hızından dolayı yüksek FPS (Frame Per Second) sağlamak ve daha net sonuçlar vermektedir [33]. Bu sebeple bu çalışmada tercih edilen nesne takip algoritmalarından biri YOLOv8 mimarisidir.

Diğer nesne takip algoritmaları görüntüyü bir bütün olarak ele alıp tespit yaparken YOLO mimarisi görüntüyü bölgelere ayırıp bu bölgelerdeki her bir nesne için adına **Bounding Box** denen 3×3 , 5×5 ... boyutunda ızgaralar çizerek çalışır ve bu ızgaralardan yola çıkarak aranan nesnenin belirlenen bu alanda olup olmadığına tek seferde bakar [34]. Her bir ızgara alanı güven derecesine dayanan merkezlenmiş bir hedef sınırlama kutusunu tahmin etmekle yükümlüdür. Ayrıca, her ızgara hücresi olasılık sınırlarını tahmin etmektedir [32].

Aşağıdaki şekilde YOLO mimarisinin çalışma prensibini anlatan şekil mevcuttur.

Şekil 2.1. YOLO CNN Mimarisi (YOLO CNN Architecture)



Bu çalışmada kullanılan YOLOv8 sürümü ise önceki sürümlerine kıyasla daha ileri düzey işlem teknikleriyle donatılmıştır. Bu teknikler, sinir ağları tarafından üretilen tahmini sınırlayıcı kutular ve nesne skorları üzerinde uygulanarak algılama sonuçlarını daha da rafine etmekte, gereksiz algılamaları ortadan kaldırmakta ve tahminlerin genel doğruluğunu artırmaktadır. Böylece, daha güvenilir ve etkili nesne tanıma performansları elde edilmektedir.

YOLOv8'in geliştirilmiş son işlem yöntemleri, özellikle karmaşık görüntü senaryolarında ve çeşitli nesne türlerinin bulunduğu durumlarda, daha yüksek başarı oranları sağlamaktadır. Bu yenilikler, kullanıcıların daha doğru ve etkili sonuçlar elde etmesine olanak tanıırken, nesne algılamanın genel verimliliğini de artırmaktadır [32].

Bu çalışmada elektrik şebekesi unsurlarından direk nesnesinin tespit edilmesi için, YOLOv8 mimarisinin sınırlandırılmış ızgaralar içinde yer alan her bir direği eğitim veri

setinde tanıtılmış olan direk nesnelere yardımcıyla belirtmesi ve bir güven aralığı oluşturması istenmiştir.

YOLO yönteminin nasıl çalıştığına ilişkin Şekil 2'deki resim incelenecek olursa, 24 adet evrişim katmanından oluşan YOLO yöntemine veri olarak bir girdi görüntüsü aktarılmıştır. Şekil.3'te görülen ve girdi verisi olan resimlerden bir tanesi 1 adet elektrik direğinden oluşmaktadır. YOLO mimarisi görüntüyü kutucuklara bölerek belirtilen alanda nesne olup olmadığına tek seferde bakarak buradaki direk nesnesini eğitim veri setlerini baz alarak tanımlamış ve görüntüdeki direk nesnesini oransal olarak %76'lık doğrulukla kırmızı çerçeve içine almış ve belirtmiştir.

Şekil 2.2. Giriş Görüntüsü (Input Image)



Coğrafi Bilgi Sistemleriyle entegre çalışan ve doğrudan coğrafi bilgi sistemine aktarım yapabilen el tabletlerinden çekilecek görüntülere uygulanan bu yöntemle direkler, fotoğraftaki diğer nesnelere ayırt edilebilecek şekilde tespit edilecek, tablet kullanıcısının elle manuel olarak yanlış yapması en aza indirgenmiş ve ofis personelleri için sahadaki direğin kontrolü kolaylıkla sağlanmış olacaktır. Böylelikle daha güncel ve kullanışlı bir veri tabanı oluşturulabilecektir.

Bu çalışmada ilk kullanılan DL yöntemlerinden YOLOv8 mimarisi birçok direk görüntüsünü tahmin etmede başarılı olmuştur. Ancak içeriğinde birden fazla direk bulunan görüntülerde ve ayrıca insan, araç, bina, ağaç gibi farklı nesnelere de bulunduğu görüntülerde Şekil.4'ten de anlaşılacağı gibi YOLOv8 yönteminin yeterince başarılı olmadığı durumlar da söz konusu olmuştur.

Şekil 2.3. *Tahminleme Yapılmayan Görüntü (Image Without Prediction)*



Bu çalışmada eğitilmiş CNN tabanlı DL yöntemlerinden YOLOv8 mimarisinde eğitim veri seti olarak sahadan toplanan 380 adet direk görüntüsü kullanılmış olup her bir görüntü ayrı ayrı işleme sokulmuştur.

YOLOv8 yöntemiyle elektrik direklerinin tespit edilmesi için yapılan çalışmalar sonucu elde edilen F1 Güven Skoru şöyledir:

Tablo 2.1. *YOLO Yöntemi F1 Güven Skoru (YOLO Method F1 Confidence Score)*

TP	TN	FP	FN	ACCURRACY	PRECİSİON	RECALL	F1 SKOR
296	49	30	179	0,623	0,908	0,623	0,739

Tablo 2.1.'deki sonuçlar incelendiğinde 296 adet görüntüde doğru nesne tespiti yapıldığı, 49 adet görüntüde nesnenin olmadığı ve tespit yapılmadığı, 30 adet görüntüde elektrik direğinden daha farklı bir nesnenin tespit edildiği, 179 adet görüntüde de nesne varken tespit yapılmadığı anlaşılmaktadır. Sonuç olarak %62 doğruluk, %90 kesinlik, %62 duyarlılık ve %74 güven skoru sonuçlarına erişilmiştir.

2.2.2. ResNet Yöntemi

ResNet, "Artık (Residual)" ağıın kısaltmasıdır ve derin evrişimli sinir ağlar arasında önemli bir yer tutmaktadır. Görüntü tanıma ve sınıflandırma alanında uzun süredir kullanılan yöntemler, daha derin ağların eğitilmesi sırasında kaybolan gradyan ve aşırı öğrenme gibi problemlerle karşılaşmaktadır. Bu tür zorluklar, ağların performansını olumsuz yönde etkileyebilir ve eğitim sürecini karmaşık hale getirebilir.

ResNet, bu sorunlara odaklanarak, derin ağları daha etkili bir şekilde eğitmeyi hedeflemektedir. Model, her katmanda belirli görevler için hem düşük hem de yüksek seviyeli özellikleri öğrenirken, "artık" olarak adlandırılan özel blokları kullanır. Bu bloklar, ağıın daha derin katmanlarında bile bilgi kaybını en aza indirmek için tasarlanmıştır. Böylece, öğrenilen özelliklerin aktarımı sağlanarak, derinlik arttıkça modelin performansı düşmez.

ResNet'in yapısal yenilikleri, derinliklerin artmasına rağmen, eğitim sürecini kolaylaştırmakta ve sonuçta elde edilen modelin doğruluğunu artırmaktadır. Bu yöntem, derin öğrenme topluluğunda büyük bir etki yaratmış ve birçok görüntü işleme görevinde standart haline gelmiştir [35].

ResNet algoritması, ilk olarak 2016 yılında Kaiming He, Xiangyu Zhang ve ekip arkadaşları tarafından daha derin ağların eğitimini kolaylaştırmak amacıyla tasarlanmış bir mimaridir. Bu yenilikçi yapı, 152 katmandan oluşmakta ve derin öğrenme alanında önemli bir kilometre taşı olarak kabul edilmektedir.

ResNet'in temel amacı, derin ağların eğitimi sırasında karşılaşılan kaybolan gradyan ve aşırı öğrenme gibi sorunları aşmaktır. Ağın derinliğinin artmasıyla birlikte, modelin öğrenme kapasitesi de artarken, eğitim sürecinin zorluğu da önemli ölçüde yükselmektedir. ResNet, bu zorlukları minimize etmek için "artık bağlantılar" (skip connections) kullanarak, katmanlar arasında bilgi akışını destekler.

Bu yöntem sayesinde, her bir katman, hem düşük seviyeli hem de yüksek seviyeli özellikleri öğrenirken, bilgiyi kaybetmeden daha derin katmanlara aktarabilmektedir. Sonuç olarak, ResNet mimarisi, daha derin ağların etkili bir şekilde eğitilmesini sağlayarak, görüntü tanıma ve sınıflandırma gibi alanlarda yüksek başarı oranları elde edilmesine katkıda bulunmuştur.


ResNet'in etkisi, sadece akademik çalışmalarda değil, aynı zamanda endüstriyel uygulamalarda da görülmektedir. Birçok modern görüntü işleme projesinde, ResNet tabanlı modeller, yüksek doğruluk ve performans sunarak tercih edilmektedir [36].

Derin evrişimli sinir ağları, nesne tanıma problemlerinde daha kesin ve güvenilir sonuçlar üretilmesine olanak tanımış, böylece görsel verilerin işlenmesi ve analizi alanında devrim niteliğinde gelişmeler sağlanmıştır. Örneğin, ImageNet yarışmasında elde edilen başarılar, derin öğrenmenin gücünü ve potansiyelini gözler önüne sermektedir. Bu durum, araştırmacıları ve mühendisleri daha derin ve etkili ağ mimarileri geliştirmeye yönlendirmiştir.

Ayrıca, derin öğrenme teknikleri, otonom araçlardan sağlık alanına kadar pek çok sektörde uygulanmakta ve bu alanlarda yenilikçi çözümler sunmaktadır. Özetle, derin evrişimli sinir ağları, günümüzün görüntü işleme problemlerinin çözümünde kritik bir rol oynamaktadır ve bu teknolojilerin gelişimi, gelecekte daha da ileri sonuçlar elde edilmesini mümkün kılacaktır [37].

Aşağıdaki görselde ResNet mimarisin çalışma prensibi yer almaktadır.

Şekil 2.4. ResNet Mimarisi (ResNet Architecture)




Şekil 2.4.'te görüldüğü üzere ResNet mimarisi residual bloklardan oluşur ve her bir katman çıktısı bir sonraki çıktı ile birleştirilerek yeniden filtreleme işlemi yapılır. ResNet mimarisi bu çalışmada elektrik direk görüntülerinden oluşan veri kütüphanesini kullanarak direklerin tespit edilmesinde artık ağırları kullanıp her biri direk için yeniden filtreleme işlemi yaparak gerçeğe en yakın ve kesin sonuçlar üretmesi için kullanılmıştır.

ResNet mimarisinde eğitim veri seti olarak sahadan toplanan 377 adet direk görüntüsü kullanılmıştır. Artık ağırlar kullanılarak her bir görüntüde direk sınıfı için ResNet yöntemi görüntüler üzerinde direkleri belirlemiş ve kutucuk içine alarak oransal olarak tahminler yaparak sonuçlar üretmiştir.

Yapılan tahminler için güven skoru eşik değeri üzerindeyse görüntü sisteme aktarılacak, değilse kullanıcı tarafından elle manuel olarak işlenecektir.

ResNet yönteminin sonuçlarına bakıldığında Şekil.7'den de anlaşılacağı üzere 1 adet direk nesnesi için farklı yüzdelik oranlarda birden fazla tahmin yapabildiği görülmüştür.

Şekil 2.5. ResNet Girdi Görüntüsü (ResNet Input Image)



Bir diğerk görüntü incelendiğinde ResNet yönteminin birden fazla nesne içeren görüntülerde de nesne tespiti yaptığı ve başarılı olduğu görülmektedir.

Şekil 2.6. Birden Fazla Nesne Olan Görüntü (Image with Multiple Objects)



Etiketleme yapılan tüm direk görüntüleri incelenmiş ve ResNet yöntemiyle yapılan çalışmalar sonucu elde edilen F1 Güven Skoru aşağıdaki tabloda özetlenmiştir:

Tablo 2.2. ResNet Yöntemi F1 Güven Skoru (ResNet Method F1 Confidence Score)

TP	TN	FP	FN	ACCURRACY	PRECİSİON	RECALL	F1 SKOR
396	25	122	109	0,646	0,764	0,784	0,774

Sonuçlar incelendiğinde 396 adet görüntüde doğru nesne tespiti yapıldığı, 25 adet görüntüde nesnenin olmadığı ve tespit yapılmadığı, 122 adet görüntüde elektrik direğinden daha farklı bir nesnenin tespit edildiği, 109 adet görüntüde de nesne varken tespit yapılmadığı anlaşılmaktadır. Sonuç olarak %64 doğruluk, %76 kesinlik, %78 duyarlılık ve %77 güven skoru sonuçlarına erişilmiştir.

2.2.3. MobileNet Yöntemi

MobileNet, görüntü sınıflandırma alanında kullanılan konvolüsyonel sinir ağı modellerinden biridir ve derinlemesine ayrılabilir, verimli katmanlardan oluşan bir yapıya sahiptir. MobileNet, hafif ve derin sinir ağları oluşturmak için modern bir mimariye dayanmaktadır. Bu mimari, derinlemesine ayrılabilir evrişimleri (depthwise separable convolutions) kullanarak, hem düşük gecikme hem de yüksek doğruluk arasında etkin bir denge sağlamaktadır.

MobileNet'in önemli bir özelliği, model oluşturucuların uygulama ihtiyaçlarına göre doğru boyutta model seçmelerine olanak tanıyan iki temel küresel hiperparametre sunmasıdır. Bu hiperparametreler, modelin genişliği ve derinliği üzerinde kontrol sağlamaktadır. Böylece, MobileNet, belirli problem kısıtlamalarına göre optimize edilmiş bir performans sergileyerek, çeşitli cihaz ve uygulamalarda etkin bir şekilde kullanılabilir.

Özellikle mobil ve gömülü sistemlerde, MobileNet'in hafif yapısı, sınırlı kaynaklara sahip cihazlarda bile yüksek performans göstermesini sağlamaktadır.

Bu özellikleri sayesinde, MobileNet, nesne tanıma, görüntü sınıflandırma ve diğer görüntü işleme görevlerinde yaygın olarak tercih edilmesiyle, derin öğrenme alanında önemli bir araç haline gelmiş ve hem akademik hem de endüstriyel uygulamalarda güçlü sonuçlar elde edilmesine katkı sağlamıştır [35].

Derinlik açısından ayrılabilir katmanlar, geleneksel evrişim katmanlarının işlemlerini büyük ölçüde taklit etmekle birlikte, çok daha hızlı ve daha az hafıza gereksinimi ile bu işlemleri gerçekleştirmektedir. Geleneksel evrişimlerde filtre uygulama ve birleştirme işlemleri aynı katmanda yapılırken, derinlik açısından ayrılabilir evrişimde bu işlemler iki ayrı katmana ayrılmaktadır. Bu yaklaşım, modelin boyutunu en aza indirirken, hesaplama gücü gereksinimlerini de önemli ölçüde azaltmaktadır.

MobileNet mimarisi, derinlikli ve noktasal evrişimlerin yanı sıra toplamda 28 katmana sahiptir. Derinlemesine ayrılabilir evrişimleri kullanarak, parametre sayısını, işlem

hacmini ve model karmaşıklığını düşürmeyi başarmıştır. Böylece, donanımsal kısıtları olan mobil ve gömülü cihazlarda kullanılabilir hale gelmiştir. Sınıflandırma işlemi için softmax katmanını besleyen tam bağlantılı katman dışında, tüm katmanlar batch normalization ve ReLU doğrusal olmayan aktivasyon katmanları ile sonlandırılmaktadır.

Derinlik açısından ayrılabilir evrişimler, bilgisayarla görü uygulamalarında oldukça önemli bir yere sahiptir. Özellikle, görüntü sınıflandırma, nesne tanıma ve segmentasyon gibi alanlarda kullanılmaktadır. MobileNet'in sunduğu bu mimari, hem düşük güç tüketimi hem de hızlı işlem süreleri ile dikkat çekmektedir. Mobil cihazlar ve gömülü sistemler için optimize edilmiş olması, bu mimarinin yaygın olarak tercih edilmesinin nedenlerinden biridir [38].


MobileNet daha küçük modellerdeki karmaşıklığın daha az olduğu teorisine dayanarak daha az karmaşık ancak daha derinlemesine işlem yapar [39]. Bu model derinlik açısından ayrılabilir evrişimlere dayanmakta olup diğer birçok bilinen modelden daha küçük boyutta, performans açısından daha hızlı yapıda ve ayrıca daha basittir [40] [41].

MobileNet derinlik açısından ayrılabilir evrişimli sinir ağlarında her bir girdi kanalına tek bir filtre uygulayıp, ardından nokta bazlı evrişimde 1×1 boyutundaki evrişimleri kullanarak derinlik bazlı katmanların çıktısını doğrusal kombinasyon oluşturarak işlem yapar [40] [41].

Bu çalışmada sahadan çekilen görüntülerden elektrik direklerinin tespit edilmesi için MobileNet görüntüleri derinlik bazlı ayrıştırılmış, her bir görüntü için bir tek filtre uygulamış, ayrıştırılan katmanların doğrusal kombinasyonlarını oluşturarak direk nesnesi görüntülerde etiketleyerek belirtmiştir.

Aşağıdaki Şekil.8'de MobileNet mimarisi ve çalışma prensibi görülmektedir.

Şekil 2.7. MobileNet Mimarisi (MobileNet Architecture)



MobileNet Şekil.9’da gösterilen mimariyi kullanarak bu çalışma için oluşturulan ve sahadan çekilen 359 adet direk görüntüsünden oluşan veri setindeki her bir görüntüyü derinlik bazlı ayırıp tek bir filtre kullanarak fotoğraflardaki direk nesnelere tespit etmiştir.

Ancak görüntüler incelendiğinde Şekil.9’daki gibi derinliğin çok olduğu bazı görüntülerde MobileNet yönteminin herhangi bir tespit yapmadığı durumlar olduğu da görülmüştür.

Şekil 2.8. *Derinliğin çok olduğu görüntü (The image with a lot of depth)*



MobileNet yöntemiyle yapılan çalışmalar sonucu elde edilen F1 Güven Skoru tablosu aşağıdaki gibidir.

Tablo 2.3. *MobileNet Yöntemi F1 Güven Skoru (MobileNet Method F1 Confidence Score)*

TP	TN	FP	FN	ACCURACY	PRECİSİON	RECALL	F1 SKOR
282	30	39	209	0,557	0,879	0,574	0,695

Sonuçlar incelendiğinde 282 adet görüntüde doğru nesne tespiti yapıldığı, 30 adet görüntüde nesnenin olmadığı ve tespit yapılmadığı, 39 adet görüntüde elektrik direğinden daha farklı bir nesnenin tespit edildiği, 209 adet görüntüde de nesne varken tespit yapılmadığı anlaşılmaktadır. Sonuç olarak %56 doğruluk, %88 kesinlik, %57 duyarlılık ve %70 güven skoru sonuçlarına erişilmiştir.

ÜÇÜNCÜ BÖLÜM

DERİN ÖĞRENME TABANLI YAKLAŞIMLA ELEKTRİK DİREKLERİNİN TESPİT EDİLMESİ

Elektrik dağıtım kurumlarında sahadaki direk objeleri koordinatlı bir şekilde tabletlerden coğrafi bilgi sistemi veri tabanlarına işlenirken elle manuel olarak satır doldurma işleminin yapıldığı görülmüştür. Bu durumun ise kullanıcı kaynaklı hataları çok sık meydana getirdiği ve verilerin sistemlere yanlış işlenip yanlış depolanmasına sebebiyet verdiği görülmektedir. Bu çalışmada bahsedilen sorunların önüne geçebilmek için direklerin sahada mevcut olduğunu konumsal tabanlı tabletlerden çekilecek fotoğraflardan tanıyıp sisteme işlenmesi adına CNN tabanlı DL yöntemleri önerilmiştir. Aşağıdaki Şekil.12’de yapılan işlemlerin akış diyagramları gösterilmiştir. Şekil.12’deki akış diyagramından da anlaşılacağı üzere direk fotoğraflarını içeren veri seti direklerin tanımlanabilmesi adına CNN tabanlı DL yöntemleri kullanılarak eğitilmeli, girdi olarak kullanılan her bir görüntüdeki direk objesi için ayrı ayrı uygulanmalıdır. Eğitim işlemi tamamlandıktan sonra önerilen sistemler direk objelerini tespit etmek üzere kullanılabilir.

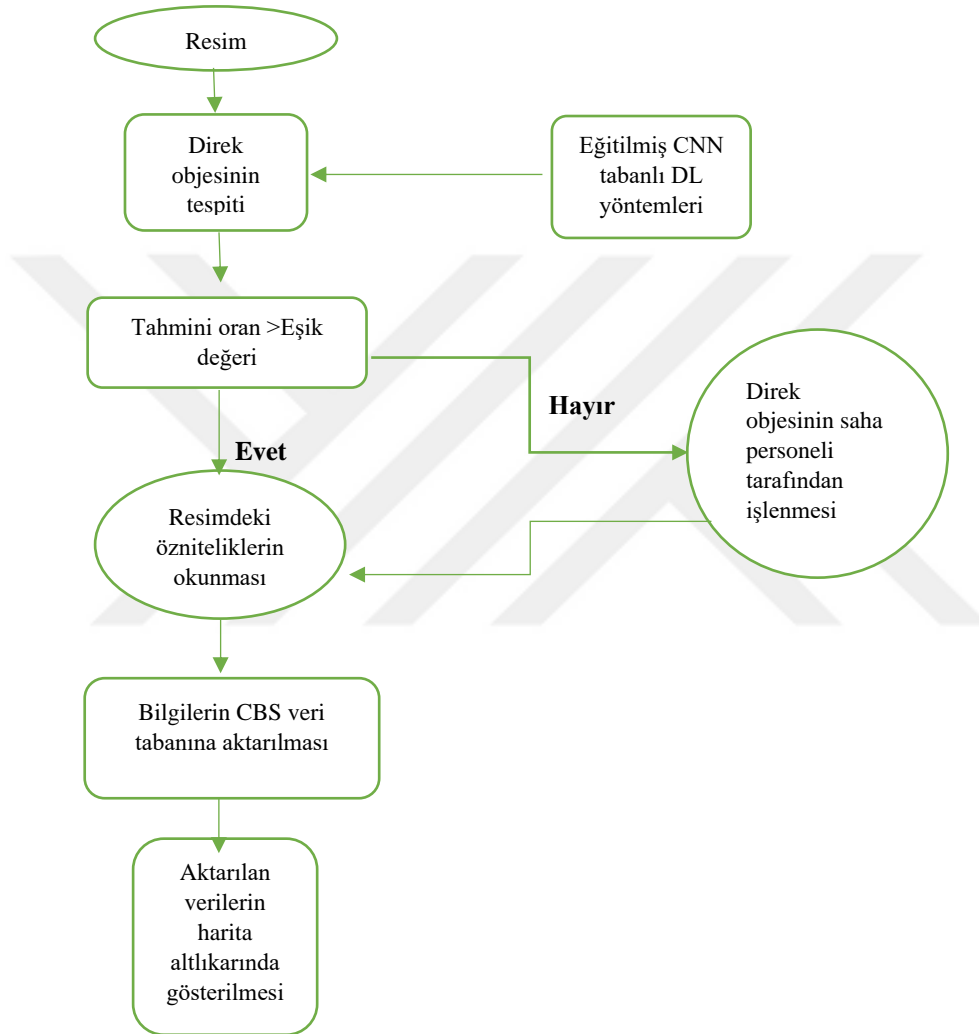
Akış diyagramından da anlaşılacağı üzere girdi görüntüleri direk objelerinin tespit edilebilmesi için eğitilmiş CNN tabanlı DL yöntemi ile tahmin edilmektedir.

DL yöntemi ile yapılan direk objelerinin tahmini güven skoru eşik değerinin üzerindeyse el tableti ile çekilen görüntü sisteme işlenmekte ve veri tabanına aktarılabilir.

Ancak DL yöntemi ile direk objesi için belirlenen tahmin güven skoru eşik değerinin altında ise o görüntü kullanılmamalı, el tabletine direk objesi için girilecek coğrafi ve diğer öznitelik bilgileri kullanıcı tarafından elle manuel olarak girilmeli ve sonrasında CBS veri tabanlarına aktarılması gerekmektedir.

Bu akış diyagramının sisteme işlenecek tüm direk görüntüleri için uygulanması gerekmektedir. Birden fazla nesnenin olduğu ya da derinliğin çok olduğu fotoğraflarda ya yanlış tespitler yapılmış ya da hiç tespit yapılmadığı durumlar olmuştur.

Tablo 3.1. DL Yöntemleriyle Direk Objelerinin Tespiti (*Detection Of Electric Poles With DL Models*)



DÖRDÜNCÜ BÖLÜM

YÖNTEM ve DENEYSEL ÇALIŞMALAR

Elektrik dağıtım şirketlerindeki CBS birimlerinin temel veri kaynağı elektrik şebekesini oluşturan nesnelere dir. Bu nesnelere dir direk objesinin sahadan çekilen görüntülerden tespit edilip sistemlere daha kolay bir şekilde aktarılabilmesi için derin öğrenme tabanlı yaklaşımlar sunulmuştur. Bu çalışmada, CNN tabanlı DL yöntemlerinden YOLOv8 mimarisi, ResNet mimarisi ve MobileNet mimarisi kullanılmış ve bu yöntemlerin verdiği sonuçlar deneysel performansları da göz önünde bulundurularak birbirleriyle kıyaslanmıştır.

4.1. Veri Seti

Tez kapsamında kullanılmak üzere Malatya ilindeki çalışma sahasındaki çeşitli yerlerden çekilen 2343 adet yaklaşık 2 GB boyuta sahip gerçek görüntülerden oluşan elektrik direklerinin fotoğrafları kullanılmıştır. Bu görüntülerden %20'si test, %20'si validasyon, %60'ı ise eğitim verisi olarak kullanılmıştır.

Eğitim veri seti evrişimsel sinir ağı tabanlı DL yöntemiyle eğitilmiş ve direklerin tespit edilmesi için kullanılmıştır. Kullanılan yöntemlerdeki test sonuçları bazı metrikler referans alınarak değerlendirilmiştir.

Bu metrikler aşağıdaki şekilde sıralanabilir:

TP(True Positive): Nesnenin olduğu yerde karesi çizilmiş.

TN(True Negative): Nesnenin olmadığı yerde karesi çizilmemiş.

FP (False Positive): Nesne dışındaki herhangi bir yere karesi çizilmiş.

FN(False Negative): Nesne olmasına rağmen karesi çizilmemiş.

Kullanılan yöntemlerin performansları bu değerlendirme metrikleri baz alınarak kıyaslanmıştır.

4.2. Yapılan Deneyler ve Kullanılan Yöntemlerin Doğrulukları

Bu bölümde DL tabanlı YOLO, ResNet ve MobileNet yöntemleri birbirleriyle karşılaştırılmış ve yöntemlerin test sonuçlarına göre doğruluk oranları kıyaslanmıştır.

Bahsedilen yöntemler sonucunda tespit edilen direk objeleri gerçek direk görüntüleri ile karşılaştırılmıştır. Sahadan toplanan 2343 adet görüntüden %20'sinde testler yapılmıştır.

Yapılan testler sonucunda yöntemlerin en yüksek güven aralıkları Şekil 12'de birbirleriyle kıyaslanmıştır.

Tablo 4.1. Yöntemlerin Karşılaştırması(Comparison of Methods)

	ACCURACY	PRECİSİON	RECALL	F1 SKOR
YOLOv8	0,623	0,908	0,623	0,739
ResNet	0,646	0,764	0,784	0,774
MobileNet	0,557	0,879	0,574	0,695

Tablo 5.1 incelendiğinde yöntemler genel olarak birbirine yakın sonuçlar vermiş olsa da doğruluk olarak en yüksek performansı sırasıyla ResNet, YOLOv8 ve MobileNet göstermiştir.

Kesinlikler değerlendirildiğinde en yüksek performansı sırasıyla YOLOv8, MobileNet ve ResNet göstermiştir. Duyarlılıklar değerlendirildiğindeyse en yüksek performansı sırasıyla ResNet, YOLOv8 ve MobileNet göstermiş olup, F1 skorları incelendiğinde ise en yüksek performansı sırasıyla ResNet, YOLOv8 ve MobileNet göstermiştir.

Genel olarak tüm sonuçlar incelendiğinde bir adet direk görüntüsü bulunan fotoğraflarda neredeyse kullanılan tüm yöntemlerin başarı gösterdiği, birden fazla direk görüntüsünün olduğu, derinliğin ya da nesne sayısının fazla olduğu fotoğraflardaysa bazı durumlarda tespitlerde yanlışlık olduğu ya da herhangi bir tespit yapılmadığı da görülmüştür.

SONUÇLAR VE TARTIŞMA

Bu çalışmada sahadan çekilen ve gerçek elektrik direklerinin görüntülerini içeren fotoğraflardan direk objelerinin belirlenebilmesi adına üç ayrı derin öğrenme yöntemiyle (YOLOv8, ResNet ve MobileNet) çalışma yapılmıştır. Bu çalışmada en yüksek F1 güven skorunu vermiş olması nedeniyle direk objelerinin tespitinde ResNet yöntemi önerilmektedir.

Önerilen bu yöntemlerin yapacağı doğru tahminlerle ofis personellerine ve CBS tablet kullanıcılarına göre çok daha hızlı bir şekilde direk objelerinin tanınıp, sahada var olduğu tespit edilip, sisteme aktarılabilceği düşünülmektedir. Çevresel ve kullanıcı kaynaklı hataların en aza indirgenebilmesi açısından bu yöntemlerin ilerleyen zamanlarda sıklıkla tercih edileceği öngörülmektedir.

Yakın gelecekte bu işlemlerin yalnızca direk objelerinin tespit edilmesi için değil, direk cinslerinin (ağaç direk, demir direk, beton direk) tespiti için de kullanılabileceği, direkler tabletlerden sistemlere aktarılırken hangi cinse sahip olduklarının belirlenebilip CBS altlığına yüksek doğrulukla aktarılabilceği düşünülmektedir.

Ayrıca elektrik dağıtım şirketleri açısından şebeke ağında oldukça önem teşkil eden ve CBS altlığında yine yüksek doğrulukla işlenmesi gereken bir diğer obje olan hatlar için de kablo kesitlerinin (monofaze, trifaze) derin öğrenme yöntemleriyle belirlenebileceği ve kullanıcı kaynaklı hataların en aza indirgenebileceği düşünülmektedir.

Daha doğru ve güncel CBS veri tabanları oluşturmada derin öğrenme yöntemlerinin, teknolojinin de ilerlemesiyle birlikte, yakın gelecekte sıklıkla kullanılacağı tahmin edilmektedir.

KAYNAKÇA

- [1] Basarsoft, Coğrafi bilgi sistemleri cbs nedir?, [Online]. 2023. Available: <https://www.basarsoft.com.tr/cograf-bilgi-sistemleri-cbs-nedir>, [Erişildi: 5 Mayıs 2024].
- [2] Vikipedi, Coğrafi bilgi sistemi, [Online], 2022. Available: <https://tr.wikipedia.org/wiki/Co%C4%9Fraf-bilgi-sistemi>, [Erişildi: 12 Mayıs 2024].
- [3] H. S. Siliğ, "Panoramik görüntülerin kampüs bilgi sisteminde kullanım olanaklarının araştırılması-itü ayazağa kampüsü örneği", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul, 2012.
- [4] N. Sönmez, M. Sarı, "Coğrafi bilgi sistemleri temel esasları ve uygulama alanları," *Derim*, vol. 21, no. 1, pp. 54-68.
- [5] Gdz Elektrik, Dağıtım operasyonları, [Online]. 2022. Available: <https://www.gdzelektrik.Com.Tr/Tr/Corporate/Dagitim-Operasyonlari>, [Erişildi: 25 Mayıs 2024].
- [6] Y. Ekrem, Elektrik dağıtım şebeke bağlantı modelinin coğrafi bilgi sistemi ile oluşturulması ile oluşturulması, [Online]. 2022. Available: <https://Docplayer.Biz.Tr/111075401-elektrik-dagitim-sebeke-baglanti-modelinin-cograf-bilgi-sistemi-ile-olusturulmasi.html>, [Erişildi: 25 Mayıs 2024].
- [7] EPDK, Mevzuat, [Online]. 2023 www.epdk.gov.tr, [Online]. Available: <https://www.epdk.gov.tr/Detay/Icerik/23-2-3/mevzuat> =, [Erişildi: 23 Şubat 2024].
- [8] Esri, Genel Bakış, www.esri.com.tr, [Online]. 2023. Available: <https://www.esri.com.tr/tr-tr/sectorler/elektrik/genel-bakis>, [Erişildi: 25 Mart 2024].
- [9] Shura, Doğal afetler karşısında elektrik [Online]. 2023. <https://shura.org.tr/wp-content/uploads/2023/03/SHURA-2023-04-Dogal-Afetler-ve-EnerjiGuvenligi.pdf>, 2024, [Erişildi: 25 Mart 2024].
- [10] Y. Ekrem, Elektrik dağıtım şebeke bağlantı modelinin coğrafi bilgi sistemi ile oluşturulması, [Online]. 2023. Available: <https://docplayer.biz.tr/111075401->

elektrik-dagitim-sebeke-baglanti-modelinin-cografi-bilgi-sistemi-ile-olusturulmasi.html, [Erişildi: 30 Mart 2024].

- [11] S. Doğan, Elektrik dağıtımda kullanılan cbs sistemleri, [Online]. 2021. Available: <https://tr.linkedin.com/pulse/elektrik-dagitimda-kullanilan-cbs-sistemleri>, [Erişildi: 5 Nisan 2024].
- [12] C. Öztürk, M. Taşyürek, "Ddl: A new deep learning based approach for multiple house numbers detection and clustering", *Journal Of The Faculty Of Engineering And Architecture Of Gazi University*, vol. 37, no. 2, 2022.
- [13] N. Aalami, "Derin öğrenme yöntemlerini kullanarak görüntülerin analizi", *Eskişehir Türk Dünyası Uygulama Ve Araştırma Merkezi Bilişim Dergisi*, vol. 1, no. 1, pp. 17-20, 2017.
- [14] Algur, Ö. , Tümen, V. , & Yıldırım, Ö.«Dış Ortam Görüntülerindeki İnsan Hareketlerinin Hibrit Derin Öğrenme Yöntemleri Kullanarak Sınıflandırılması,» *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, Pp. 121-129, 2018.
- [15] S. Toroman, "Derin öğrenme ile insansız hava aracı görüntülerinden yaya tespiti", *Journal Of Aviation*, vol. 2, no. 2, pp. 64-69, 2018.
- [16] N. Barışçı, S. Sarıkaya, *Video ve kameradan yolo ve retinanet kullanarak gerçek zamanlı çoklu nesne tanıma*, International Scientific Research Congress, 2019.
- [17] R. Daş, B. Polat, G. Tuna, "Derin öğrenme ile resim ve videolarda nesnelere tanınması ve takibi", *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 31, no. 2, pp. 571-581, 2019.
- [18] F. Bayram, "Derin öğrenme tabanlı otomatik plaka tanıma," *Politeknik Dergisi*, vol. 23, no. 4, pp. 955-960.
- [19] A. Yavuz, "Derin öğrenme algoritmaları ile trafik işaret ve levhalarının tanımlanması," Yüksek Lisans Tezi, Pamukkale Üniversitesi, Denizli, 2021.
- [20] E. Saralioğlu, Güngör, O. "Yüksek çözünürlüklü uydu görüntülerinden daha hızlı bölge tabanlı derin öğrenme modeli ile bina tespiti," *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, vol. 12, no. 2, pp. 550-563, 2022.

- [21] Z. Saygılı, G. Özmen, "İnsansız hava araçlarında gömülü sistem üzerinden derin öğrenme ile nesne tespiti," *Avrupa Bilim ve Teknoloji Dergisi*, no. 34, pp. 292-298, 2022.
- [22] Buluistan, Denetimli ve gözetimli öğrenme nedir supervised learning genel bakış, [Online]. 2023. Available: <https://bulutistan.com/blog/denetimli-ve-gozetimli-ogrenme-nedir-supervised-learning-genel-bakis/> [Erişildi: 17 Temmuz 2024].
- [23] S. Şengül, M. Taşyürek, B. Daşbaşı, "Şehir içi otobüs durak numaralarının hiyerarşik kümeleme yöntemiyle yeniden numaralandırılması: Kahramanmaraş ili örneği," *Euroasia Journal Of Mathematics, Engineering, Natural & Medical Sciences*, vol. 8, no. 18, pp. 164-174, 2021.
- [24] A. Şeker, B. Diri, H. H. Balık, "Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme," *Gazi Mühendislik Bilimleri Dergisi*, vol. 3, no. 3, pp. 47-64, 2017.
- [25] T. Talan, C. Aktürk, *Bilgisayar bilimlerinde teorik ve uygulamalı araştırmalar*. Ankara: Efe Akademi Yayınları, 2021.
- [26] Ö. İnik, E. Ülker, "Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri," *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, vol. 6, no. 3, pp. 85-104, 2017.
- [27] F. Doğan, İ. Türkoğlu, "Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme," *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, vol. 10, no. 2, , pp. 409-445, 2019.
- [28] K. Kayaalp, A. A. Süzen, *Derin öğrenme. derin öğrenme ve Türkiye'deki uygulamaları*, Ankara: İksad Yayınevi, 2018.
- [29] E. Akın, M. E. Şahin, "Derin öğrenme ve yapay sinir ağı modelleri üzerine bir inceleme," *EMO Bilimsel Dergisi*, vol. 14, no. 1, pp. 27-38, 2024.
- [30] J. Redmon, S. Divvala, E. Girshick, A. Farhadi, *You only look once: Unified, real-time object detection*, In Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition, 2016.

- [31] R. Huang, J. Pedoeem, C, Chen, *Yolo-lite: A real-time object detection algorithm optimized for non-gpu computers*, In 2018 Ieee International Conference On Big Data (Big Data), Pp. 2503-2510, 2018.
- [32] A. F. Bayram, V. Nabiyev, "Derin öğrenme tabanlı saklanan kamufle tankların tespiti: Son teknoloji yolo ağlarının karşılaştırmalı analizi," *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, vol. 13, no. 4, pp. 1082-1093, 2023.
- [33] M. A. Özel, S. S. Baysal, M. Şahin, "Derin öğrenme algoritması (Yolo) ile dinamik test süresince süspansiyon parçalarında çatlak tespiti," *Avrupa Bilim ve Teknoloji Dergisi*, no. 26, pp. 1-5.
- [34] A. Bilgin, Yolo (You only look once) mimarisi nedir?, [Online]. 2021. Available: <https://Aylablgn.Medium.Com/Yolo-You-Only-Look-Once-Mimarisi-Nedir-754d0bc6a6ba>, [Erişildi: 19 Aralık 2022].
- [35] Z. A. Güven, "Türkçe konuşmada duygu tanıma için makine öğrenme yöntemleri ve derin öğrenme tabanlı modellerin karşılaştırılması," *Mühendislik Bilimleri Ve Tasarım Dergisi*, vol. 12, no. 2, pp. 285-297, 2024.
- [36] F. Akın *Yüz tanıma sürecinde farklı cnn modellerinin performans karşılaştırması*, Elazığ: Fırat Üniversitesi, 2019.
- [37] S. Çilek, Resnet residual network nedir, [Online]. 2021. Available: <https://suhedacilek.medium.com/resnet-residual-network-nedir-49105e642566>, [Erişildi: 19 Aralık 2022].
- [38] S. Gökalp, İ. Aydın, "Farklı derin sinir ağı modellerinin duygu tanımadaki performanslarının karşılaştırılması," *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 2, no. 11, pp. 35-43, 2021.
- [39] G. Doğan, B. Ergen, "İmobilenet cnn yaklaşımları ve özellik seçme yöntemleri kullanarak araç türlerini sınıflandırma," *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 25, no. 3, pp. 618-628, 2021.
- [40] S. Gökalp, İ. Aydın, İ. "Farklı derin sinir ağı modellerinin duygu tanımadaki performanslarının karşılaştırılması", *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 2, no. 1. pp. 35-43, 2021.

- [41] A. G. Howard, "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.



ÖZ GEÇMİŞ

1. İLETİŞİM BİLGİLERİ

Adı Soyadı : Sonay ŞENGÜL

Uyruğu : Türkiye Cumhuriyeti

2. ÖĞRENİM DURUMU

Derece	Alan	Üniversite	Yıl
Lisans	Harita Mühendisliği	Erciyes Üniversitesi	2012-2017
Yüksek Lisans	Lisansüstü Eğitim Enstitüsü Hesaplamalı Bilimler ve Mühendislik Ana Bilim Dalı	Kayseri Üniversitesi	2021-Devam

3. YABANCI DİL : İngilizce

4. İŞ DENEYİMLERİ (varsa)

Yıl	Kurum	Görev
2018-2021	Kahramanmaraş Büyükşehir Belediyesi	Harita Mühendisi
2021-Devam	Fırat Elektrik Dağıtım A.Ş Malatya İl Müdürlüğü	Harita Mühendisi

5. YAYINLAR

- ❖ Şengül, S., Taşyürek, M. U. R. A. T., & DAŞBAŞI, B. (2021). ŞEHİR İÇİ OTOBÜS DURAK NUMARALARININ HİYERARŞİK KÜMELEME YÖNTEMİYLE YENİDEN NUMARALANDIRILMASI: KAHRAMANMARAŞ İLİ ÖRNEĞİ. *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 8(18), 165-174.

TEZ İNTİHAL RAPORU

COĞRAFİ BİLGİ SİSTEMLERİNDE ELEKTRİK DİREKLERİNİN DERİN ÖĞRENME YÖNTEMLERİ İLE BELİRLENMESİ

By Sonay Şengül

WORD COUNT

6902

TIME SUBMITTED

21-JUL-2024 11:24PM

PAPER ID

110584428

COĞRAFI BİLGİ SİSTEMLERİNDE ELEKTRİK DİREKLERİNİN DERİN ÖĞRENME YÖNTEMLERİ İLE BELİRLENMESİ

ORIGINALITY REPORT

17%

SIMILARITY INDEX

PRIMARY SOURCES

1	dergipark.org.tr Internet	463 words — 6%
2	bulutistan.com Internet	118 words — 2%
3	docplayer.biz.tr Internet	85 words — 1%
4	www.toroslaredas.com.tr Internet	61 words — 1%
5	www.guvenplus.com.tr Internet	39 words — 1%
6	cevap-bul.com Internet	37 words — 1%
7	icidaai.yalova.edu.tr Internet	36 words — < 1%
8	aip.vse.cz Internet	31 words — < 1%
9	www.euroasiajournal.org Internet	27 words — < 1%

	Internet	8 words — < 1%
30	www.youtube.com Internet	8 words — < 1%
31	Mohammadi, Khatereh. "Prioritized Object Detection Integrating Fuzzy Logic Risk Assessment and Planned Path", Northern Illinois University, 2024 ProQuest	7 words — < 1%
32	Gülter, Betül. "Çocuk resimlerindeki nesnelerin derin öğrenme yöntemleriyle tespit edilmesi", Izmir Katip Celebi University (Turkey), 2024 ProQuest	6 words — < 1%

EXCLUDE QUOTES OFF
EXCLUDE BIBLIOGRAPHY ON

EXCLUDE SOURCES OFF
EXCLUDE MATCHES OFF