



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**UZAKTAN ALGILAMA YÖNTEMİ KULLANARAK SENTİNEL-1
UYDU GÖRÜNTÜLERİNDEN MAKİNE ÖĞRENMESİ
YAKLAŞIMI İLE YÜKSEK GERİLİM DİREĞİ TESPİTİ**

Hasan SARIKAYA

**Ocak-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**UZAKTAN ALGILAMA YÖNTEMİ KULLANARAK SENTİNEL-1
UYDU GÖRÜNTÜLERİNDEN MAKİNE ÖĞRENMESİ
YAKLAŞIMI İLE YÜKSEK GERİLİM DİREĞİ TESPİTİ**

Hasan SARIKAYA

**Danışman
Doç. Dr. Emrullah ACAR**

Diğer Jüri Üyeleri

Dr. Öğr. Üyesi Mehmet Cengiz Arslanoğlu Dr. Öğr. Üyesi Mustafa ÜSTÜNER

**Ocak-2025
BATMAN**

TEZ KABUL VE ONAYI

Hasan SARIKAYA tarafından hazırlanan “UZAKTAN ALGILAMA YÖNTEMİ KULLANARAK SENTİNEL-1 UYDU GÖRÜNTÜLERİNDEN MAKİNE ÖĞRENMESİ YAKLAŞIMI İLE YÜKSEK GERİLİM DİREĞİ TESPİTİ” adlı tez çalışması 23/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Mustafa ÜSTÜNER

.....

Danışman

Doç. Dr. Emrullah ACAR

.....

Üye

Dr. Öğr. Üyesi Mehmet Cengiz Arslanoğlu

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Hasan SARIKAYA
Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

UZAKTAN ALGILAMA YÖNTEMİ KULLANARAK SENTİNEL-1 UYDU GÖRÜNTÜLERİNDEN MAKİNE ÖĞRENMESİ YAKLAŞIMI İLE YÜKSEK GERİLİM DİREĞİ TESPİTİ

Hasan SARIKAYA

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Emrullah ACAR

2025, 66 Sayfa

Elektrik enerjisi, modern toplumların ekonomik ve teknolojik gelişiminde kritik bir rol oynamaktadır. Elektrik, sanayi üretimi, sağlık hizmetleri, eğitim ve iletişim gibi temel sektörlerde kesintisiz hizmet sunumunu mümkün kılarak yaşam kalitesini artırmaktadır. Elektrik enerjisinin iletilmesi, verimli enerji dağıtımı için yüksek gerilim hatları aracılığıyla gerçekleştirilmektedir. Bu hatlar, enerji iletim kayıplarını minimize ederek, enerji verimliliğini ve sürdürülebilirliğini artırır. Elektrik enerjisinin güvenli ve kesintisiz iletimi, altyapının sağlamlığı ve bakımı açısından büyük önem taşımaktadır.

Bu çalışmada, uzaktan algılama ve farklı makine öğrenme teknikleri kullanarak Batman çevresindeki yüksek gerilim hattı direklerinin tespit edilmesi amaçlanmıştır. Sentinel-1 Synthetic Aperture Radar (SAR) uydusu kullanılmıştır. DY (Düşey-Yatay), DD (Düşey-Düşey) polarizasyon modları verisetini oluşturmuştur. Bu verisetleri makine öğrenmesi yöntemi türü olan gözetimli öğrenme modeline ait algoritmalar (Destek vektör makinesi, KNN, Karar Ağacı, Quadratic Discriminant, Naive Bayes) tarafından çözümlenmiştir. Sonuç olarak Destek vektör makinesi modeli ile %85.0; Quadratic Discriminant modeli ile %82.5; KNN modeli ile %82.2; Karar Ağacı modeli ile %76.8; Naive Bayes modeli ile %74.0 başarı oranı sağlanmıştır. Çalışma yapay zekâ kullanılarak yüksek gerilim direklerinin daha doğru, hızlı ve belirli periyotlarla kontrolüne olanak sağlamaktadır. Geleneksel yöntemlerin yüksek gerilim hatlarının kontrolünde zaman alıcı ve maliyetli olduğu göz önüne alındığında, bu çalışma amacı, enerji nakil hatlarının izlenmesi ve bakım süreçlerinin iyileştirilmesine katkıda bulunarak enerji altyapısının verimliliğini artırmaktır.

Anahtar Kelimeler: Yüksek Gerilim Hatları, Makine Öğrenmesi, Uzaktan Algılama, Sentinel-1, Yapay Zekâ.

ABSTRACT

MASTER THESIS

DETECTION OF HIGH VOLTAGE TRANSMISSION TOWERS USING SENTINEL-1 SATELLITE IMAGES WITH A MACHINE LEARNING APPROACH BASED ON REMOTE SENSING METHODS

Hasan SARIKAYA

Batman University Graduate Education Institute

Electrical and Electronics Engineering Department

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2025, 66 Pages

Electric energy plays a critical role in the economic and technological development of modern societies. By enabling uninterrupted service delivery in key sectors such as industrial production, healthcare, education, and communication, electricity enhances the quality of life. The transmission of electric energy is carried out through high-voltage lines to ensure efficient energy distribution. These lines minimize energy transmission losses, thereby increasing energy efficiency and sustainability. The safe and continuous transmission of electric energy is of great importance for the robustness and maintenance of infrastructure.

In this study, it is aimed to detect high-voltage transmission line poles around Batman using remote sensing and different machine learning techniques. The Sentinel-1 Synthetic Aperture Radar (SAR) satellite was used. DY (Vertical-Horizontal), DD (Vertical-Vertical) polarization modes formed the dataset. These datasets were analyzed by algorithms belonging to the supervised learning model type, namely Support Vector Machine, KNN, Decision Tree, Quadratic Discriminant, Naive Bayes. As a result, the Support Vector Machine model achieved an accuracy rate of 85.0%; Quadratic Discriminant model 82.5%; KNN model 82.2%; Decision Tree model 76.8%; and Naive Bayes model 74.0%. The study allows for the more accurate, faster, and periodic control of high-voltage poles using artificial intelligence. Considering that traditional methods for inspecting high voltage lines are time-consuming and costly, the aim of this study is to contribute to the monitoring and improvement of maintenance processes of energy transmission lines, thereby enhancing the efficiency of energy infrastructure.

Keywords: High Voltage Lines, Machine Learning, Remote Sensing, Sentinel-1, Artificial Intelligence.

ÖN SÖZ

Yüksek Lisans Tez çalışma sürecimde yapmış olduğu eleştirileri ve çok kıymetli değerlendirmeleri ile bana yol gösteren çok değerli danışman hocam Doç. Dr. Emrullah ACAR'a teşekkürlerimi sunarım.

Çalışmanın gerçekleşmesi sürecinde faydalandığım Google Earth Engine- Code Editor platformu ve bu platformda kullandığım Sentinel-1 Uydu verileri için European Space Agency (ESA) çalışanlarına teşekkürlerimi sunarım.

Tez çalışma sürecimde bana vermiş oldukları manevi destekten dolayı aileme teşekkür ederim.

Hasan SARIKAYA
BATMAN-2025



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER/TABLolar LİSTESİ.....	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Araştırmanın Amacı ve Önemi	4
1.2. Araştırma Problemi ve Hipotezi	5
1.3. Araştırmanın Varsayımları	6
1.4. Araştırmanın Sınırlılıkları	6
1.5. Evren ve Örneklem	6
2. KAYNAK ARAŞTIRMASI	7
2.1. Uzaktan Algılama Yöntemi ile Makine Öğrenmesi Yaklaşımıyla Yüksek Gerilim Direkleri Tespiti	7
2.1.1. Uzaktan algılama	10
2.1.2. Yapay zekâ.....	11
2.1.2.1. Makine öğrenimi.....	12
2.2. Literatür Çalışmaları	13
2.2.1. Uzaktan algılama yöntemi ile ilgili literatür çalışmaları	14
2.2.2. Hem yapay zekâ hem de uzaktan algılama ile ilgili literatür çalışmaları	15
3. MATERYAL VE METOT.....	20
3.1. Önerilen Sistem Mimarisi	20
3.2. Çalışma Alanı	20
3.3. Verilerin Toplanması	21
3.3.1. Sentinel-1 uydusu özellikleri ve işleyişi	22
3.3.2. Google Earth Engine-Kod Editörü platform yapısı ve işleyişi	25
3.4. Verilerin Çözümlemesi için Uygulanan Makine Öğrenmesi Yöntemleri	26
3.4.1. Destek vektör makinesi (DVM) algoritması.....	26
3.4.2. Naive Bayes (NB) algoritması	28
3.4.3. Karar ağacı algoritması (Decision tree)	28
3.4.4. K-En yakın komşuluk algoritması (k-Nearest neighbours)	29
3.4.5. Quadratic Discriminant algoritması (QD)	30
3.5. Konfüzyon Matrisi	31
3.5.1. Konfüzyon Matrisi (Karmaşıklık Matrisi) Uygulamaları	32
3.6. ROC Eğrisi.....	33
3.6. Cross Validation (Çapraz Doğrulama)	35

4. BULGULAR VE TARTIŞMA.....	36
4.1. Sentinel-1 uydusu polarizasyon bantları.....	38
4.1.1. Makine öğrenmesi ile elde edilen sonuçlar.....	38
4.1.2. DY polarizasyon azalan (descend) yörüngedeki makine öğrenimi sonuçları	38
4.1.3. DD polarizasyon azalan (descend) yörüngedeki makine öğrenimi sonuçları	41
4.1.4. DY polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları ...	45
4.1.5. DD polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları ...	49
4.1.6. DY-DD polarizasyon azalan ve artan yörüngedeki makine öğrenimi sonuçları.....	53
5. SONUÇLAR VE ÖNERİLER.....	58
5.1 Sonuçlar	58
5.2 Öneriler	59
KAYNAKLAR	61

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 4.1. DY polarizasyon azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	39
Çizelge 4.2. DD Polarizasyon azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	42
Çizelge 4.3. DY Polarizasyon artan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	47
Çizelge 4.4. DD Polarizasyon artan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	51
Çizelge 4.5. DY-DD Polarizasyon artan ve azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	55



ŞEKİLLER LİSTESİ

Şekil 2.1. ENH Bileşenleri.....	7
Şekil 2.2. Yüksek Gerilim Direk Çeşitleri (Eltamaly ve ark.,2021)	8
Şekil 2.3. Enerji Nakil Hattı Yangın Çıkma Anı (Karabacak, 2021)	8
Şekil 2.4. İHA ve Dron (Karabacak, 2021)	9
Şekil 2.5. ENH'nın Dron kullanarak kontrollerinde örnek konum modeli (Luque-Vega vd., 2014)	9
Şekil 2.6. Yapay Zekâ (Turknet,2024)	11
Şekil 2.7. Makine Öğrenimi Uygulama Alanları (Mechtekno,2024)	12
Şekil 2.8. Makine Öğrenmesi (Talentcoders,2023)	12
Şekil 3.1. Önerilen sistemin iş akış şeması	20
Şekil 3.2. Seçilen noktaların Google Earth uydu görüntüsü	21
Şekil 3.3. Seçilen direk ve rastgele noktalara ait GEE platformu görüntüsü.....	21
Şekil 3.4. Sentinel-1 Uydu (European Space Agency,2024)	22
Şekil 3.5. Sentinel-1 Takımyıldızı (ESA,2024)	23
Şekil 3.6. Copernicus Sentinel-1A tarafından bir bölge üzerinde DY, DD görüntüsü. (ESA,2024)	24
Şekil 3.7. Makine öğrenmesi türleri (Hatipoğlu,2024).....	26
Şekil 3.8. DVM yapısı (Javatpoint,2024)	27
Şekil 3.9. Karar ağacının genel yapısı (Medium,2017)	29
Şekil 3.10. K-NN diyagramı (IBM,2024).....	30
Şekil 3.11. Konfüzyon matris düzeni (IBM, 2024)	31
Şekil 3.12. ROC-AUC eğrisi (Evidentlyai, 2024)	33
Şekil 3.13. ROC Eğrisi (Evidentlyai,2024)	34
Şekil 3.14. Rastgele ROC Eğrisi (Evidentlyai,2024).....	34
Şekil 4.1. Batman iline ait Google Earth uydu görüntüsü	36
Şekil 4.2. GEE platformu kullanılarak seçilen direk görüntüsü	37
Şekil 4.3. Google Earth Engine kullanılarak seçilen direk ve rastgele seçilen noktalara ait DY-DD polarizasyon görüntüsü	37
Şekil 4.4. DY polarizasyon azalan(descend) yörüngedeki makine öğrenimi sonuçları .	39
Çizelge 4.1. DY polarizasyon azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	39
Şekil 4.5. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	40
Şekil 4.6. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	40
Şekil 4.7. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	40
Şekil 4.8. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	41
Şekil 4.9. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	41
Şekil 4.10. DD polarizasyon azalan (descend) yörüngedeki makine öğrenimi sonuçları	42
Çizelge 4.2. DD Polarizasyon azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	42
Şekil 4.11. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	43
Şekil 4.14. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	45
Şekil 4.15. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	45
Şekil 4.16. DY polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları...	46
Çizelge 4.3. DY Polarizasyon artan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	47
Şekil 4.22. DD polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları...	50

Çizelge 4.4. DD Polarizasyon artan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	51
Şekil 4.23. Quadratic Discriminant konfüzyon Matrisi (sol) ve ROC eğrisi (sağ).....	51
Şekil 4.24. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	52
Şekil 4.25. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	52
Şekil 4.26. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	53
Şekil 4.27. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	53
Şekil 4.28. DY-DD polarizasyon artan ve azalan yörüngedeki makine öğrenimi sonuçları.....	54
Çizelge 4.5. DY-DD Polarizasyon artan ve azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri	55
Şekil 4.29. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	55
Şekil 4.30. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	56
Şekil 4.31. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	56
Şekil 4.32. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	56
Şekil 4.33. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)	57

SİMGELER VE KISALTMALAR

Kısaltmalar

AB	: Avrupa Birliği
AGL	: Yer Seviyesinden Yükseklik
AI/YZ	: Yapay Zekâ
API	: Uygulama Programlama Arayüzü
AUC	: Eğri Altındaki Alan
BM	: Birleşmiş Milletler
CM	: Santimetre
CNN	: Evrişimli Sinir Ağı
DD	: Düşey Düşey
DY	: Düşey Yatay
DINSAR	: Diferansiyel Sentetik Açıklıklı Radar İnterferometrisi
DL	: Derin Öğrenme
DT	: Karar Ağaçları
EC	: Avrupa Komisyonu
ENH	: Enerji Nakil Hattı
ESA	: Avrupa Uzay Ajansı
GA	: Genetik Algoritma
GEE	: Google Earth Engine
GIS/CBS	: Coğrafi Bilgi Sistemi
GLM	: Genelleştirilmiş Doğrusal Model
GPS	: Küresel Konumlandırma Sistemi
HT	: Hough Dönüşümü
IMU	: Ataletsel Ölçüm Birimi
İHA- UAV	: İnsansız Hava Aracı
KHK	: Kanun Hükmünde Kararname
KNN	: K-En Yakın Komşuluk
KV	: Kilovolt
LDA	: Doğrusal Ayırıcı Analiz
LİDAR	: Lazer Görüntüleme, Tespit ve Menzil Ölçme
M	: Metre
ML	: Makine Öğrenimi
MMW	: Milimetre Dalga Radar Sistemi
NB	: Naive Bayes
NLP	: Doğal Dil İşleme
RF/RO	: Rastgele Orman
ROC	: Alıcı Çalışma Karakteristikleri Eğrisi
SAR	: Sentetik Açıklıklı Radar
SKA	: Sürdürülebilir Kalkınma Amaçları
NB	: Naive Bayes
SVM/DVM	: Destek Vektör Makine Algoritması
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
YSA	: Yapay Sinir Ağı
VPLD	: Voksel Tabanlı Parçalı Çizgi
QD	: Karesel Ayırıcı

1. GİRİŞ

Elektrik enerjisi, modern toplumların ekonomik, teknolojik ve sosyal gelişiminde kritik bir role sahiptir. Elektrik, sanayi üretiminden sağlık hizmetlerine, eğitimden iletişime kadar geniş bir yelpazede kesintisiz hizmet sunumunu mümkün kılarak yaşam kalitesini artırır. Elektrik enerjisinin sürdürülebilir ve güvenli bir şekilde sağlanması, toplumların refah düzeyini doğrudan etkiler ve ekonomik büyümeyi destekler. Elektrik enerjisinin üretildiği noktalardan tüketim merkezlerine verimli ve güvenli bir şekilde iletilmesi, enerji dağıtım sistemlerinin temel hedefidir. Bu süreç, yüksek gerilim hatları ve trafo merkezleri aracılığıyla gerçekleştirilir. Yüksek gerilim hatları, elektrik enerjisinin uzun mesafelere taşınmasında etkin rol oynar ve enerji iletim kayıplarını minimize ederek verimliliği artırır. Elektriğin dağıtımını ise yerel dağıtım şebekeleri aracılığıyla yapılır ve bu süreç, şehirler ve kırsal alanlar arasında dengeli bir enerji arzı sağlanmasını amaçlar (Karabacak,2021). Elektrik arzının istikrarı, bölgesel kalkınmanın temel gerekliliklerinden biridir. Elektrik şebekeleri, elektrik enerjisini merkezi güç santrallerinden bireysel kullanıcılara aktarmada kritik bir bağlantı sağlar (Albert ve ark.,2004).

Elektrik enerjisinin kesintisiz ve güvenli bir şekilde iletilmesi ve dağıtılması, elektrik altyapısının sağlamlığı ve düzenli bakımı açısından büyük önem taşır. Yüksek gerilim hatlarının ve trafo merkezlerinin düzenli olarak izlenmesi ve bakımı, arızaların önlenmesi ve elektrik kesintilerinin minimuma indirilmesi için kritik öneme sahiptir. Bakım ve izleme süreçlerinin etkin bir şekilde yönetilmesi, enerji arz güvenliğini artırır ve operasyonel maliyetleri azaltır. Elektrik direklerinin geniş dağılımı, farklı görünümeleri ve karmaşık çevre koşulları nedeniyle, geleneksel insan gücüne dayanan saha denetimleri büyük miktarda kaynak tüketir ve düşük zaman verimliliğine sahiptir. İHA (İnsansız Hava Aracı) tabanlı saha denetimleri, daha performanslı olabilir ancak bu yaklaşım, geniş alanlarda gerçek zamanlı izleme ihtiyaçlarını karşılamakta zorluk yaşar ve yüksek binaların çevresel etkilerine karşı hassastır (Qiao ve ark.,2020). Modern uydu teknolojileri daha geniş izleme ve çevresel etkilerden daha az etkilendiklerinden dolayı uzaktan algılama ve yapay zekâ teknikleri kullanılarak bu süreçlerin daha hızlı ve etkili bir şekilde gerçekleştirileceği değerlendirilmektedir.

Uzaktan algılama yönteminin yapay zekâ ile entegre edilmesi ile oluşturulacak olan bir uygulama sayesinde yüksek gerilim direklerinin tespitlerinin hızla yapılabileceği

düşünülmektedir. Çalışma, uzaktan algılama yöntemi ile elde edilen uydu görüntülerinin yapay zekâya öğretilmesi sonucunda verilerin TEİAŞ (Türkiye Elektrik İletim Anonim Şirketi) gibi ilgili kurumlarla koordine edilerek yüksek gerilim hat ve direklerinin izlemesini kolaylaştırmayı amaçlamaktadır. Verilere hızlı bir şekilde ulaşarak izleme, bakım faaliyetlerini düzenli yaparak olası elektrik kesintilerinin süresini minimize edebilmek için yeterli zamanı elde edebilecektir.

Son yıllarda rüzgâr ve güneş enerji santrallerinin sayısının artmasıyla burada üretilen elektrik enerjisinin var olan sisteme entegre edilebilmesi için yeni yüksek gerilim hatlarına ihtiyaç duyulmaktadır. Eklenen yüksek gerilim hattı projelerinin yapay zekâ kullanılarak en kısa sürede sisteme eklenmesinin o bölgelerde alçak irtifa uçuş yapan hava araçları için uçuş emniyetini korumak açısından da katkı sağlayacağı değerlendirilmektedir. 22 Haziran 2017 tarihinde resmi gazetede yayınlanan 691 sayılı Kanun Hükmünde Kararname (KHK) ile Harita Genel Komutanlığı'na ilgili veri tabanının güncel tutulması görevi verilmiştir: “Uçuş emniyetini etkileyebilecek nitelikte ülke sınırları içinde yapılmış, yapılacak ve/veya kaldırılacak olan yapı, tesis ve benzeri tüm düşey engellere dair bilgiler; bu yapı ve tesisleri yapan, yaptıran, kaldıran, yapımına veya kaldırılmasına izin veren kurum ve kuruluşlar tarafından doğruluğu teyit edilerek Harita Genel Komutanlığına gönderilir. Bu kurum ve kuruluşlar, kendilerine ait bilgilerin güncelliğinin sağlanmasından ve Harita Genel Komutanlığına gönderilmesinden sorumludur. Harita Genel Komutanlığı bu bilgileri elektronik ortamda yayımlar.” Uydu görüntüleriyle kısa sürede tespit edilen yüksek gerilim direklerinin bu kapsamda veri tabanına bir an önce işlenmesinin ilgili hükümlerin en kısa sürede uygulanabilmesi açısından fayda sağlayacağı değerlendirilmektedir.

Bu çalışmada Batman çevresinde manuel olarak 200 adet yüksek gerilim direği ve 200 adet rastgele nokta işaretlenmiştir. Sentinel-1 uydusu SAR (Sentetik Açıklı Radar) teknolojisi kullanarak DY (Vertical-Horizontal,VH), DD (Vertical-Vertical,VV) bant parametrelerinden elde edilen geri saçılma değerlerine makine öğrenmesi modelleri uygulanarak yüksek gerilim direklerinin tespit edilebilirliği incelenmiştir. Bu çalışmada üç ana hipotez üzerinde durulmaktadır: İlk olarak, uzaktan algılama ile elde edilen görüntülerin geri saçılma değerlerinin yapay zekâ ile analiz edilmesi sonucunda elde edilen çıktıların değerlendirilmesi; ikinci olarak, yapay zekâ ile elde edilen verilerin doğruluk analizinin gerçekleştirilmesi ve üçüncü olarak, yapay zekâ verilerinin yüksek doğruluk oranına sahip olması durumunda sistemin işlevselliğinin doğrulanması. Bu araştırma, mevcut literatürdeki çalışmalardan bu yönüyle ayrılmaktadır. Bu alanda

kullanılan makine öğrenmesi modellerinin başarı oranları yüksek bulunmuş olup, bu durum yüksek gerilim direklerinin tespitinde önemli bir avantaj sağlamaktadır.

Literatürde yer alan benzer çalışmalarda özellikle LİDAR (Lazer Görüntüleme, Tespit ve Menzil Ölçme) görüntüleri ile çalışıldığı görülmektedir. Sentinel-1 uydusu SAR ile yapılmış çalışmalar literatürde az sayıda yer almaktadır. Bu çalışmada ise Sentinel-1 uydusu DY, DD polarizasyon modlarından elde edilen görüntüler üzerinde çalışılmıştır. Sentinel-1 SAR uydusu, gökyüzü bulutlarına ve yağmura karşı dirençlidir, bundan dolayı her zaman veri toplama imkânı sağlaması ve kısa tekrar süreleri ile düzenli ve hızlı veri sağlaması bu uydunun seçilme nedenlerindendir. Uydu vasıtasıyla elde edilen görüntülerin makine öğrenmesi modelleri kullanılarak analiz edilmesi, bu çalışmanın önemini vurgulayan bir diğer unsurdur. Makine öğrenmesi modelleri, elde edilen verilerin doğruluğunu ve başarı oranlarını kıyaslamak için oldukça etkili bir yöntemdir. Bu çalışmada da bu yöntem kullanılarak tatmin edici sonuçlar elde edilmiştir.

Giriş bölümünün ardından çalışmanın “Kaynak Araştırması” başlıklı ikinci bölümünde öncelikle enerji nakil hatlarının bileşenleri ele alınmış ve çalışmanın odak noktası olan Batman çevresi yüksek gerilim direklerinin tespit süreci hakkında detaylı bilgiler sunulmuştur. Bu süreçte yüksek gerilim direklerinin tespitlerinde kullanılan uzaktan algılama yöntemi incelenmiş ve çalışmanın amacı doğrultusunda bu yöntemin önemi vurgulanmıştır. Ayrıca, yapay zekâ kavramı üzerinde durulmuş ve literatürdeki benzer çalışmaların taraması yapılmıştır.

Çalışmanın “Yöntem” başlıklı üçüncü bölümünde önerilen sistem mimarisi, çalışma alanı, veri toplama süreçleri ve verilerin analiz yöntemleri detaylı bir şekilde açıklanmıştır. Bu bölüm, çalışmanın metodolojik temelini oluşturarak, elde edilen verilerin nasıl işlendiği ve değerlendirildiğine dair bilgiler vermektedir.

Son olarak, “Bulgular ve Tartışma” başlıklı dördüncü bölümde literatür taraması sonucunda elde edilen verilere dayalı bulgular yorumlanmıştır.

"Sonuç ve Öneriler" başlığı altında, uzaktan algılama ve yapay zekâ kullanılarak yüksek gerilim direk tespitine yönelik değerlendirmeler ve öneriler sunulmuştur. Bu bölümde, çalışmanın kısa bir özeti yapılmış ve elde edilen bulgular detaylı bir şekilde yorumlanmıştır.

1.1. Araştırmanın Amacı ve Önemi

Toplumların gelişmişlik düzeyi ve üretim kapasitesi, enerji tüketimiyle doğrudan bağlantılıdır. Santrallerde üretilen elektrik, sanayi için temel itici güç olup ülkenin kalkınmasında hayati rol oynar. Üretilen elektrik yüksek gerilime dönüştürülerek iletim hatlarıyla taşınır. Elektrik enerjisinin üretim noktalarından tüketim noktalarına minimum kayıp ve kesintisiz iletilmesi hedeflenir. İletim hatları vasıtasıyla şehirlere iletilen elektrik, trafolarla gerilimi düşürülerek dağıtım şebekelerine verilir. Enerji Nakil Hatları (ENH), fırtına, heyelan, deprem gibi doğa olaylarından etkilenebilir ve hasar görebilir, bu nedenle düzenli kontrol ve bakım yapılması önemlidir (Karabacak, 2021). Enerji altyapısının güvenliği ve sürekliliği, enerji iletim hatlarının güvenli ve kesintisiz bir şekilde çalışmasıyla sağlanır (Matikainen ve ark.,2016). Yüksek gerilim direkleri, bu altyapının kritik bileşenlerinden biridir ve bu direklerin düzenli olarak izlenmesi ve bakımı, potansiyel arızalar ve kazaların önlenmesi açısından son derece önemlidir.

Geleneksel yöntemler, enerji nakil hattı direklerinin tespit ve izlenmesi için saha çalışmaları ve hava fotoğrafları gibi zaman alıcı ve maliyetli süreçleri gerektirmektedir. Ayrıca, insanlı helikopterlerle yapılan denetimler hem yüksek maliyetler gerektirir hem de kaza durumunda ciddi riskler taşır. Günümüzde, bu sorunlara çözüm olarak insansız hava araçları (İHA) ve uzaktan algılama teknolojileri giderek daha fazla kullanılmaktadır. Uydu görüntüleme teknolojilerindeki son gelişmeler ve makine öğrenmesi tekniklerinin ilerlemesi, bu süreci daha hızlı, verimli ve kapsamlı bir şekilde gerçekleştirme potansiyeline sahiptir. Özellikle Sentinel-1 gibi yüksek çözünürlüklü radar verileri sağlayan uydu sistemleri, geniş alanları tarayarak enerji nakil hatlarının izlenmesini ve bakımının planlanmasını mümkün kılmaktadır.

Yüksek gerilim direklerinin tespitinin yapılması ile izleme ve bakım faaliyetlerinin hızlı bir şekilde gerçekleşmesi kesintisiz, sürekli elektrik arzının sağlanmasına büyük katkı sağlayacaktır. Bu bağlamda Birleşmiş Milletler Genel Kurulu Sürdürülebilir Kalkınma Amaçlarından “Erişilebilir ve temiz enerji” konulu 7. hedefi ve “Sanayi, yenilikçilik ve altyapı” konulu 9. hedefiyle ilişkilendirilebilir.

Bu tez çalışmasında, Sentinel-1 uydu verileri kullanılarak Batman çevresindeki yüksek gerilim hattı direklerinin tespiti amaçlanmıştır. Sentinel-1, radar tabanlı bir uzaktan algılama sistemidir ve geniş alanları kapsayan, düzenli aralıklarla güncellenen yüksek çözünürlüklü veriler sağlar. Radar verileri, hava koşullarından bağımsız olarak gece ve gündüz eşit derecede etkili bir şekilde veri toplama imkânı sunar. Bu nedenle,

Sentinel-1 uydu verilerinin kullanımı, yüksek gerilim hattı direklerinin tespit edilmesi için maliyet etkin ve güvenilir bir alternatif yöntem olarak kullanılabilir. Çeşitli makine öğrenmesi algoritmaları teknikleri uygulanarak, uydu görüntüleri üzerinde enerji nakil hattı direklerinin otomatik tespiti gerçekleştirilecektir. Çalışma kapsamında, elde edilen bant değerleri karşılaştırılarak en doğru sonuca ulaşılması hedeflenmektedir. Ayrıca, bu yöntemlerin doğruluk, hassasiyet ve performans açısından karşılaştırılması yapılacaktır.

Sonuç olarak, bu çalışma uzaktan algılama ve makine öğrenmesi tekniklerinin enerji nakil hatları direklerinin tespiti ve bakım süreçlerinin iyileştirilmesi amacıyla nasıl kullanılabileceğini göstermeyi amaçlamaktadır. Elde edilen bulguların, enerji altyapısının yönetiminde önemli katkılar sağlayacağı öngörülmektedir.

1.2. Araştırma Problemi ve Hipotezi

Enerji nakil hatları, elektrik enerjisinin güvenli ve verimli bir şekilde iletilmesi için hayati bir öneme sahiptir. Geleneksel yöntemler kullanılarak bu hatların ve direklerin izlenmesi, zaman alıcı ve maliyetli olabilmektedir. Özellikle geniş ve zor erişilen alanlarda, yüksek gerilim direklerinin tespiti ve izlenmesi önemli bir lojistik zorluk teşkil eder. Bu bağlamda, uzaktan algılama teknolojileri ve yapay zekâ yöntemlerinin kullanımı, daha verimli ve ekonomik bir çözüm sunma potansiyeline sahiptir. Ancak, bu yöntemlerin doğruluğu ve uygulanabilirliği hakkında yeterli bilgi bulunmamaktadır. Araştırma problemi, yüksek gerilim direklerinin uzaktan algılama ve yapay zekâ teknikleri kullanılarak güvenilir ve doğru bir şekilde tespit edilip edilemeyeceğidir. Özellikle, Sentinel-1 uydu verilerinin bu amaçla kullanımının etkinliği ve makine öğrenmesi algoritmalarının performansı değerlendirilecektir.

Bu tez çalışmasının hipotezi, Sentinel-1 uydu görüntüleri ve makine öğrenmesi yöntemleri kullanılarak yüksek gerilim direklerinin güvenilir ve doğru bir şekilde tespit edilebileceğidir. Bu bağlamda, çeşitli makine öğrenmesi algoritmaları kullanılarak, yüksek doğruluk oranlarına ulaşılabileceği ve bu yöntemlerin enerji nakil hatlarının izlenmesi ve bakım süreçlerinin iyileştirilmesine önemli katkılar sağlayacağı öngörülmektedir.

1.3. Araştırmanın Varsayımları

Çalışma ile yüksek gerilim hattı direklerinin uzaktan algılama yöntemi aracılığıyla ulaşarak, yapay zekâ sayesinde direklerin tespitlerinin belirlenerek en hızlı ve en doğru biçimde gerçekleştirilmesi varsayılmaktadır. Sentinel-1 uydu görüntülerinin yüksek çözünürlüklü ve doğru veri sağladığı, bu verilerin yüksek gerilim direklerinin tespiti için yeterli ve güvenilir olduğu varsayılmıştır.

1.4. Araştırmanın Sınırlılıkları

Uydu görüntülerinin çözünürlüğü ve kalitesi, tespit sonuçlarının doğruluğunu etkileyebilir. Geliştirilen makine öğrenme modelleri, farklı coğrafi bölgelerde veya farklı çevresel koşullar altında aynı doğruluğa sahip olmayabilir. Modellerin genellenebilirliği sınırlı olabilir. Yüksek gerilim direkleri üzerindeki bitki örtüsü, arazi yapısı veya insan yapımı yapı gibi geçici engeller tespit doğruluğunu azaltabilir. Tespit edilen yüksek gerilim direklerinin doğruluk oranları, modelin eğitime ve kullanılan verilerin kalitesine bağlı olarak değişebilir. Bu, sonuçların güvenilirliğini etkileyebilir. Uydu verilerinin ve tespit sonuçlarının doğru yorumlanması amaçlanır. Yanlış yorumlamalar, hatalı sonuçlara yol açabilir.

1.5. Evren ve Örneklem

Türkiye'deki tüm enerji nakil hattı direkleri bu araştırmanın evreni oluşturmaktadır. Batman ili ve çevresinden seçilen enerji nakil hattı direkleri örneklem olarak kullanılacaktır.


2. KAYNAK ARAŞTIRMASI

Bu bölümde enerji nakil hatlarının bileşenleri, elektrik hatlarının kontrol bakım yöntemleri, uzaktan algılama, yapay zekâ, makine öğrenmesi kavramları hakkında bilgiler verilmiştir. Aşağıda uzaktan algılama ve makine öğrenme teknikleriyle nesne ve yüksek gerilim direği tespiti ile ilgili yapılan bazı çalışmalar incelenmiştir.

2.1. Uzaktan Algılama Yöntemi ile Makine Öğrenmesi Yaklaşımıyla Yüksek Gerilim Direkleri Tespiti


Başlangıçta aydınlatma amacıyla kullanılmaya başlanan elektrik enerjisi, sanayi devriminin yaşanıp seri üretimin artıp fabrikalaşmanın yaygınlaşmasıyla büyük miktarlarda talep edilmeye başlanmıştır. Artan elektrik enerjisi talebini karşılayabilmek amacıyla, yeni üretim tesislerinin inşa edilmesi ve mevcut iletim hatlarının genişletilmesi zorunlu hale gelmiştir. Üretilen bu enerjiyi taşımak için dağıtım sistemleri ve nakil hatları kullanılmaktadır.

Elektrik santrallerinde üretilen elektrik enerjisinin, santrallerden alınıp kullanıcılara dağıtılmasını sağlayan sistemlere enerji nakil hattı (ENH) denir. Enerji nakil hatları iletken teller ve bu telleri taşıyan pylonlar (direkler) olmak üzere iki parçadan oluşur. ENH bileşenleri Şekil 2.1’de gösterilmiştir (Muş,2019).



Şekil 2.1. ENH Bileşenleri

Yüksek gerilim hatları direkleri, taşınacak olan elektrik enerjisinin kapasitesine göre farklı boyutlarda ve büyüklükte seçilir. Yüksek gerilim direk çeşitleri Şekil 2.2’de verilmiştir.



Şekil 2.2. Yüksek Gerilim Direk Çeşitleri (Eltamaly ve ark.,2021)

Doğal afetler, enerji nakil hatları üzerinde ciddi tahribatlara yol açabilen olaylardır. Fırtına, deprem, sel ve diğer doğa olayları, enerji nakil hatlarına zarar vererek enerji dağıtımında kesintilere ve güvenlik sorunlarına neden olabilir (Matikainen ve ark.,2016). Bu tür durumları önlemek ve enerji nakil hatlarının işlevselliğini korumak için düzenli kontrollerin yapılması büyük bir önem taşır.




Şekil 2.3. Enerji Nakil Hattı Yangın Çıkma Anı (Karabacak, 2021)

ENH düzenli bakım ve kontrollerinde geleneksel insanlı devriye kontrolü, helikopter ve İHA/Dron yöntemleri kullanılmaktadır. İnsanlı devriye kontrolü, yüksek gerilim hattı direklerinin dürbün vb. cihazlar ve korona algılama kameraları ile incelenmesidir. Helikopter tarafından yapılan yöntemi hızlı ancak maliyet olarak yüksektir (Karabacak 2021).



Şekil 2.4. İHA ve Dron (Karabacak, 2021)

İHA/Dron ile yapılan kontrollerde üzerinde bulunan kamerayla görüntüler alır. Enerji nakil hatlarının fiziki durumu, herhangi bir hasar alıp almadığı ve etrafında büyüyen bir ağaç olup olmadığı kontrol edilir (Matikainen ve ark.,2016).



Şekil 2.5. ENH'nın Dron kullanarak kontrollerinde örnek konum modeli (Luque-Vega vd., 2014)

Bu çalışmada, Sentinel-1 SAR uydusu üzerinden elde edilen görüntülere ait veriler üzerinde çalışılmıştır. Sentinel-1 uydusu ile yapılmış çalışmalar literatürde az sayıda yer almaktadır. Sentinel-1, Synthetic Aperture Radar (SAR) teknolojisi kullanarak her zaman ve her hava koşulunda veri toplayabilir. Bu, enerji nakil hatlarının sürekli ve kesintisiz izlenmesini sağlar. Geniş alanları kapsayarak yüksek çözünürlüklü veriler elde edebilir. Bu, enerji nakil hatlarının uzun mesafelerde izlenmesini ve büyük alanlarda tehditleri tespit etmesini mümkün kılar. Uydu görüntüleri, geniş alanların izlenmesi ve analiz edilmesi için önemli bir veri kaynağıdır. Makine öğrenme teknikleri ise bu görüntülerin işlenmesi ve anlamlı bilgilere dönüştürülmesi sürecinde kritik bir rol oynamaktadır.

Yüksek gerilim hatları direkleri, uydu görüntülerinin analiz edilmesiyle belirli bir alandaki direklerin belirlenmesini içerir. Bu süreçte, makine öğrenme algoritmaları

kullanılarak direklerin otomatik olarak tespit edilmesi sağlanır. Karşılaştırmalı analiz ise Sentinel-1 SAR uydu görüntülerinin DD (Düşey-Düşey) ve DY (Düşey-Yatay) polarizasyondaki geri saçılma değerlerinin makine öğrenmesi sonuçlarının karşılaştırılmasıyla direklerin tespit edilmesini sağlayacak en doğru yöntemi bulmayı hedeflemektedir.

2.1.1. Uzaktan algılama

Uzaktan Algılama teknolojisindeki ilerlemeler, Dünya yüzey dinamiklerinin izlenmesini sağlayan çeşitli Dünya gözlem uydularının kullanımını önemli ölçüde artırmıştır. Ani ve beklenmedik doğal afetlerin, küresel iklim değişikliğinin ve nüfus artışının etkilerinin izlenmesi ve analiz edilmesi, bu teknolojilerin temel uygulama alanları arasında yer almaktadır. Bunun yanı sıra, doğal kaynakların korunması ve etkin yönetimi, birçok ülke için öncelikli ve kritik konular haline gelmiştir. Bu bağlamda, Uzaktan algılama teknolojileri, sürdürülebilir çevre yönetimi ve afet risk azaltma stratejilerinin geliştirilmesi için vazgeçilmez araçlar sunmaktadır (Abdikan,2016).

Uzaktan algılama, yeryüzü ve yer kaynaklarının incelenmesinde fiziksel temas olmadan veri toplama ve analiz yapma yöntemidir. Başka bir ifadeyle, uzaktan algılama; hava araçları ve uydular kullanarak yeryüzünün görüntülerini kaydedip, bu görüntülerden bilgi elde etmeyi hedefleyen bir bilim dalıdır (Başarsoft,2024).

Uzaktan algılama teknolojileri, yüksek çözünürlüklü uydu verilerinin ticari olarak kullanılmaya başlanmasıyla önemli bir veri kaynağı haline gelmiştir. Günümüzde yaşanan problemleri çözmede önemli faydalar sağlar. Uydu görüntüleri ve coğrafi-mekânsal verilerin analizi, geniş ölçekli uygulamalarda kritik bilgiler sağlar. Geleneksel yöntemlere kıyasla daha hızlı, daha ekonomik çözümler sağlar. Problemleri çözme yeteneği, kullanılan verilerin doğruluğu ve güvenilirliğine dayanır ve bu verilerin hızlı ve ekonomik bir şekilde elde edilmesi gereklidir. Uzaktan algılama, fiziksel temas olmadan nesnelerin özelliklerini belirleme bilimidir ve farklı konumsal, spektral, radyometrik ve zamansal çözünürlüklerle yeryüzünü izlemeyi sağlar. Uydu görüntüleri, yeryüzünün düzenli izlenmesi ve ulaşımı zor bölgelerde çalışılmasına olanak sağlar (Kavzoğlu ve ark.,2011).

Uzaktan algılama, aktif ve pasif sistemler olarak iki bölümden oluşur. Pasif sistemlerde yer alan optik uydular, algılama işlemi için güneş ışığı gibi dış enerji kaynaklarına gereksinim duyarlar. Aktif sistemlerde bulunan radar uyduları, kendi

ürettikleri mikrodalga sinyallerini yeryüzüne gönderip, bu sinyallerin geri yansımalarını algılayarak veri toplarlar (Şanlı,2022).

Uydu görüntüleri, çeşitli spektral bantlarda toplanan verilerden oluşur ve bu veriler, belirli nesnelerin ve değişimlerin tespit edilmesinde kullanılır. Uydu görüntülerinin analizi, görüntü sınıflandırması, değişiklik tespiti ve nesne tanımlama gibi teknikleri içerir. Bu teknikler, şehir planlama, tarım, afet yönetimi ve çevresel izleme gibi birçok alanda kullanılmaktadır.

2.1.2. Yapay zekâ

Yapay zekâ kavramının tanımından önce “zekâ” kavramının açıklanması gerekmektedir. Zekâ, insanın düşünme, akıl yürütme, algılama, kavrama, yargılama ve sonuç çıkarma yeteneklerinin toplamı olarak değerlendirilebilir. Ancak, zekâ kavramı oldukça belirsiz ve geniş bir yapıya sahiptir (Akerkar, 2014).

Yapay zekâ, makinelerin karmaşık problemlere insan benzeri çözümler üretebilmesini sağlama ile ilgilenen bir bilim dalıdır. Bu genellikle, insan zekâsının özelliklerini algoritmalar yoluyla bilgisayarlara uyarlama amaçlanır (Badrinarayan ve ark.,2015).

Yapay zekâ, derin öğrenme, veri analizi, makine öğrenmesi, nesnelerin interneti, simülasyon ve modelleme gibi birçok uygulama alanı sunar (Pannu, 2015).



Şekil 2.6. Yapay Zekâ (Turknet,2024)


2.1.2.1. Makine öğrenimi



Şekil 2.7. Makine Öğrenimi Uygulama Alanları (Mechtekno,2024)

Makine öğrenmesi (machine learning) yapay zekânın (AI) bir alt kümesidir ve makine öğrenme algoritmaları yapay zekâ prensiplerine dayanarak çalışmaktadır. Makine öğrenmesi, bilgisayarların verilerden öğrenmesini öğretmeye ve belirli programlama talimatları yerine deneyimle gelişmesine odaklanır. Bu alanda kullanılan algoritmalar, büyük veri kümelerinde desen ve korelasyonları bulmak ve bu analizlere dayanarak en uygun kararları ve tahminleri yapmak amacıyla eğitilir. Kullanım sıklığıyla birlikte gelişen makine öğrenmesi uygulamaları, daha fazla veri erişimi sağlandıkça daha da doğru sonuçlar üretir.

Yapay zekâ, karar alma ve tahmin yapma süreçlerinde verileri kullanarak işlem yapan bilgisayar tabanlı bir sistemdir. Yapay zekâ bünyesindeki makine öğrenmesi algoritmaları ve diğer yapay zekâ destekli uygulamalar, sistemin yalnızca verileri işlemesini sağlamakla kalmaz, aynı zamanda ek programlamaya ihtiyaç duymadan görevleri yerine getirmesine, tahminlerde bulunmasına, öğrenmesine ve daha akıllı hale gelmesine olanak tanır (Sap,2024).



Şekil 2.8. Makine Öğrenmesi (Talentcoders,2023)

Makine öğrenimi sınıflandırması, uzaktan algılama literatüründe merkezi bir konu haline gelmiştir (Pal ve ark.2003). Makine öğrenimi (ML), uzaktan algılama uygulamaları için son derece etkili ve verimli bir yöntemdir. Son yirmi yılda, uzaktan algılama görüntüleri kullanarak haritalama alanında makine öğrenimi tabanlı yaklaşımların geliştirilmesinde önemli ilerlemeler kaydedilmiştir (Maxwell ve ark.,2018). Makine öğrenimi, doğrusal olmayan sistemlerin regresyon ve sınıflandırılmasında etkili bir yöntemdir. Çok değişkenli olabilen bu sistemler için, sistem parametre alanını kapsayan bir 'eğitim veri kümesi' oluşturulur ve verilerin bir alt kümesi bağımsız doğrulama için ayrılır (Lary ve ark.,2016). Yaygın olarak kullanılan makine öğrenimi algoritmalarının türleri yapay sinir ağları (YSA), destek vektör makineleri (DVM), karar ağaçları (DT), rastgele ormanlar, durum tabanlı muhakeme, genetik algoritma (GA), çok değişkenli uyarlanabilir regresyon eğrileri gibi yöntemleridir (Samui,2012).

2.2. Literatür Çalışmaları

Uzaktan algılama teknolojisi, sağladığı veri artışıyla istenen alanları belirleme, detaylandırma, dağılımlarını analiz etme ve bölgesel değişiklikleri izleme imkânı sunar (Bağcı, 2022). Makine öğrenmesi, son dönemlerde nesne tespiti ve sınıflandırmada geniş çapta kullanılmaya başlanmış ve çeşitli sektörlerdeki problemleri çözmek için uygulanmaktadır (Acar ve ark., 2021). Ayrıca makine öğrenmesi yöntemlerinin, taşkın risk analizi ve orman yangını haritalaması gibi doğal afet olaylarında da etkili bir şekilde kullanılabildiği yapılan çalışmalarla kanıtlanmıştır (Mojaddadi ve ark., 2017). Bu çalışma kapsamında ise, sınıflandırma yöntemleri olarak geleneksel makine öğrenmesi teknikleri tercih edilmiştir. Makine öğrenmesi, insan zekasını taklit etmek amacıyla tasarlanmış ve çevresindeki ortamdan öğrenme yeteneğine sahip bir hesaplama algoritmasıdır (Naqa ve ark.,2015). Uzaktan algılama verileri kullanılarak yüksek gerilim direği tespiti ile ilgili çalışmalar ve benzer çalışmalar taranmış olup bu çalışmalar aşağıda verilmiştir.

2.2.1. Uzaktan algılama yöntemi ile ilgili literatür çalışmaları

Uzaktan algılama yöntemi kullanılarak yapılan bazı çalışmalar aşağıda verilmiştir.

Şenol (2023) tarafından yapılan çalışmada, uzaktan algılama teknikleriyle derin öğrenme algoritmaları kullanılarak nesne tespiti için uydu verilerinin kullanımı araştırılmıştır. Ayrıca, Sentinel-1 radar uydusu kullanarak denizdeki gemilerin tespit edilmesi hedeflenmiştir. Sonuçta, Sentinel-1 DY verileri kullanılarak derin öğrenme algoritmasının %86,11'lik bir doğruluk oranına ulaşılmıştır.

Şanlı (2022) tarafından yapılan çalışmada, bir yıl boyunca farklı zamanlardan alınan SAR ve optik uydu görüntüleri kullanılarak sınıflandırma yapılmıştır. Sınıflandırma sürecinde hem SAR hem de optik verileri birleştirilmiş, ayrıca yalnızca SAR ve yalnızca optik verileri ayrı ayrı sınıflandırılarak SAR ve optik görüntülerin birleştirilmesinin sınıflandırma doğruluğuna etkisi değerlendirilmiştir. Destek Vektör Makineleri (DVM), Rastgele Orman Algoritması (RO) ve K-En Yakın Komşuluk (K-NN) algoritmalarını kullanarak SAR ve optik uydu görüntülerinin birleştirilmesi ile elde edilen veri sonucu %95,90 olarak elde edilmiştir.

Solmaz (2022) tarafından yapılan çalışmada, Bursa şehrindeki arazi kullanımı ve arazi örtüsündeki değişimini tespit etmek için uzaktan algılama teknikleri ve makine öğrenimi algoritmaları kullanılmıştır. Sonuç olarak, DVM ve RO algoritma sonuçları incelendiğinde, DVM yönteminde daha başarılı sonuçlar elde edilmiştir.

Zha ve ark. (2023) tarafından yapılan bu çalışmada, uzaktan algılama görüntülerinden elektrik direklerini tespit etmek amacıyla, görüntü iyileştirme, yarı-denetimli öğrenme ve deforme edilebilir evrişim yöntemlerini birleştiren yüksek hassasiyetli bir nesne algılama modeli sunulmuştur. Görüntü iyileştirme algoritmaları kullanılarak görüntülerin yorumlanabilirliğinin artırılması önerilmiştir. Çalışma, %88 doğruluğa ulaşmış ve sınırlı veri koşullarında dahi performansını arttırabileceği gösterilmiştir. Mevcut nesne algılama modellerine kıyasla bu modelin daha iyi performans gösterdiği tespit edilmiştir. Bu yöntemle, elektrik direklerinin tespit hassasiyetinin yükseltilerek elektrik şebekelerinin verimli işletimi, bakımı ve yönetimi için önemli bir katkı sağlanmıştır.

2.2.2. Hem yapay zekâ hem de uzaktan algılama ile ilgili literatür çalışmaları

Yapay zekâ ve uzaktan algılama teknikleri kullanılarak yapılan çalışmalar aşağıda verilmiştir.

Erbaş (2016) tarafından yapılan çalışmada, radar sistemlerine benzer şekilde çalışan aktif bir uzaktan algılama sistemi olan LiDAR kullanılmıştır. Uçağa takılan lazer cihazı tarafından hassas olarak ölçümler yapılmış ve uygulamada 15m'den daha yüksek olan bölgeler tespit edildikten sonra 15 m'den yüksek olan piksellerin değerleri "1" diğer piksellerin değerleri "0" olacak şekilde binary görüntü oluşturulmuştur. Analiz sonucunda 15 m'den yüksek olan toplam 39,17 km uzunluğunda yüksek gerilim hattı tespit edilmiştir.

Muş (2019) tarafından yapılan çalışmada, geleneksel yöntemlere kıyasla daha başarılı sonuçlar elde edilen hava LiDAR verileri kullanılmıştır. Enerji nakil hatları ve yüksek yerüstü objelerinin, geliştirilen algoritma sayesinde otomatik olarak tespit edilmesi amaçlanmıştır. Önerilen algoritma kullanılarak tellerin tespit oranı %97,13 olarak gerçekleştirilmiştir.

Bakış (2023) tarafından yapılan çalışmada, müsilağın yoğun olduğu Marmara Denizi'nin Armutlu-Zeytinbağı bölgesi, 2021 Mayıs ayında Sentinel-1 uydusu ile incelenmiştir. Bölgede 1300 nokta, Google Earth Engine (GEE) platformu üzerinden işaretlenmiş ve Sentinel-1 uydusuna aktarılmış ve DD-DY bant parametreleri kullanılarak geri saçılım değerleri alınmış ve bu değerlerden veri setleri oluşturulmuştur. Bu veri setlerine makine öğrenmesi algoritmaları ve derin öğrenme algoritmaları uygulanmıştır. Makine öğrenmesi ve derin öğrenme modellerinin veri setlerine uygulanmasının sonuçları incelendiğinde, DD+DY bandı için kullanılan Karar Ağacı (DT) modelinde doğruluk oranı %98,2 olarak hesaplanmıştır.

Şimşek (2024) tarafından yapılan çalışmada, tarımsal ürün deseninin sınıflandırma yoluyla tespitinde Sentinel-1 Sentetik Açıklıklı Radar (SAR) ve Sentinel-2 multispektral verilerinin etkisi incelenmiştir. Bu çalışmada, 2021 yılına ait çok zamanlı Sentinel-1 ve Sentinel-2 görüntüleri kullanılarak aşırı gradyan arttırma (XGBoost) algoritması ile tarımsal ürünlerin desen sınıflandırması yapılmıştır. Sentinel-1 verileri (DY, DD, DY/DD) kullanılarak yapılan sınıflandırmada %72,3 sonucu elde edilmiştir. Sadece Sentinel-2 verileri ile yapılan sınıflandırmada %87,2 sonucuna ulaşılmış olup,

Sentinel-1 ve Sentinel-2 verilerinin birlikte kullanıldığı sınıflandırma sonucu %92,1 olarak elde edilmiştir.

Babagiray ve ark. (2021) tarafından yapılan çalışmada, Adana ili ve çevresinde 24.12.2019- 08.01.2020 tarihleri arasında meydana gelen şiddetli yağışlar incelenmiştir. 16 günlük dönemde 594 mm, 3 günlük dönemde 346 mm ve bir günde 182 mm yağış kaydedilmiştir. Bu yağışlar, yerleşim bölgelerinde ve tarım arazilerinde maddi zarara neden olmuştur. Sentinel-1 SAR uydu görüntüleri kullanılarak su kaplı alanlar tespit edilmiştir. Bu analizler sonucunda, uzaktan algılama ürünleri ve CBS yardımıyla su kaplı alanların belirlenebildiği, bu alanların yağış miktarı, artan toprak nemi, eğim ve toprak yapısına bağlı olduğu belirlenmiştir.

Desai ve ark. (2022) tarafından yapılan çalışmada, GEE kullanarak Sentinel-1 veri kümeleri ile Pusad, Maharashtra'nın arazi örtüsü haritasının oluşturması hedeflenmiştir. Sentinel-1, kullanılarak hava durumundan bağımsız gözlemler sağlanmış SAR veri kümeleri oluşturulmuştur. DD ve DY polarizasyon Sentinel-1 zaman serisi verileri, Destek Vektör Makinesi (DVM) ve Rastgele Orman (RF) algoritmaları kullanılarak otomatik olarak sınıflandırılmıştır. Kullanılan metodoloji ve polarizasyona bağlı olarak, %82,3 ile %90 arasında değişen genel doğruluklar elde edilmiştir.

Tian ve ark. (2020) tarafından yapılan çalışmada, yüksek çözünürlüklü SAR görüntülerinde elektrik kulelerinin tanımlanması için derin öğrenme tabanlı modeller oluşturulmuştur. Zhijiang Şehri'ndeki geniş formatlı görüntülerde 42 elektrik kulesi tespit edildiği ve bunların 31'inin Hubei Eyaleti'nde bulunduğu, geri çağırma oranı ise %73,8 olarak görülmüştür. SAR görüntülerinin, karmaşık arka planlardaki bozulmaları yüksek oranda ortadan kaldırarak, daha yüksek doğruluk sağlayabileceği belirtilmiştir. Elektrik kulelerinin bulunduğu arka planın karmaşıklığı nedeniyle, tarım arazileri, nehirler, binalar ve dağ ormanları gibi çeşitli çevresel faktörler doğruluk sonucunu etkilemiştir. Bu nedenle, örnek setini genişletmek ve karakteristik iyileştirme gibi işlemler eklenerek, elektrik kulesi tespitinin geri çağırma oranı ve doğruluğu artırılabilir sonucu elde edilmiştir.

Qiao ve ark. (2020) tarafından yapılan çalışmada elektrik direğinin tespiti hedeflenmiştir. Elektrik direklerinin izlenmesi, kentsel gelişimi önemli ölçüde etkileyebilmektedir. Bu nedenle, elektrik direklerinin sürekli ve gerçek zamanlı izlenmesi gerekmektedir. Manuel algılama verimsiz olduğundan, bu çalışma yüksek çözünürlüklü uzaktan algılama görüntülerinde elektrik direği algılaması için derin öğrenme

yöntemlerinin kullanımı önerilmiştir. Çalışmada, farklı özelliklere sahip 10 derin öğrenme tabanlı dedektörün performansı test edilmiştir. 1500 görüntü içeren veri kümesi üzerinde kapsamlı deneyler yapılmış ve karmaşık durumlara uyarlanabilirlik analiz edilmiştir. Deney sonuçlarında, derin öğrenme yöntemlerinin elektrik direği algılamada uygulanabilir olduğu gösterilmiştir.

Acar (2020) tarafından yapılan çalışmada, makine öğrenmesi yöntemi ve Sentinel-1 SAR görüntüleri kullanarak tarım alanlarındaki kayıt dışı elektrik dağıtım trafolarının tespit edilmesi hedeflenmiştir. Çalışma; özellik çıkarma, en iyi makine öğrenmesi tekniğini belirleme, özellik seçimi ve tespit olmak üzere dört temel aşamadan oluşmuştur. İlk aşamada, DY ve DD polarizasyonlarının iki geri saçılma parametresi 32 farklı tarihte elde edilmiş ve her bir örnek noktası için 64 birimlik bir özellik vektörü oluşturulmuştur. İkinci aşamada, en uygun makine öğrenmesi tekniği belirlenmiş olup üçüncü aşamada ise en anlamlı ve etkili özellikler seçilmiştir. Son olarak, belirlenen teknik ve seçilen özellikler kullanılarak tespit işlemleri gerçekleştirilmiştir. Makine öğrenmesi yöntemi kullanarak elektrik dağıtım trafoları %85,47 ortalama doğruluk oranıyla tespit edilmiştir.

Xiong ve ark. (2021) tarafından yapılan bu çalışmada, yüksek gerilim direkleri ve hatlarının alçak irtifa uçan hava araçları için tehlikeli durumlar oluşturduğu belirtilmiştir. Bu sorunu çözmek amacıyla, Hough dönüşümü (HT) ve evrişimli sinir ağı (CNN) kullanan bir milimetre dalga (MMW) radar sistemi önerilmiştir. HT, düz çizgi çıkarma kapasitesiyle hatları belirlerken, CNN derin özellik çıkarma ve öğrenme kapasitesiyle gerçek güç hatlarını tespit etmiştir. Hatlar için azimut ve geliş açısı vektörleri güç vektörlerine eklenmiş ve yeni bir CNN mimarisi ile sınıflandırılmıştır. Önerilen CNN mimarisi, endeks havuzlaması kullanarak azimut ve geliş açısı vektörlerini Bragg deseninin özellikleriyle birleştirilmiştir. Ölçek dönüşüm tekniği sayesinde ağ, farklı giriş ölçeklerine uyum sağlamıştır. Deneysel sonuçlar, önerilen yöntemin geleneksel KNN, SVM ve CNN modellerinden daha yüksek doğruluğa ve düşük standart sapmaya sahip olduğunu göstermiştir. Ayrıca, sınıflandırma performansının giriş ölçeklerine ve gürültü seviyelerine duyarlı olmadığı belirlenmiştir.

Ekici ve ark. (2019) bu çalışmada, hibrit bir güç sisteminde iletim hattı arızalarının sınıflandırılması için sürekli dalgacık dönüşümü, evrişimsel sinir ağları ve Bayes optimizasyon yöntemine dayalı bir yöntem önerilmiş. Diğer arıza sınıflandırma uygulamalarından farklı olarak, doğrudan arıza akımı ve voltaj sinyalleri yerine, farklı ölçekleme faktörleriyle elde edilen 3 fazlı voltaj sinyallerinin sürekli dalgacık dönüşümü

katsayı görüntüleri kullanılmıştır. Bu görüntüler, evrimsel sinir ağlarının sınıflandırma yetenekleri ile analiz edilmiştir. Böylece, klasik sinyal işleme ve makine öğrenme yöntemlerine göre, tüm arıza ve faz sinyalleri %100 doğrulukla ve daha kolay sınıflandırılmıştır.

Jwa ve ark. (2009) tarafından yapılan bu çalışmada, yüksek gerilim hattı özelliklerinin zamanında ve doğru izlenmesinin olası tehlikeli durumların önlenmesinde önemli olduğu vurgulanmıştır. Hava kaynaklı LiDAR verilerini kullanarak 3 boyutlu yüksek gerilim hattı modellerini otomatik olarak yeniden yapılandıran Voxel-based Piece-wise Line Detector (VPLD) adlı yeni bir yöntem tanıtılmıştır. Çalışmada, önerilen VPLD yaklaşımının, LiDAR veri setinden yüksek gerilim hatlarını %93,8 başarı oranı ile ortalama 1,4 metre nokta mesafesi ile çıkarabildiği gösterilmiştir.

Zeybek (2018) tarafından yapılan çalışmada, hava kaynaklı LiDAR sistemi ile elde edilen 3D düzensiz nokta bulutlarından yüksek gerilim hattı segmentasyonu için bir yöntem önerilmiştir. İlk olarak, nokta bulutu düzenlenmiş ve zemin filtreleme işlemleri uygulanmıştır. Daha sonra, segmentlenen zemin olmayan noktalar, zemin noktaları ile normalize edilmiş ve AGL (Above Ground Level) hesaplanmıştır. Zemin olmayan AGL değerleri rasterleştirilip kenar tespiti yapılmıştır. Son olarak, yüksek gerilim hatları 3D segmentasyon ve 2D görüntü işleme metodolojilerine dayanan Hough dönüşümü yaklaşımı ile çıkarılmıştır. Farklı arazi koşullarında yüksek gerilim hatlarının tespit edilebilirliği değerlendirilmiştir.

Ko ve ark. (2012) tarafından yüksek gerilim hattı altyapısını tehdit eden ağaçları belirlemek için uzaktan algılama yöntemi kullanılarak yüksek yoğunluklu lazer tarayıcı verileriyle ağaçlar için geometrik özellikler hesaplanmış ve Rastgele Orman makine öğrenme yöntemi ile ağaç türlerinin sınıflandırılması için kullanılmıştır. LiDAR'ın üç boyutlu haritalama kabiliyetini kullanarak, ağaçların geometrisiyle ilgili ağaç metrikleri türetilmiştir. Ağaçların baskın büyüme yönü, iletim hatlarına doğru eğilen ağaçları tanımlamada fayda sağlar. Sonuçlara dayanarak, minimum bitki örtüsü açıklık mesafesi içinde büyüyen ağaçlar tespit edilmiş ve yüksek gerilim hatlarının üzerine düşebilecek uzun ağaçlar belirlenmiştir.

Bu çalışmada kullanılan yöntemler, literatürdeki diğer çalışmalardan farklılık göstermektedir. Diğer çalışmalarda yüksek mekânsal çözünürlüklü uydu görüntüleri, derin öğrenme algoritmaları ve LiDAR verileri kullanılmıştır. Bu çalışmada Sentinel-1 SAR, DY-DD bant verileri ile elde edilen geri saçılma değerleri sayısal veri formatında düzenlenerek makine öğrenmesi yöntemleri uygulanmış olup sınıflandırma sonuçları

karşılaştırılmıştır. Uydu görüntülerinin yansıma değerleri kullanılarak makine öğrenmesi yöntemleri ile başarılı sonuçlar elde edilmiştir.




3. MATERYAL VE METOT

Bu bölümde; önerilen sistem mimarisi, çalışma alanı, verileri toplama ve kullanılan makine öğrenme yöntemleri açıklanmıştır.

3.1. Önerilen Sistem Mimarisi

Çalışma kapsamında oluşturulan iş akış diyagramı Şekil 3.1’de yer almaktadır.




Şekil 3.1. Önerilen sistemin iş akış şeması

İş akış şeması aşağıdaki aşamalardan oluşmaktadır:

1. Uzaktan algılama yöntemi olarak Sentinel-1 uydusunun kullanılması
2. Bu uydu aracılığıyla yüksek gerilim direklerinin tespit edilmesi
3. Bu alandan alınan verilerin işlenmesi
4. İşlenen verilerden özellik çıkarılması
5. Öznetelik vektörlerinin belirlenmesi
6. Ulaşılan veri setlerine makine öğrenmesi yöntemlerinin uygulanması
7. Uygulanan yöntemler sonucunda direklerin tespit edilip analizinin yapılması

3.2. Çalışma Alanı


Çalışmada, pilot alan olarak Batman ili ve çevresi seçilmiştir. Bu alan üzerinde yüksek gerilim direklerinin belirlenebilmesi için 200 adet direk ve 200 adet rastgele nokta seçilmiştir. Çalışma alanı Şekil 3.2’de gösterilmiştir.



Şekil 9. Seçilen noktaların Google Earth uydu görüntüsü


3.3. Verilerin Toplanması

GEE platformu kullanılarak Batman ili ve çevresindeki yüksek gerilim direklerinin tespitini gerçekleştirebilmek için Sentinel-1 uydu görüntüsü kullanılmıştır. Elde edilen görüntülerde direkler ve rastgele noktalar belirlenip seçilerek ilgili polarizasyon geri saçılma değerlerine bu platform kullanılarak ulaşılmıştır. Sentinel-1 uydu görüntüleri üzerinde 200 adet direk 200 adet rastgele olmak üzere 400 nokta seçilmiştir. Seçilen noktalara ait uydu görüntüsü Şekil 3.3’de gösterilmiştir.



Şekil 10. Seçilen direk ve rastgele noktalara ait GEE platformu görüntüsü

3.3.1. Sentinel-1 uydusu özellikleri ve işleyişi



Şekil 3.4. Sentinel-1 Uydusu (European Space Agency,2024)

Sentetik açıklıklı radar (SAR) görüntüleri, mikrodalga dalgalarının yansıma özelliklerini kullanarak, değişken hava koşullarında yüksek çözünürlüklü görüntüler sağlayarak nesne tespiti çalışmalarında kritik bir rol oynar (Karataş ve ark.,2023).


Optik görüntülemeye kıyasla önemli avantajlara sahiptir. SAR, yansıyan mikrodalga sinyallerini kullanarak hedeflerin boyut ve yapı gibi doğal farklılıklarını belirler ve analiz eder (Licheng ve ark.,2008).

SAR görüntüleri, meteorolojik koşulların optik verilerin elde edilmesini engellediği durumlarda özellikle kullanışlıdır. Optik uyduların aksine, SAR uyduları bulutlu hava koşullarında bile net ve kesintisiz görüntü sağlayabilir. Bu özellik, SAR'ın çeşitli zorlu çevresel koşullarda etkin veri toplama kapasitesini artırır (Balzter ve ark.,2015). Ayrıca Sentinel-1 SAR görüntüleri, gece ve gündüz veri sağlayabilmektedir (Conde ve ark.,2019).

Sentinel-1A uydusu, 12 günlük tekrarlanan döngüler içinde hem tekil hem de çift polarizasyonda C-bant görüntüleri sağlamaktadır. Bu veriler, tüm kullanıcılar için ücretsiz olarak sunulmakta olup, yeni ve zorlayıcı uygulamalar ile fırsatlar için oldukça cazip hale gelmiştir (Nagler ve ark.,2015).


Sentinel-1, ESA'nın Copernicus girişimi için geliştirdiği beş görevden ilkidir. Ölçüm alanı, arazi topografyası, çok amaçlı görüntüleme, okyanus yüzey rüzgarları, okyanus topografyası/akıntıları, okyanus dalga yüksekliği ve spektrumu, deniz buzu örtüsü, kenar ve kalınlık, kar örtüsü, kenar ve derinlik, toprak nemi ve bitki örtüsünü kapsar.

Sentinel-1, 12 günlük tekrar döngüsü ve tek bir uydu için döngü başına 175 yörünge ile kutuplara yakın, güneşle senkronize bir yörüngededir. Hem Sentinel-1A hem de Sentinel-1B, 180° yörüngesel faz farkıyla aynı yörünge düzlemini paylaşır. Her iki uydu da çalışırken, tekrar döngüsü altı gündür.



Şekil 3.5. Sentinel-1 Takımyıldızı (ESA,2024)

Copernicus Sentinel-1, antenini kullanarak aynı darbe serisinden birkaç farklı görüntü toplayabilir ve aynı anda belirli polarizasyonları alabilir. Copernicus Sentinel-1, faz koruyan çift polarizasyonlu bir SAR sistemidir. Yatay (Y) ve Düşey (D) polarizasyonda bir sinyal iletebilir ve ardından hem yatay hem de düşey polarizasyonlarında alabilir. Yerdeki hedefler, farklı yoğunluklarda farklı polarizasyonları yansıtan ve bir polarizasyonu diğerine dönüştüren belirgin polarizasyon imzalarına sahiptir. Polarimetrik hedef ayrıştırma gibi polarimetrik teknikler, farklı saçılma katkılarının ayrılmasına izin verir ve saçılma süreci hakkında bilgi çıkarmak için kullanılabilir. Bu teknikler, nokta hedeflerinin ve dağıtılmış hedef alanlarının iyileştirilmiş sınıflandırılmasını sağlar (ESA, 2024).



Şekil 3.6. Copernicus Sentinel-1A tarafından bir bölge üzerinde DY, DD görüntüsü.
(ESA,2024)

Polarimetrisinin uygulamaları şunları içerir:

- Tarım: bitki türü tanımlama, bitki durumu izleme, toprak nemi ölçümü.
- Ormancılık: biyokütle tahmini, tür tanımlama ve yangın izi haritalaması.
- Hidroloji: sulak alanların ve kar örtüsünün izlenmesi.
- Oşinografi: deniz buzunu tanımlama, kıyı rüzgâr alanı ölçümü, petrol sızıntısı tespiti.
- Güvenlik: gemi tespiti ve sınıflandırması.

Copernicus Sentinel-1 ile, dünya çapında kara ve öncelikli kıyı bölgeleri üzerinde ikili polarizasyon edinimleri toplanır. Çift polarizasyonlu Copernicus Sentinel-1 verilerinin kullanılabilirliği, polarimetrik analiz kullanılarak küresel ve rutin uygulamaların kurulmasını mümkün kılar (ESA 2024).

Elektrik kuleleri, insan yapımı metal yapılardır ve yüksek dielektrik katsayısına sahiptirler. Bu nedenle, SAR görüntülerinde, güçlü yansıma sinyalleri üretirler ve yüksek piksel değeri ile yüksek piksel yoğunluğu gibi özellikler gösterirler (Crisp,2004).

Yüksek gerilim direklerinin metal yapılarından ve dolayısıyla yüksek iletkenlikleri nedeniyle radar dalgalarını güçlü bir şekilde yansıtmaktadır. Yüksek gerilim direkleri, çok sayıda kafes veya çatal tasarımlarına sahip olduklarından dolayı görüntülerde gürültüye (distortion) neden olurlar. Radar görüntülerinden geri saçılmalar ve gürültü, direklerin yönüne ve radar dalgalarının geliş açısına bağlı olarak değişir. Yüksek gerilim direklerine dik gelen radar dalgaları daha güçlü geri saçılmalara neden olmaktadır. DD polarizasyonun metal yüzeylerde daha güçlü geri saçılmalara neden olduğu, DY polarizasyonun ise dağınık geri saçılmalara neden olduğu bildirilmektedir (Sarabandi ve ark.,1994).

Elektrik kulelerinin şekil, yüksekliği ve yapısal özelliklerindeki farklılıklar ile çevresel faktörler, gözlemlenmeleri üzerinde önemli bir etkiye sahiptir. Geniş ovalarda inşa edilen elektrik kuleleri dikkat çekici şekillere sahipken, dik dağlık arazilerdeki kuleler arka plan etkisiyle daha bulanık görünebilir. Bu da dağlık bölgelerdeki elektrik kulelerinin tanımlanmasını zorlaştırır (Tian,2020).

Çalışmada Sentinel-1 SAR uydusu ile yüksek gerilim hatları direklerinin analiz edilmesi yer almaktadır. Söz konusu analizler için, Sentinel-1 uydusunun sahip olduğu farklı polarizasyon modları DY, DD kullanılacaktır.

3.3.2. Google Earth Engine-Kod Editörü platform yapısı ve işleyişi

Dünya gözlem teknolojilerindeki ilerlemeler, çeşitli uydu sensörlerinden elde edilen verilerin artan erişilebilirliği ve yarı otomatik ile otomatik sınıflandırma tekniklerindeki gelişmeler, geniş alanların uzaktan izlenmesini ve analizini mümkün kılmaktadır. GEE gibi çevrimiçi platformlar, veri odaklı teknikleri araştırmacılara sunarak işlemleri büyük ölçüde kolaylaştırmaktadır (Feizizadeh ve ark.,2023). GEE, uydu verilerinin işlenmesi, depolanması ve entegrasyonu konusunda büyük kapasiteye sahip bulut tabanlı bir bilgi işlem platformu olarak öne çıkmaktadır. GEE, farklı son teknoloji sınıflandırıcıların ve hızlı işlem hızının kullanılabilirliği sayesinde, araştırmacılar arasında popülerlik kazanmaktadır (Gorelick ve ark.,2017).


GEE, verileri görselleştirme, zaman serisi grafiklerine dönüştürme ve harici işleme için veri indirme yeteneklerine sahiptir. (Hansen ve ark.,2013). GEE veri kümeleri, JavaScript ve Python uygulama programlama arayüzünde (API) edinilebilir ve işlenebilir. Bu, araştırmacıların ve geliştiricilerin verileri daha esnek ve güçlü bir şekilde uygulamalarına olanak tanır (Google,2024).

GEE, bitki örtüsü haritalama ve izleme, arazi örtüsü haritalama (Wahap ve ark.,2020), tarımsal uygulamalar, sulak alan haritalama (Mleczko ve ark.,2018), afet yönetimi, yer bilimleri ve daha birçok alanda kullanılmaktadır. GEE, Landsat arşivine ve Avrupa Uzay Ajansı (ESA) verilerine erişebilen bir bulut platformu olup yüksek performansı ve yüksek doğruluk oranı gibi avantajları yaygın olarak kullanılmasını sağlamaktadır (Kadı ve ark.,2024).

Çalışmada GEE platformu kullanılarak seçilen noktalara ait DY, DD polarizasyon değerleri alınarak veriseti oluşturulmuştur.

3.4. Verilerin Çözümlemesi için Uygulanan Makine Öğrenmesi Yöntemleri

Araştırma amacı ve kullanılacak veri türlerine bağlı olarak farklı yöntem ve algoritmalar kullanılabilmektedir. Makine öğrenimi tabanlı yöntemlerin modelleme yeteneklerinin, bilim ve mühendislikteki çok kapsamlı uygulamalarda başarılı bir şekilde kullanıldığı çeşitli araştırmalar ile ispatlanmıştır. Mevcut tez çalışmasında, uzaktan algılama problemlerinin çözümünde etkili bir yaklaşım olarak Makine öğreniminin rolü vurgulanacaktır. İlk olarak, Destek Vektör Makineleri (DVM) başta olmak üzere Makine Öğrenmesi tekniklerinin özellikleri gözden geçirilerek Batman bölgesi için bir uygulama örneği GEE kodlaması kullanarak sunulacaktır.



Şekil 3.7. Makine öğrenmesi türleri (Hatipoğlu,2024)

3.4.1. Destek vektör makinesi (DVM) algoritması

Destek Vektör Makineleri (DVM), istatistiksel öğrenme ve denetimli öğrenme temelli bir yaklaşımdır. DVM çalışma prensibi, iki sınıfı en iyi şekilde ayırabilecek en uygun karar fonksiyonunun tahmin edilmesine dayanmaktadır. Bu, iki sınıfı birbirinden en uygun şekilde ayıran bir hiper-düzlemin tanımlanması ile gerçekleştirilir (Vapnik,2013). Bu yöntem, yapısal riski en aza indirerek sınıflandırma ve eğri uydurma problemlerinde kullanılmak üzere geliştirilmiştir (Bergil, 2018).

DVM iki sınıfı ayıran ve destek vektörleri arasındaki marjı maksimize eden en uygun sınırı bulmayı amaçlar. DVM sınıflandırıcısı, doğası gereği ikili bir yapıya sahiptir ve iki sınıf arasında tek bir sınır belirler. Ancak bu sorun, sınıflandırıcının her olası sınıf

kombinasyonu için tekrar tekrar uygulanmasıyla aşılabılır; bu durumda sınıf sayısı arttıkça işlem süresi üssel olarak artacaktır (Cortes,1995).


DVM, veri kümesini sınıflandırmak veya regresyon problemlerini çözmek için kullanılan bir öğrenme algoritmasıdır. DVM, veri kümesini en iyi şekilde bölen bir karar sınırı oluşturarak sınıflandırma yapar. Bu karar sınırı, veri noktalarını en iyi şekilde bölen bir hiper düzlemdir (Mountrakis ve ark.,2011). DVM, bu hiper düzlemi oluştururken, veri noktalarından en uzak olanları destek vektörleri olarak adlandırır.

DVM, doğrusal ve doğrusal olmayan (çekirdek yöntemleri kullanarak) veri kümesi için kullanılabilir. Doğrusal DVM, doğrusal olarak ayrılabilen veri kümesi için kullanılırken, doğrusal olmayan DVM, doğrusal olarak ayrılamayan veri kümesi için kullanılır (Medium,2024).

Son yıllarda, DVM çeşitli bilimsel araştırmalarda en güçlü, basit ve sağlam sınıflandırma ve regresyon algoritmalarından biri olarak yaygınlıkla kullanılmaya başlamıştır. Aynı zamanda, DVM araştırmacılar arasında oldukça popüler ve aktif bir araştırma alanı olan örüntü tanıma (pattern recognition) görevlerinde önemli bir rol oynamaktadır (Cervantes et al., 2020).

DVM'ler, öğrenme teorisinin merkezi unsurlarından biridir ve çeşitli bilimsel ve mühendislik uygulamalarında önemli bir rol oynar. Özellikle, sınıflandırma problemleri ve desen tanıma gibi alanlarda son derece etkilidirler (Wu,2006).

DVM'ler, veriyi çok boyutlu bir uzayda temsil ederek ve en uygun ayırma sınırlarını belirleyerek çalışır. Bu sayede, verinin doğrusal olarak ayrıştırılamadığı durumlarda bile yüksek performans sergileyebilirler. Sınıflandırma görevlerindeki başarısı, onları biyometrik tanıma, metin madenciliği, tıbbi teşhis gibi birçok alanda kullanılmasını sağlar.



Şekil 11. DVM yapısı (Javatpoint,2024)

3.4.2. Naive Bayes (NB) algoritması

Makine öğreniminde en sık kullanılan sınıflandırma yaklaşımlarından biri Bayes sınıflandırmasıdır. Adından da anlaşılacağı gibi, Bayes sınıflandırıcısının amacı, niteliklere dayalı sınıfların koşullu olasılıklarını elde etmektir. En popüler Bayes sınıflandırıcısı Naïve Bayes (NB) sınıflandırıcısıdır. Bu sınıflandırıcıya "Naïve" adının verilmesinin nedeni, niteliklerin birbirinden bağımsız olduğunu varsaymasıdır. Koşullu olasılığın hesaplanmasında nitelikler arasındaki ilişkiyi dahil eden algoritmalar Naive olmayan veya yarı Naïve Bayes sınıflandırıcılarıdır (Sağlam ve ark.,2022).

Bayes Teoremi, 1812 yılında Thomas Bayes tarafından bulunan koşullu hesaplama formülü olup bir olayın meydana gelme olasılığını, daha önce meydana gelmiş başka bir olayın meydana gelme olasılığı verildiğinde bulur. Bayes Teoremi matematiksel olarak aşağıdaki denklemle ifade edilir (Bayes,1968).

$$P(A|B) = \frac{P(B|A).P(A)}{P(B)} \quad (3.1)$$

$P(A|B)$ = B olayı gerçekleştiğinde A olayının gerçekleşme olasılığı

$P(A)$ = A olayının gerçekleşme olasılığı

$P(B|A)$ = A olayı gerçekleştiğinde B olayının gerçekleşme olasılığı

$P(B)$ = B olayının gerçekleşme olasılığı

3.4.3. Karar ağacı algoritması (Decision tree)


Karar ağacı algoritmaları sezgisel olarak en basit sınıflandırıcılar arasındadır. Karar ağacı algoritması, giriş verilerinin yinelemeli bir bölünmesidir (Pal ve ark.,2003). Bu yöntem, makine öğrenimi, desen tanıma ve istatistik gibi çeşitli alanlarda kullanılmaktadır. Araştırmacılar, karar ağaçlarını farklı veri kümeleri üzerinde genişleterek tıbbi hastalık analizi, metin sınıflandırması, akıllı telefon kullanıcı sınıflandırması ve görüntü işleme gibi birçok uygulama alanında kullanmayı önermektedir.

Bu yöntemin yaygın kullanımı, veri analizi ve sınıflandırma problemlerinde sunduğu anlaşılabilirlik ve doğruluk nedeniyle dikkat çekmektedir. Karar ağaçları,

verinin hiyerarşik olarak yapısını açığa çıkaran ve bu sayede veri üzerinde daha derinlemesine analiz yapmayı sağlayan etkili araçlardır (Charbuty ve ark.,2021).

Karar ağaçları, eksik verilerin varlığında sağlamdır ve ortaya çıkan modellere eksik verileri dahil etmenin birden fazla yolunu sunar. Karar ağaçları esnek ve kullanımı kolay yöntemlerdir. Bu, dağıtım için çok az varsayım gerektiren yüksek kaliteli sonuçların üretilmesini sağlar.

Kök düğüm, dallar, iç düğümler ve yaprak düğümlerden oluşan hiyerarşik bir ağaç yapısına sahiptir. Şekil 17’de karar ağaçları şeması gösterilmiş olup, bir karar ağacı herhangi bir gelen dalı olmayan bir kök düğümlerle başlar. Kök düğümlerden çıkan dallar daha sonra karar düğümleri olarak da bilinen dahili düğümlere beslenir. Mevcut özelliklere göre, her iki düğüm türü de yaprak düğümleri veya terminal düğümleri ile gösterilen homojen alt kümeler oluşturmak için değerlendirmeler gerçekleştirir. Yaprak düğümleri veri kümesindeki tüm olası sonuçları temsil eder (Quinlan,1996).



Şekil 3.9. Karar ağacının genel yapısı (Medium,2017)

3.4.4. K-En yakın komşuluk algoritması (k-Nearest neighbours)

K-En Yakın Komşular (K-NN) algoritması, veri ayırımında temel ve etkili bir yöntem olup, özellikle belirsiz verilerle çalışırken tercih edilmektedir. 1951 yılında Evelyn Fix ve Joseph Hodges tarafından geliştirilen bu algoritma, parametrik tahminle olasılık yoğunluklarını belirlemenin zor olduğu durumlarda kullanılır (Fix,1985).

K-NN algoritması hem sınıflandırma hem de regresyon görevleri için kullanılabilir de ağırlıklı olarak nesne sınıflandırmasında tercih edilir.

Ayrıca, eksik değerleri atamak ve verileri yeniden örneklemek için de son derece kullanışlı bir algoritmadır.

K-NN'deki 'K', yeni veri noktasının komşularının sayısını ifade eder ve bu değerin doğru şekilde belirlenmesi, algoritmanın en kritik aşamasıdır. Doğru değer seçimi, daha iyi doğruluk elde etmek için gereklidir ve bu işlem "parametre ayarlama" olarak adlandırılır. Çok düşük bir K değeri (örneğin, 1 veya 2), gürültülü sonuçlara yol açabilirken, çok yüksek bir K değeri ise veri setine bağlı olarak bazen karışıklığa neden olabilir (Javatpoint,2024).

Bu modelde, çeşitli uzaklık hesaplama algoritmaları mevcut olup Öklidyen, Manhattan, Chebyshev, Hamming, Minkowski, Manahalobis, Havarsiene, Levenshtein, Sorensen-Dice, Jacckard KNN modeli için uzaklık hesaplama algoritmalarıdır (Bakış,2023).



Şekil 3.10. K-NN diyagramı (IBM,2024)

3.4.5. Quadratic Discriminant algoritması (QD)

Gözetimli sınıflandırma problemlerine yönelik standart yaklaşımlardan biri, Quadratic Discriminant (QD) yöntemidir. QD, her sınıfın olasılık dağılımını bir Gauss (normal) dağılımı olarak modelleyerek çalışır (Hastie ve ark.,2001). Bu yöntemde, belirli bir test noktası için sınıfı tahmin etmek amacıyla arka dağılımlar kullanılır. QD, doğrusal olmayan ayırma sınırları kullanarak sınıflandırma yapar ve her sınıfın kovaryans matrisinin farklı olduğunu varsayar. Bu özellikleri sayesinde, QD heterojen veri setlerinde etkili bir sınıflandırma yöntemi olarak öne çıkar.

QD, makine öğrenmesinde kullanılan ve sınıflandırma problemlerine yönelik güçlü bir tekniktir. QD, özellikle veri noktalarını farklı sınıflara ayırmak için kullanılır ve her sınıfın farklı kovaryans matrislerine sahip olduğu durumlarda etkili bir şekilde çalışır.

QD, her sınıf için ayırım fonksiyonları oluşturur ve bu fonksiyonlar, veri noktalarının hangi sınıfa ait olduğunu belirler. Ayırım fonksiyonları, sınıfların ortalama değerleri ve kovaryans matrisleri kullanılarak hesaplanır.

3.5. Konfüzyon Matrisi

Konfüzyon matrisi, makine öğreniminde kullanılan ve gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif tahminleri tablolastırarak bir sınıflandırma modelinin performansını özetleyen bir performans değerlendirme aracıdır (Beauxis ve ark.2014). Modelin tahminlerinin doğruluğunu ve etkinliğini değerlendirmeye yardımcı olur. Matris, gerçek pozitifler (TP), gerçek negatifler (TN), yanlış pozitifler (FP) ve yanlış negatifler (FN) kavramlarına dayanır. Bir modelin farklı sınıflardaki performansının ayrıntılı bir görünümünü sağlar.

		Tahmin Sınıfı (Predicted Class)		
		Positive	Negative	
Gerçek Sınıf (Actual Class)	Positive	Gerçek Pozitif True Positive (TP)	Yanlış Negatif False Negative (FN)	Hassasiyet (Sensitivity) $\frac{TP}{(TP + FN)}$
	Negative	Yanlış Pozitif False Positive (FP)	Gerçek Negatif True Negative (TN)	Özgüllük (Specificity) $\frac{TN}{(TN + FP)}$
		Kesinlik (Precision) $\frac{TP}{(TP + FP)}$	Negatif Tahmin Değeri (Negative Predictive Value) $\frac{TN}{(TN + FN)}$	Doğruluk (Accuracy) $\frac{TP + TN}{(TP + TN + FP + FN)}$

Şekil 12. Konfüzyon matris düzeni (IBM, 2024)

Konfüzyon matrisi, bir modelin performansına ilişkin ayrıntılı içgörüler sunan temel değerlendirme ölçütlerinin hesaplanmasının temelini oluşturur:

- Doğruluk: Doğruluk, doğru tahminlerin (TP ve TN) toplam tahmin sayısına oranını niceliksel olarak ifade eder. Bilgilendirici olsa da bu ölçüm sınıflar dengesiz olduğunda yanıltıcı olabilir.
- Kesinlik: Kesinlik, tüm pozitif tahminler arasındaki gerçek pozitif tahminlerin oranını değerlendirir ($TP / (TP + FP)$). Bu ölçüm, yanlış pozitiflerin maliyeti yüksek olduğunda kritik öneme sahiptir.

- Geri Çağırma (Hassasiyet veya Gerçek Pozitif Oranı): Geri Çağırma, gerçek pozitif tahminlerin gerçek pozitif örnek sayısına oranını ölçer ($TP / (TP + FN)$). Bu ölçüm, pozitif örnekleri kaçırmamanın maliyetli olduğu durumlarda önemlidir.
- Özgüllük (Gerçek Negatif Oranı): Özgüllük, gerçek negatif tahminlerin gerçek negatif örnek sayısına oranını ($TN / (TN + FP)$) hesaplar. Bu ölçüm, negatif örnekleri doğru bir şekilde belirlemeye vurgu yapıldığında hayati önem taşır.
- F1-Puanı: F1-Puanı, kesinlik ve geri çağırma arasında bir denge kurarak hem yanlış pozitiflerin hem de yanlış negatiflerin benzer öneme sahip olduğu durumlarda kullanışlı hale gelir.

3.5.1. Konfüzyon Matrisi (Karmaşıklık Matrisi) Uygulamaları

Karmaşıklık matrisinin çeşitli alanlarda uygulamaları vardır:


- Model Değerlendirmesi: Karmaşıklık matrisinin birincil uygulaması, bir sınıflandırma modelinin performansını değerlendirmektir. Modelin doğruluğu, kesinliği, geri çağırması ve F1 puanı hakkında içgörüler sağlar.
- Tıbbi Tanı: Karmaşıklık matrisi, testlere veya görüntülere dayalı olarak hastalıkları teşhis etmek için tıbbi alanlarda yaygın olarak kullanılır. Tanı testlerinin doğruluğunu ölçmeye ve yanlış pozitifler ile yanlış negatifler arasındaki dengeyi belirlemeye yardımcı olur.
- Dolandırıcılık Tespiti: Bankalar ve finans kuruluşları, yapay zeka algoritmalarının dolandırıcılık faaliyetlerinin modellerini belirlemeye nasıl yardımcı olduğunu göstererek dolandırıcılık işlemlerini tespit etmek için karmaşıklık matrislerini kullanır.
- Doğal Dil İşleme (NLP): NLP modelleri, duygu analizini, metin sınıflandırmasını ve adlandırılmış varlık tanımayı değerlendirmek için karmaşıklık matrislerini kullanır.
- Müşteri Kaybı Tahmini: Karmaşıklık matrisleri, müşteri kaybını tahmin etmede önemli bir rol oynar ve yapay zekâ destekli modellerin müşteri kaybını tahmin etmek ve azaltmak için geçmiş verileri nasıl kullandığını gösterir.
- Görüntü ve Nesne Tanıma: Karmaşıklık matrisleri, görüntülerdeki nesneleri tanımlamak için modellerin eğitilmesine yardımcı olur ve böylece otonom arabalar ve yüz tanıma sistemleri gibi teknolojilerin geliştirilmesine olanak tanır (Encord,2024).

3.6. ROC Eğrisi

Alıcı çalışma karakteristikleri (ROC) eğrileri, makine öğrenmesi ve istatistikte sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir araçtır (Fawcett,2006). Bu eğri, modelin farklı eşik değerlerinde doğru pozitif oranı (True Positive Rate) ile yanlış pozitif oranını (False Positive Rate) karşılaştırarak oluşturulur. ROC eğrisinin temel özellikleri şunlardır:


- Doğru Pozitif Oranı (TPR): Duyarlılık olarak da bilinir ve pozitif sınıfların doğru bir şekilde tahmin edilme oranını gösterir.
- Yanlış Pozitif Oranı (FPR): Bir modelin negatif sınıfları yanlış bir şekilde pozitif olarak tahmin etme oranını gösterir.
- Eğri Altındaki Alan (AUC- Area Under Curve): Modelin genel performansını özetler; 1'e yakın AUC değerleri daha iyi performansı, 0.5'e yakın değerler ise rastgele tahmin performansını gösterir. ROC AUC puanı, sınıflandırıcının pozitif ve negatif sınıfları ne kadar iyi ayırt ettiğini gösterir. 0 ile 1 arasında değerler alabilir (Hanley ve ark.,1982).

ROC eğrisi, model performansını görsel olarak değerlendirmek ve en iyi karar sınırlarını belirlemek için kullanışlıdır.




Şekil 13. ROC-AUC eğrisi (Evidentlyai, 2024)

Eğer model tüm tahminlerde her zaman doğruysa, bu TPR'nin her zaman 1,0, FPR'nin ise 0 olduğu anlamına gelir. ROC eğrisi aşağıdaki gibi görünecektir.



Şekil 14. ROC Eğrisi (Evidentlyai,2024)

Modelin rastgele olduğu durum, iki sınıf arasında ayrım yapamaz ve tahminleri rastgeledir. Gerçekten rastgele bir model, pozitif ve negatif sınıfları eşit olasılıkla tahmin edecektir.



Şekil 15. Rastgele ROC Eğrisi (Evidentlyai,2024)

3.6. Cross Validation (Çapraz Doğrulama)

Çapraz doğrulama, tahmin modellerinin genelleme yeteneğini değerlendirmek ve aşırı uyumu önlemek amacıyla kullanılan, model seçimi ve değerlendirilmesinde en yaygın veri yeniden örnekleme yöntemlerinden biridir (Berrar,2019). Bu teknik, modelin çeşitli veri alt kümeleri üzerinde test edilmesi yoluyla, model performansının daha geniş bir perspektiften ölçülmesini sağlar. Çapraz doğrulama, modelin sadece eğitim verisi üzerinde değil, gelecekte karşılaşılabileceği yeni veriler üzerinde de sağlam ve güvenilir performans göstermesini sağlar.

Çapraz doğrulama kullanılarak sınıflandırma parametrelerinin ayarlanmasının uzaktan algılama analizlerinde sınıflandırma doğruluğunu artırdığı gösterilmiştir (Duro ve ark.,2012).

En yaygın kullanılan yöntemlerden biri K-katlı (K-Fold Cross-Validation) çapraz doğrulama yöntemidir. K-katlı çapraz doğrulama yöntemi, örnek kümesinin eşit büyüklükteki k sayıda kata (gruplara) rastgele bölünmesini içerir. Burada, k, veri kümesinin bölündüğü bölüm veya kat sayısını belirtir. Örneğin, k değeri on olarak belirlendiğinde, veri kümesi on eşit bölüme ayrılır. Bu durumda, her bir tekrarda, dokuz bölüm eğitim verisi olarak kullanılırken, kalan bir bölüm test verisi olarak kullanılır. Bu işlem, her seferinde farklı bir bölümü test verisi olarak kullanarak on kez tekrarlanır. Elde edilen sonuçların ortalaması, modelin performansını değerlendirmek için raporlanır (Stone,1974).

4. BULGULAR VE TARTIŞMA

Çalışmada pilot alan olarak Batman ili ve çevresi seçilmiş ve Batman çevresindeki yüksek gerilim direklerinin tespit edilmesi hedeflenmiştir. GEE platformu kullanılarak Batman ili ve çevresindeki yüksek gerilim direkleri manuel olarak tespit edilerek Sentinel-1 SAR uydusu DY, DD polarizasyonlarından alınan geri saçılma değerleri ile veri seti oluşturulmuştur. Oluşturulan veri seti, farklı makine öğrenmesi yöntemleri (DVM, KNN, NB, QD, DT) kullanılarak çözümlenmiş ve sonuçlara göre en başarılı yöntemler belirlenmiştir.




Şekil 16. Batman iline ait Google Earth uydu görüntüsü

Çalışmada, Batman ilindeki yüksek gerilim direklerinin makine öğrenmesi yöntemleriyle tespit edilerek sonuçlarının analizinin yapılması amaçlanmıştır. Çalışma bölgesi üzerinde, manuel olarak 200 yüksek gerilim direği ve 200 rastgele nokta işaretlenmiştir.



Şekil 4.2. GEE platformu kullanılarak seçilen direk görüntüsü

Sonrasında; Sentinel-1 uydusu artan ve azalan yörüngelerdeki bant parametreleri (DY, DD) kullanılarak veri setleri oluşturulması hedeflenmiş olup her bir nokta için yansıma değerlerine ulaşılmıştır. Amaç her bir bant verisini makine öğrenmesi ile analiz etmektir. Bu doğrultuda veri setlerine, direklerin belirlenebilmesi için makine öğrenmesi modelleri uygulanmıştır. Çalışma bölgesinde işaretlenen direklerin ve rastgele noktaların bulunduğu Sentinel-1 A-B uyduları üzerindeki yansıma bant değerleri GEE platformu üzerinden elde edilmiştir.



Şekil 4.3. Google Earth Engine kullanılarak seçilen direk ve rastgele seçilen noktalara ait DY-DD polarizasyon görüntüsü

4.1. Sentinel-1 uydusu polarizasyon bantları

Sentetik açıklıklı radar (SAR) sensörleri, elektro-optik sensörlerin yetersiz kaldığı bulutlu hava koşullarında ve hem gece hem de gündüz aktif olarak çalışabilen ileri teknoloji cihazlarıdır. Bu sensörler, yüzeyin özelliklerini algılayarak detaylı bilgi sağlar. Bu özellikleri sayesinde, zorlu hava koşullarında bile güvenilir veri elde edilmesini mümkün kılarlar (Dickinson ve ark.,2013). Polarimetrik SAR sistemleri hem dikey hem de yatay polarizasyonlu mikrodalga sinyallerini gönderip alarak çalışır. Bu sistemler, yüzeyin elektromanyetik özelliklerini daha detaylı ve kapsamlı bir şekilde analiz etmeye olanak tanır (Açıksarı ve ark.,2018).


Çift polarimetrik Sentinel-1 verilerinin analizleri, banliyö ve kentsel alanlarda en hassas sonuçları sağlamıştır (Roychowdhury, 2016). Ayrıca Sentinel-1 verilerinin analizleri, afet yönetimi ve hızla değişen çevre koşullarının tespiti için de kullanılmıştır. DD ve DY polarizasyonlarının çeşitli kombinasyonlarını kullanarak, yüksek genel doğruluk oranı elde edilebilir (Abdikan, 2016).

4.1.1. Makine öğrenmesi ile elde edilen sonuçlar

Oluşturulan veri seti, K-katlamalı çapraz doğrulama (K-fold cross validation) yöntemiyle alt gruplara ayrılmıştır. Bu süreçte, K değeri değiştirilerek sistemin maksimum başarısı elde edilmeye çalışılmıştır. Bu çalışmada, K değeri 4 olarak seçilmiş ve veri seti farklı makine öğrenmesi modellerini eğitmek için kullanılmıştır.

4.1.2. DY polarizasyon azalan (descend) yörüngedeki makine öğrenimi sonuçları

Bu aşamada, 200 adet yüksek gerilim direğine ve 200 adet rastgele seçilen noktalara ait Sentinel-1 uydusu DY polarizasyon veriseti, GEE platformu kullanılarak oluşturulmuştur. Bu verisetine, çalışmada farklı makine öğrenmesi yöntemleri KA, NB, KNN, QD VE DVM uygulanmış olup elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Bu sonuçlar incelendiğinde KA, NB, KNN, QD VE DVM makine öğrenme yöntemlerinin diğer yöntemlere göre daha başarılı olduğu gözlenmiştir. En başarılı yöntem %69,5 başarı ile Destek Vektör Makinesi modelidir. Çalışmada kullanılan makine öğrenmesi yöntemlerinin karşılaştırma sonuçları Şekil 4.4'te verilmiştir.




Şekil 4.4. DY polarizasyon azalan(descend) yörüngedeki makine öğrenimi sonuçları

Şekil 4.4'te elde edilen sayısal değerler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. DY polarizasyon azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri


Sınıflandırma Yöntemi	Doğruluk % (Accuracy)	Kesinlik % (Precision)	Duyarlılık % (Recall)	F1 Skor % (F1 Score)
Destek Vektör Makineleri (DVM)	69,5%	69,9%	69,5%	69,3%
Naive Bayes	65,2%	66,1%	65,3%	64,8%
Karar Ağacı	65,8%	66,8%	65,8%	65,2%
KNN	64,2%	64,3%	64,2%	64,2%
Quadratic Discriminant	65,2%	66,1%	65,3%	64,8%

Ayrıca, en başarılı yöntem olarak belirlenen DVM makine öğrenmesi yöntemine ait konfüzyon matrisi ve ROC eğrisi Şekil 4.5'te verilmiştir.




Şekil 4.5. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.6’da Naive Bayes algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.6. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.7’de Karar ağacı algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.7. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.8’de KNN algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.



Şekil 4.8. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.9’da Quadratic Discriminant algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.9. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

4.1.3. DD polarizasyon azalan (descend) yörüngedeki makine öğrenimi sonuçları

Bu aşamada, 200 adet yüksek gerilim direğine ve 200 adet rastgele seçilen noktalara ait Sentinel-1 uydusu DD polarizasyon veriseti, GEE platformu kullanılarak oluşturulmuştur. Bu verisetine, çalışmada farklı makine öğrenmesi yöntemleri KA, NB, KNN, QD ve DVM uygulanmış olup elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Bu sonuçlar incelendiğinde KA, NB, KNN, QD VE DVM makine öğrenme yöntemlerinin diğer yöntemlere göre daha başarılı olduğu gözlenmiştir. En başarılı yöntem %63,0 başarı

ile Destek Vektör Makinesi modelidir. Çalışmada kullanılan makine öğrenmesi yöntemlerinin karşılaştırma sonuçları Şekil 4.10'da verilmiştir.



Şekil 17. DD polarizasyon azalan (descend) yörüngedeki makine öğrenimi sonuçları


Yukardaki şekilde elde edilen sayısal değerler Çizelge 4.2'de verilmiştir.

Çizelge 4.2. DD Polarizasyon azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri

Sınıflandırma Yöntemi	Doğruluk % (Accuracy)	Hassasiyet % (Precision)	Duyarlılık % (Recall)	F1 Skor % (F1 Score)
Destek Vektör Makineleri	63,0 %	63,6%	63,0%	62,6%
Naive Bayes	62,5%	63,7%	62,5%	61,6%
Karar Ağacı	61,0%	61,5%	61,0%	60,6%
KNN	60,5%	61,8%	60,5%	59,4%
Quadratic Discriminant	57,5%	60,6%	57,5%	54,2%


Ayrıca, en başarılı yöntem olarak belirlenen DVM makine öğrenmesi yöntemine ait konfüzyon matrisi ve ROC eğrisi Şekil 4.11’de verilmiştir.

Şekil 4.11’de DVM algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 18. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.12’de Naive Bayes algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.12. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.13'te Karar ağacı algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.13. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.14'te KNN algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.



Şekil 19. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.15'te Quadratic Discriminant algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 20. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

4.1.4. DY polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları

Bu aşamada, 200 adet yüksek gerilim direğine ve 200 adet rastgele seçilen noktalara ait Sentinel-1 uydusu DY polarizasyon veriseti, GEE platformu kullanılarak oluşturulmuştur. Bu verisetine, çalışmada farklı makine öğrenmesi yöntemleri KA, NB, KNN, QD VE DVM uygulanmış olup elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Bu sonuçlar incelendiğinde KA, NB, KNN, QD ve DVM makine öğrenme yöntemlerinin

diğer yöntemlere göre daha başarılı olduđu gözlenmiştir. En başarılı yöntem %73,2 başarı ile Destek Vektör Makinesi modelidir. Çalışmada kullanılan makine öğrenmesi yöntemlerinin karşılaştırma sonuçları Şekil 4.16'da verilmiştir.




Şekil 21. DY polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları

Yukardaki şekilde elde edilen sayısal değerler Çizelge 4.3'te verilmiştir.

Çizelge 4.3. DY Polarizasyon artan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri


Sınıflandırma Yöntemi	Accuracy % (Doğruluk)	Precision % (Hassasiyet)	Recall % (Duyarlılık)	F1 Score % (F1 Skor)
Destek Vektör Makineleri	73,2%	73,6%	73,2%	73,1%
Karar Ağacı	73,2%	74,1%	73,2%	73,0%
Naive Bayes	71,2%	72,3%	71,2%	70,9%
Quadratic Discriminant	70,2%	72,5%	70,2%	69,5%
KNN	69,8%	69,8%	69,8%	69,7%

Ayrıca en başarılı yöntem olarak belirlenen DVM makine öğrenmesi yöntemine ait konfüzyon matrisi ve ROC eğrisi Şekil 4.17’de verilmiştir.




Şekil 22. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.18’de Karar ağacı algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 23. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.19’da Naive Bayes algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.19. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.20’de Quadratic Discriminant algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.



Şekil 24. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.21’de KNN algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 25. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

4.1.5. DD polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları

Bu aşamada, 200 adet yüksek gerilim direğine ve 200 adet rastgele seçilen noktalara ait Sentinel-1 uydusu DD polarizasyon veriseti, GEE platformu kullanılarak oluşturulmuştur. Bu verisetine, çalışmada farklı makine öğrenmesi yöntemleri KA, NB, KNN, QD VE DVM uygulanmış olup elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Bu sonuçlar incelendiğinde KA, NB, KNN, QD ve DVM makine öğrenme yöntemlerinin

diğer yöntemlere göre daha başarılı olduğu gözlenmiştir. En başarılı yöntem %68,0 başarı ile Quadratic Discriminant modelidir. Çalışmada kullanılan makine öğrenmesi yöntemlerinin karşılaştırma sonuçları Şekil 4.22’de verilmiştir.




Şekil 26. DD polarizasyon artan (ascend) yörüngedeki makine öğrenimi sonuçları

Yukardaki şekilde elde edilen sayısal değerler Çizelge 4.4’te verilmiştir.

Çizelge 4.4. DD Polarizasyon artan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri


Sınıflandırma Yöntemi	Doğruluk % (Accuracy)	Hassasiyet % (Precision)	Duyarlılık % (Recall)	F1 Skor % (F1 Score)
Quadratic Discriminant	68,0%	72,6%	68,0%	66,3%
Naive Bayes	68,0%	72,6%	68,0%	66,3%
Destek Vektör Makineleri (DVM)	67,8%	72,1%	67,8%	66,1%
Karar Ağacı	65,2%	68,6%	65,2	63,6
KNN	64,8%	70,7%	64,8%	62,0%

Ayrıca, en başarılı yöntem olarak belirlenen Quadratic Discriminant makine öğrenmesi yöntemine ait konfüzyon matrisi ve ROC eğrisi Şekil 4.23'te verilmiştir.




Şekil 27. Quadratic Discriminant konfüzyon Matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.24'te Naive Bayes algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 28. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.25'te DVM algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 29. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.26'da Karar ağacı algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.



Şekil 30. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.27’de KNN algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 31. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

4.1.6. DY-DD polarizasyon azalan ve artan yörüngedeki makine öğrenimi sonuçları

Bu aşamada, 200 adet yüksek gerilim direğine ve 200 adet rastgele seçilen noktalara ait Sentinel-1 uydusu DY-DD polarizasyon veriseti, GEE platformu kullanılarak oluşturulmuştur. Bu verisetine, çalışmada farklı makine öğrenmesi yöntemleri KA, NB, KNN, QD VE DVM uygulanmış olup elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Bu sonuçlar incelendiğinde KA, NB, KNN, QD ve DVM makine öğrenme yöntemlerinin diğer yöntemlere göre daha başarılı olduğu gözlenmiştir. En

başarılı yöntem %85,0 başarı ile Destek Vektör Makinesi modelidir. Çalışmada kullanılan makine öğrenmesi yöntemlerinin karşılaştırma sonuçları Şekil 4.28’de verilmiştir.




Şekil 32. DY-DD polarizasyon artan ve azalan yörüngedeki makine öğrenimi sonuçları

Yukardaki şekilde elde edilen sayısal değerler Çizelge 4.5’te verilmiştir.

Çizelge 4.5. DY-DD Polarizasyon artan ve azalan yörüngedeki makine öğrenmesi yöntemleri ile elde edilen performans parametre değerleri


Sınıflandırma Yöntemi	Doğruluk % (Accuracy)	Hassasiyet % (Precision)	Duyarlılık % (Recall)	F1 Skor % (F1 Score)
Destek Vektör Makineleri	85.0 %	85.5%	85.0%	84.9%
Quadratic Discriminant	82.5%	83.9%	82.5%	82.3%
KNN	82.2%	82.4%	82.2%	82.2%
Karar Ağacı	76.8%	76.8%	76.8%	76.7%
Naive Bayes	74.0%	75.3%	74.0%	73.7%

Ayrıca, en başarılı yöntem olarak belirlenen Destek Vektör Makinesi yöntemine ait konfüzyon matrisi ve ROC eğrisi Şekil 4.29’da verilmiştir.




Şekil 33. DVM konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.30’da Quadratic Discriminant algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 4.30. Quadratic Discriminant konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.31’de KNN algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.




Şekil 34. KNN konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.32’de Karar ağacı algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.



Şekil 35. Karar Ağacı (DT) konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Şekil 4.33'te Naive Bayes algoritmasına ait konfüzyon matrisi ve ROC eğrisi verilmiştir.



Şekil 36. Naive Bayes konfüzyon matrisi (sol) ve ROC eğrisi (sağ)

Çalışmada Sentinel-1 uydusunun artan ve azalan yörüngelerde veri toplayan DY, DD polarizasyon değerlerinden tek bir veri seti oluşturulup makine öğrenmesi yöntemleriyle incelenmiş olup başarı oranları %85, %82.5, %82.2, %76.8 ve %74.0 değerleri elde edilmiştir. Çalışmada en başarılı makine öğrenmesi yöntemi, %85 başarı oranı elde edilen Destek Vektör Makinesi modelidir. Tek bant ile elde edilen makine öğrenmesi sonuçları incelendiğinde; DY-DD artan ve azalan yörünge verileriyle oluşturulan veri seti makine öğrenmesi yöntemlerinin başarı oranlarının daha yüksek olduğu görülmüştür.

5. SONUÇLAR VE ÖNERİLER

Bu bölümde çalışmada ulaşılan sonuçlara yer verilmiş olup araştırma ile ilgili öneriler aktarılmıştır.

5.1 Sonuçlar

Çalışmanın ana odağı; Sentinel-1 SAR uydu görüntüleri ve makine öğrenme teknikleri kullanarak Batman çevresindeki yüksek gerilim hattı direklerini tespit etmek ve bu verileri karşılaştırmalı olarak analiz etmektir. Bu çalışma, enerji nakil hatlarının güvenli ve verimli bir şekilde izlenmesi ve bakımı için uzaktan algılama ve makine öğrenmesi tekniklerinin potansiyelini ortaya koymayı amaçlamaktadır. Bu sayede, enerji altyapısının yönetiminde yenilikçi ve etkili çözümler sunulması hedeflenmektedir.

Çalışmanın konusu olarak belirlenen “Uzaktan algılama kullanarak Sentinel-1 uydu görüntülerinden makine öğrenmesi yöntemi ile yüksek gerilim hattı direği tespiti ve bant değerleri analizinin yapılması konusunda yapay zekâ kullanılabilir mi?” araştırma sorusuna çalışma sonucunda uzaktan algılama yöntemleri ve yapay zekâ kullanılarak gerçekleştirilebileceği sonucuna ulaşılmıştır. Uzaktan algılama yöntemleri ve yapay zekâ kullanımı günümüzde giderek yaygın hale gelmeye başlamıştır. Çalışmada yüksek gerilim hatları direklerinin tespitinin gerçekleştirilmesi konusunda uzaktan algılama yöntemleri ile yapay zekânın kullanımı üzerinde durulmuştur.

Çalışmanın giriş kısmında araştırma hakkında genel bilgilere yer verilmiştir. Çalışmanın ikinci kısmında ise araştırma konusu ile ilgili olarak literatür taraması yapılmıştır. Bu bölümde konu çerçevesinde yapılan çalışmalara değinilmiştir. Ayrıca çalışmanın ana kısmı olan çalışmanın temel mantığının anlaşılması adına teorik kısma yer verilmiştir. Bu bölümde kavram tanımlamaları aktarılmıştır. Özellikle de uzaktan algılamanın ve yapay zekânın tanımları bu bölümde yer almaktadır. Üçüncü bölümde çalışmada kullanılan metot ve yöntemlere değinilmiştir. Veri setinin hazırlanması için GEE platformu ve Sentinel-1 uydusu kullanıldığından bu platform ve uydu hakkında bilgiler bu bölümde aktarılmıştır. Çalışmada kullanılan verilerde makine öğrenmesi yöntemlerinden yararlanılmıştır. Sentinel-1 uydusundan elde edilen uydu görüntüleri DY, DD polarizasyon bant değerleri önce tek tek makine öğrenmesi yöntemleri ile analiz edilmiş olup sonrasında yükselen ve alçalan yörüngedeki DY, DD polarizasyon bant

değerleriyle tek bir veri seti oluşturulup makine öğrenmesi yöntemleriyle analiz edilmiştir.

Bu tez çalışmasında, Sentinel-1 uydu görüntüleri ve makine öğrenmesi teknikleri kullanılarak Batman ili ve çevresindeki yüksek gerilim hattı direklerinin tespiti gerçekleştirilmiştir. Çalışmanın ana hedefi, enerji iletim hatlarının güvenli ve verimli bir şekilde izlenmesi ve bakımının yapılabilmesi için uzaktan algılama ve makine öğrenmesi yöntemlerinin potansiyelini ortaya koymaktır.

Sonuçlar, uzaktan algılama verilerinin ve makine öğrenmesi algoritmalarının yüksek doğruluk oranlarıyla yüksek gerilim hattı direklerinin tespitinde etkili olduğunu göstermektedir. Özellikle, kullanılan yöntemlerin direk tespiti için zaman ve maliyet verimliliği sağladığı, aynı zamanda insan müdahalesini minimuma indirerek operasyonel riskleri azalttığı belirlenmiştir.

Çalışmanın bulguları, enerji altyapısının yönetiminde yenilikçi ve etkili çözümler sunma potansiyeline sahip olduğunu ortaya koymaktadır. Ayrıca, elde edilen sonuçlar, enerji nakil hatlarının rutin izlenmesi ve bakımı için geliştirilmiş yöntemlerin uygulanabilirliğini ve güvenilirliğini kanıtlamaktadır. Bu çalışma, gelecekte enerji sektöründe benzer uygulamalar için referans niteliğinde olup, enerji iletim hatlarının yönetiminde yeni yaklaşımlar geliştirilmesine katkıda bulunabilir.

Araştırma kapsamında önerilen yöntemlerin farklı coğrafi bölgelerde ve farklı iklim koşullarında uygulanabilirliği incelenmeli ve daha geniş ölçekli çalışmalarla desteklenmelidir. Bu sayede, enerji iletim hatlarının izlenmesi ve bakımı için daha kapsamlı ve genelleştirilebilir çözümler sunularak yaygınlaştırılması sağlanabilir.

Gelecekte, farklı uydu görüntüleri ve derin öğrenme teknikleriyle önerilen yaklaşımın geliştirilmesi ve performans artırılması hedeflenmektedir.

5.2 Öneriler

Bu çalışmada uzaktan algılama ve makine öğrenmesi teknikleri kullanılarak yüksek gerilim hattı direklerinin tespiti gerçekleştirilmiştir. GEE platformu vasıtasıyla ulaşılan veriler Excel ortamında düzenlenerek makine öğrenmesi için uygun veri seti haline getirilmiştir. Çalışmada uygulanan farklı makine öğrenmesi yöntemleri ile başarılı sonuçlar elde edilmiştir.

Makine öğrenmesi yöntemleri kullanarak yüksek gerilim direklerinin tespit edilebileceği sonucuna ulaşılmıştır. Bu çalışma kapsamında, TEİAŞ personelinin yapay zekâ konularında eğitim alarak mevcut yüksek gerilim direklerinin belirli periyotlarla izlenmesini, fırtına, heyelan, çığ, yangın gibi doğal afetlerde yüksek gerilim direklerinin durumunun kontrolünü sağlayarak hızlı reaksiyon göstermesine katkı sağlayacağı önerilmiştir. Bu bakım ve kontrol işlemlerinin geleneksel yöntemlere kıyasla daha hızlı ve daha az maliyetli yapılabileceği belirtilmiştir. Ayrıca, yeni yapılan yüksek gerilim direklerinin 691 sayılı KHK gereği kısa sürede mevcut veritabanına işlenerek, bölgede alçak irtifa uçuş yapan hava araçlarını olası kazalardan koruyabileceği değerlendirilmektedir.

Çalışmada Sentinel-1 uydusu ve farklı makine yöntemleri kullanılarak yüksek gerilim direği tespiti yapılmıştır. Farklı uydu görüntüleri ve derin öğrenme tekniklerinin kullanımıyla önerilen yaklaşımın daha da geliştirilmesi ve performansının artırılması önerilmiştir. Daha yüksek çözünürlüklü ve çeşitli uydu görüntüleri kullanılarak analiz edilen veri setlerinin sayısı, kapsamı ve hassasiyeti artırılacaktır. İlerde yapılacak olan çalışmalarda yüksek gerilim direklerinin merkez nokta olmak üzere belli bir çapta tampon daireler oluşturulup bu dairelerin saçılma değerlerinin ortalaması alınarak, yüksek gerilim direklerinin tespitinde daha yüksek doğruluk oranları elde edilmesi önerilmiştir. Böylece, sistemin genel verimliliği ve güvenilirliği artırılarak uzaktan algılama tabanlı enerji altyapısı izleme süreçlerine önemli katkılar sağlayacağı değerlendirilmiştir.

KAYNAKLAR

- Abdikan, S., Sanli, F. B., Ustuner, M., & Calò, F. (2016). Land cover mapping using sentinel-1 SAR data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 757-761.
- Acar, E. (2020). Makine öğrenmesi yaklaşımlarıyla Sentinel-1 SAR görüntüleri yardımıyla tarım alanlarındaki kayıt dışı elektrik dağıtım trafolarının tespiti. *Tarımda Bilgisayarlar ve Elektronik*, 175, 105559.
- Acar, E., & Altun, M. (2021). Classification of the agricultural crops using landsat-8 NDVI parameters by support vector machine. *Balkan Journal of Electrical and Computer Engineering*, 9(1), 78-82.
- Açıksarı, E., & Akçay, Ö. (2018). İkili PolSAR görüntülerinin çok zamanlı ayrışma ve kontrolsüz sınıflandırma analizi. *Çanakkale Onsekiz Mart Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 4(2), 69-87.
- Akerkar, R. (2014). *Introduction to artificial intelligence*. London: PHI Learning Press.
- Albert, R., Albert, I., & Nakarado, G. L. (2004). Structural vulnerability of the North American power grid. *Physical review E*, 69(2), 025103.
- Ambika, (2023), "Support Vector Machine (SVM) Algorithm: Explained", [online], Medium, Support Vector Machine (SVM) Algorithm: Explained, [Erişim Tarihi: 11.01.2025].
- Babagiray, S., & Kalkan, K. (2021). Yağışların tarım alanlarında sebep olduğu göllenmelerin Sentinel-1 uydu görüntüleri ile analizi. *Jeodezi ve Jeoinformasyon Dergisi*, 8(2), 145-160.
- Badrinarayan, V., Kendall, A. ve Cipolla, R., (2015). "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation", arXiv preprint arXiv:1511.00561, 2015.
- Bağcı, R. Ş., Acar, E., & Türk, Ö. (2023). Identification of cotton and corn plant areas by employing deep transformer encoder approach and different time series satellite images: A case study in Diyarbakir, Turkey. *Computers and Electronics in Agriculture*, 209, 107838.
- Balzter, H., Cole, B., Thiel, C., & Schmullius, C. (2015). Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using random forests. *Remote Sensing*, 7(11), 14876-14898.
- Başarsoft, "Uzaktan algılama", [online], Uzaktan Algılama Nedir? - Kullanım Alanları | Başarsoft (basarsoft.com.tr), [Erişim Tarihi: 16.07.2024].
- Bayes, T. (1968). Naive bayes classifier. *Article Sources and Contributors*, 1-9.

- Beauxis-Aussalet, E., & Hardman, L. (2014, November). Simplifying the visualization of confusion matrix. In 26th Benelux conference on artificial intelligence (BNAIC).
- Bergil, E. (2018). EEG işaretlerinin epileptik nöbet kestiriminde modern yöntemlerle analizi ve sınıflandırılması.
- Berrar, D. (2019). Cross-validation.
- Carreño Conde, F., & De Mata Muñoz, M. (2019). Flood monitoring based on the study of Sentinel-1 SAR images: The Ebro River case study. *Water*, 11(12), 2454.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215.
- Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20-28.
- Cortes, C. (1995). Support-Vector Networks. *Machine Learning*.
- Coxe, S., West, S. G., & Aiken, L. S. (2013). Generalized linear models. *The Oxford handbook of quantitative methods*, 2, 26-51.
- Crisp, D. J. (2004). The state-of-the-art in ship detection in synthetic aperture radar imagery.
- Desai, G., & Gaikwad, A., (2022), Automatic land cover classification with SAR imagery and Machine learning using Google Earth Engine. *International Journal of Electrical and Computer Engineering Systems*, 13(10), 909-916.
- Dickinson C., Siqueira P., Clewley D., Lucas R., 2013. Classification of forest composition using polarimetric decomposition in multiple land scapes. *Remote sensing of environment*, 131:206-21.
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning? (pp. 3-11). Springer International Publishing.
- Encord, “Confusion matrix”. [online], Encord, Confusion matrix, [Erişim Tarihi: 11.01.2025].
- Erbaş, M. (2016). LiDAR Verilerinden Enerji Nakil Hatlarının Otomatik Tespit Edilmesi Çalışmaları. *Harita Dergisi*, 156, 32-40.
- ESA 2017, “Sentinels bring solutions to pipeline monitoring.”, [online], The European Space Agency, Sentinels bring solutions to pipeline monitoring, [Erişim Tarihi: 11.01.2025].

- EvidentlyAI, “How to explain the ROC curve and ROC AUC score?”, [online], EvidentlyAI, How to explain the ROC curve and ROC AUC score, [Erişim Tarihi: 11.01.2025].
- Faur, D., Espinoza-Molina, D., Gavat, I., & Datcu, M. (2013). Multi Temporal Analysis of Floods and Tsunami Effects: Annotation and Quantitative Analysis. In MultiTemp 2013 Conference Proceedings (pp. 1-4). IEEE Xplore.
- Fawcett, T. (2006). An introduction to ROC analysis. Pattern recognition letters, 27(8), 861-874.
- Feizizadeh, B., Omarzadeh, D., Kazemi Garajeh, M., Lakes, T., & Blaschke, T. (2023). Machine learning data-driven approaches for land use/cover mapping and trend analysis using Google Earth Engine. Journal of Environmental Planning and Management, 66(3), 665-697.
- Fix, E. (1985). Discriminatory analysis: nonparametric discrimination, consistency properties (Vol. 1). USAF school of Aviation Medicine.
- GeeksforGeeks, “Understanding logistic regression”, [online], GeeksforGeeks, Understanding logistic regression, [Erişim Tarihi: 11.01.2025].
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote sensing of Environment, 202, 18-27.
- Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. Radiology, 143(1), 29-36.
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., ... & Townshend, J. R. (2013). High-resolution global maps of 21st-century forest cover change. science, 342(6160), 850-853.
- Hatipoğlu, A., Güneri, Y., & Yılmaz, E. (2024). Makine ve derin öğrenme temelli karşılaştırmalı bir öngörücü bakım uygulaması. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 39(2), 1037-1048.
- H. Mojaddadi, B. Pradhan, H. Nampak, N. Ahmad, and A. H. bin Ghazali, “Ensemble machine-learning-based geospatial approach for flood risk assessment using multi-sensor remote-sensing data and GIS,” Geomatics, Natural Hazards and Risk, vol. 8, no. 2, pp. 1080–1102, Dec. 2017, doi: 10.1080/19475705.2017.1294113.
- IBM, “What is the KNN algorithm?”, [online], IBM, What is the k-nearest neighbors (KNN) algorithm?, [Erişim Tarihi: 11.01.2025].
- ,Javatpoint, “Machine learning- Support vector machine (SVM) algorithm”, [online], Javatpoint, Support vector machine (SVM) algorithm, [Erişim Tarihi: 11.01.2025].
- Jiao Licheng, Liu Fang, et al. Intelligent SAR Image Processing and Interpretation [M]. Science Press, 2008.

- Jwa, Y., Sohn, G., & Kim, H. B. (2009). Automatic 3d powerline reconstruction using airborne lidar data. *Int. Arch. Photogramm. Remote Sens*, 38(Part 3), W8.
- Kadı, F., & Yılmaz, O. S. (2024). Orman içi açıklıklara ait zamansal değişimlerin uzaktan algılama teknikleri ile Google Earth Engine platformunda tespit edilmesi: Trabzon-Düzköy İlçesi örneği. *Geomatik*, 9(2), 141-155.
- Karabacak, A. (2021). İnsansız hava araçları (İHA) İle enerji nakil hatlarının ölçülmesi üzerine derleme. *Türkiye Fotogrametri Dergisi*, 3(1), 1-8.
- Karataş, L., Alptekin, A., & Yakar, M. (2023). Investigating the limestone quarries as geoheritage sites: Case of Mardin ancient quarry. *Open Geosciences*, 15(1), 20220473.
- Kavzoğlu, T. ve Çölkesen, İ., 2011. Uzaktan algılama teknolojileri ve uygulama alanları.
- Ko, C., Remmel, T. K., & Sohn, G. (2012). Mapping tree genera using discrete LiDAR and geometric tree metrics. *Bosque*, 33(3), 313-319.
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3-10.
- Luque-Vega, L. F., Castillo-Toledo, B., Loukianov, A., & Gonzalez-Jimenez, L. E. (2014, April). Power line inspection via an unmanned aerial system based on the quadrotor helicopter. In *MELECON 2014-2014 17th IEEE Mediterranean electrotechnical conference* (pp. 393-397). IEEE.
- Matikainen, L., Lehtomäki, M., Ahokas, E., Hyypä, J., Karjalainen, M., Jaakkola, A., Kukko, A. ve Heinonen, T., 2016. Remote sensing methods for power line corridor surveys. *ISPRS Journal of Photogrammetry and Remote Sensing*, 119, 10-31.
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International journal of remote sensing*, 39(9), 2784-2817.
- Mechtekno, “makine öğrenimi nedir nasıl çalışır.”, [online], Makine Öğrenimi Kullanım Alanları, [Erişim Tarihi: 06.02.2025].
- Medium, 2017, “Makine Öğrenimi Karar Ağaçları”, [online], Makine Öğrenimi Karar Ağaçları, [Erişim Tarihi: 06.02.2025].
- Mleczko, M. ve Mróz, M. (2018). Sentinel-1A ve TanDEM-X Görevlerinden SAR Verilerini Kullanarak Sulak Alan Haritalama: Biebrza Taşkın Ovasında (Polonya) Karşılaştırmalı Bir Çalışma. *Uzaktan Algılama*, 10 (1), 78.
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing*, 66(3), 247-259.

- Muş, E. (2019). LiDAR verileri kullanılarak enerji nakil hatlarının ve hatlara risk oluşturan yüksek obje konumlarının otomatik olarak belirlenmesi (Master's thesis, Fen Bilimleri Enstitüsü).
- Nagler, T., Rott, H., Hetzenecker, M., Wuite, J., & Potin, P. (2015). The Sentinel-1 mission: New opportunities for ice sheet observations. *Remote Sensing*, 7(7), 9371-9389.
- Pal, M., and P. M. Mather. 2003. "An Assessment of the Effectiveness of Decision Tree Methods for Land Cover Classification." *Remote Sensing of Environment* 86: 554–565.
- Pannu, A. (2015). Artificial intelligence and its application in different areas. *Artificial Intelligence*, 4(10), 79-84.
- Qiao, S., Sun, Y. ve Zhang, H. (2020). Uzaktan Algılama Görüntülerinde Derin Öğrenme Tabanlı Elektrik Pilonu Algılama. *Uzaktan Algılama* , 12 (11), 1857.
- Quinlan, J. R. (1996). Learning decision tree classifiers. *ACM Computing Surveys (CSUR)*, 28(1), 71-72.
- Roychowdhury, K. (2016). Comparison between spectral, spatial and polarimetric classification of urban and periurban landcover using temporal Sentinel–1 images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 789-796.
- Sağlam, F., Yıldırım, E., & Cengiz, M. A. (2022). Clustered Bayesian classification for within-class separation. *Expert Systems with Applications*, 208, 118152.
- Samui, P. (2012). Application of statistical learning algorithms to ultimate bearing capacity of shallow foundation on cohesionless soil. *International Journal for Numerical and Analytical Methods in Geomechanics*, 36(1), 100-110.
- Sap, "What is machine learning?", [online],SAP, What is machine learning, [Erişim Tarihi: 11.01.2025].
- Sarabandi, K. & Pierce, L.E. & oh, Yutaek & Ulaby, F.T.. (1994). Power Lines: Radar Measurements and Detection Algorithm for Polarimetric SAR Images. *Aerospace and Electronic Systems*, IEEE Transactions on.
- Solmaz, B. Makine öğrenme yöntemleriyle uydu görüntülerinin sınıflandırılması ve zamansal değişiminin izlenmesi.
- Stone, M. (1974). Cross-validatory choice and assessment of statistical predictions. *Journal of the royal statistical society: Series B (Methodological)*, 36(2), 111-133.
- Şanlı, F. B. Ahmet Batuhan Polat.
- Şenol H. İ. (2023). Gelişmiş Deniz Gözlemi: SAR Tabanlı Gemi Tespiti için CNN Algoritmalarının Kullanımı. *Türkiye LiDAR Dergisi*, 5(1), 01-07.

- Şimşek, F. F. (2024). Optik ve radar görüntüleri ile aşırı gradyan artırma algoritması kullanılarak tarımsal ürün desen tespiti. *Geomatik*, 9 (1), 54-68.
- Talentcoders,2023, “Machine learning hakkında her sey”, [online], Talentcoders, Machine Learning Nedir, [Erişim Tarihi: 06.02.2025].
- Turknet,2023, “İşinizi Hızlandıracak En İyi Yapay Zekâ Uygulamaları”, [online], Turknet, İşinizi Hızlandıracak En İyi Yapay Zekâ Uygulamaları [Erişim Tarihi: 06.02.2025].
- T. Hastie, R. Tibshirani, and J. Friedman. *The Elements of Statistical Learning*. Springer-Verlag, New York, 2001.
- Tian, G., Meng, S., Bai, X., Zhi, Y., Ou, W., Fei, X., & Tan, Y. (2020). Electric tower target identification based on high-resolution SAR image and deep learning.
- Vapnik, V. (2013). *The nature of statistical learning theory*. Springer science & business media.
- Wahap, N. A., & Shafri, H. Z. (2020, July). Utilization of Google earth engine (GEE) for land cover monitoring over Klang Valley, Malaysia. In *IOP Conference Series: Earth and Environmental Science* (Vol. 540, No. 1, p. 012003). IOP Publishing.
- Wu, Q., & Zhou, D. X. (2006). Analysis of support vector machine classification. *Journal of Computational Analysis & Applications*, 8(2).
- Xiong, W., Luo,J. & Yu, C.(2021). Power line detection in milimetre-wave radar images applying convolutional neural networks.*IET Radar,Sonar & Navigation*, 15(9), 1083-1095.
- Zha, W., Hu, L., Duan, C., & Li, Y. (2023). Semi-supervised learning-based satellite remote sensing object detection method for power transmission towers. *Energy Reports*, 9, 15-27.
- Zeybek, M. (2018). Estimation of powerline route from airborne lidar. *power*, 1, 6.