



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**SENTİNEL-1 SAR GÖRÜNTÜLERİNİN, DERİN ÖĞRENME
TEKNİKLERİ KULLANILARAK MÜSİLAJ BÖLGELERİNİN OTOMATİK
OLARAK TESPİT EDİLMESİNDEKİ ROLÜ: MARMARA DENİZİ
ARMUTLU-ZEYTİNBAĞI'NDA BİR VAKA ÇALIŞMASI**

Enes BAKIŞ

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz-2023
BATMAN
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Enes BAKIŞ tarafından hazırlanan “SENTİNEL-1 SAR GÖRÜNTÜLERİNİN, DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK MÜSİLAJ BÖLGELERİNİN OTOMATİK OLARAK TESPİT EDİLMESİNDEKİ ROLÜ: MARMARA DENİZİ ARMUTLU-ZEYTİNBAGI'NDA BİR VAKA ÇALIŞMASI” adlı tez çalışması 04/07/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Unvanı Adı SOYADI

.....

Danışman

Unvanı Adı SOYADI

.....

Üye

Unvanı Adı SOYADI

.....

Üye

Unvanı Adı SOYADI

.....

Üye

Unvanı Adı SOYADI

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BİLDİRİMİ

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 bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Enes BAKIŞ

Tarih:05.07.2023

ÖZET

YÜKSEK LİSANS TEZİ

SENTİNEL-1 SAR GÖRÜNTÜLERİNİN, DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK MÜSİLAJ BÖLGELERİNİN OTOMATİK OLARAK TESPİT EDİLMESİNDEKİ ROLÜ: MARMARA DENİZİ ARMUTLU- ZEYTİNBAGI'NDA BİR VAKA ÇALIŞMASI

Enes BAKIŞ

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Emrullah ACAR

2023, 68 Sayfa

Jüri

Doç. Dr. Emrullah ACAR
Dr. Öğr. Üyesi Yılmaz KAYA
Dr. Öğr. Üyesi Mustafa ÜSTÜNER

Doğada bulunan çeşitli nesnelerin tespit edilmesi, türlerin tanımlanması ve bu türlerin keşfedilmesi günümüz dünyasında büyük önem arz etmektedir. Aktif ve pasif görüntüleme sistemleri bu doğrultuda hem ekonomik hem de kolaylık bakımından avantajlı bir konumdadır. Son zamanlarda ülkemizde yaşanan müsilaj olayları hem deniz yaşamı hem de insan hayatı için ciddi riskler oluşturmaktadır. Bu çalışmada obje olarak Mayıs 2021'de meydana gelen müsilaj olayından büyük ölçüde etkilenen bölgelerden birindeki su alanları seçilmiştir. Çalışma alanı olarak Marmara Denizi'nde Armutlu-Zeytinbağı arasındaki bölge seçilmiştir. Müsilaj bölgesinden toplam 1300 örnek manuel olarak seçilmiş ve GPS yardımıyla kayıt altına alınmıştır. Seçilen bu örnekler 17 Mayıs–22 Mayıs arası müsilajlı alan, 21 Haziran–22 Haziran arası temiz alan olarak (toplam 2600 örnek) seçildikten sonra Sentinel-1 uydu görüntüleri yardımıyla zaman serileri kullanılarak görüntü analizleri yapılmıştır. Bu görüntü analizleri, Sentinel-1 spektral bant parametreleri (VV-VH) kullanılarak yapılmıştır. VV-VH spektral bant görüntülerinin yansıma değerlerini gösteren sayısal veriler excel ortamına aktararak 2 adet özgün veri seti elde edilmiştir. Elde edilen veri setlerine ayrı ayrı derin öğrenme ve makine öğrenmesi modelleri uygulanarak bu müsilajlı bölgesinin otomatik olarak tespit edilmesi amaçlanmıştır. Uygulamalı derin öğrenme (LSTM, CNN) ve makine öğrenmesi modellerimizin (DT, NB, SVM, RF, SGD) başarısının yüksek (84%-100%) olduğu gözlemlenmiştir. Uygulanan derin öğrenme ve makine öğrenmesi yöntemleri ile müsilaj bölgelerinin daha kolay tespit edilmesi ve bu bölgelere erken müdahale edilmesi amaçlanmıştır.

Anahtar Kelimeler: Derin Öğrenme, Makine Öğrenmesi, Müsilajlı Alan Tespiti, Sentinel-1, Spektral Bant Parametreleri, Uzaktan Algılama

ABSTRACT

MS THESIS

THE ROLE OF SENTINEL-1 SAR IMAGES IN THE AUTOMATIC DETECTION OF MUCILAGE AREAS USING DEEP LEARNING LEARNING TECHNIQUES: A CASE STUDY IN THE ARMUTLU-ZEYTINBAĞI OF THE MARMARA SEA

Enes BAKIŞ

**FACULTY OF ENGINEERING
DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
GRADUATE EDUCATION INSTITUTE
THE DEGREE OF MASTER OF
IN ELECTRICAL AND ELECTRONICS ENGINEERING**

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2023, 68 Pages

Jury

Assoc. Prof. Dr. Emrullah ACAR

Asst. Prof. Dr. Yılmaz KAYA

Asst. Prof. Dr. Mustafa ÜSTÜNER

Detection of various objects in nature, identification of species and discovery of these species are of great importance in today's world. Active and passive imaging systems are in an advantageous position in this direction, both in terms of economy and convenience. Recently, mucilage events in our country pose serious risks to both marine life and human life. In this study, water areas in one of the regions that were greatly affected by the mucilage event that occurred in May 2021 were selected as the object. The region between Armutlu-Zeytinbağı in the Sea of Marmara was chosen as the study area. A total of 1300 samples from the Musilaj region were manually selected and recorded with the help of GPS. After these selected samples were chosen as mucilage area between 17 May and 22 May and as clean area between 21 June and 22 June (2600 samples in total), image analyzes were made using time series with the help of Sentinel-1 satellite images. These images analyze were performed using Sentinel-1 spectral band parameters (VV-VH). Numerical data showing the reflectance values of VV-VH spectral band images were transferred to excel and 2 original data sets were obtained. It is aimed to automatically detect this mucilage region by applying deep learning and machine learning models separately to the obtained data sets. It has been observed that the success of our applied deep learning (LSTM, CNN) and machine learning models (DT, NB, SVM, RF, SGD) is high (84%-100%). With the applied deep learning and machine learning methods, it is aimed to detect mucilage regions more easily and to intervene in these regions early.

Keywords: Deep Learning, Machine Learning, Mucilage Field Detection, Sentinel-1, Spectral Band Parameters, Remote Sensing

ÖNSÖZ

Yüksek Lisans Tez çalışma sürecimde her türlü yol gösterici olan, ilgili ve olumlu tavırlarıyla beni cesaretlendiren, gerekli tüm donanımlarını hiç düşünmeden benimle paylaşan, ufkumu genişleten ve uzaktan algılamaya farklı bir açıdan bakmamı sağlayan, beraber çalışmaktan ve her zaman öğrencisi olmaktan gurur duyduğum çok değerli sayın danışman hocam Doç. Dr. Emrullah ACAR'a sonsuz teşekkürlerimi sunarım.

Bu çalışmadaki zamanın çoğunun geçtiği yer olan GEE-CE (Google Earth Engine- Code Editor) platformu kurucularına ve bu platformda kullandığım Sentinel-1 Uydu verileri için ESA (European Space Agency)'ya teşekkürlerimi sunarım.

Son olarak tüm hayatım boyunca beni destekleyen, maddi ve manevi olarak sürekli yanımda olan ve akademik hayata teşvikimi sağlayan babam Doç. Dr. Abdulrezzak BAKIŞ'a, annem Süheyla BAKIŞ'a sonsuz şükranlarımı sunar ve teşekkür ederim.

Enes BAKIŞ
BATMAN-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGE LİSTESİ.....	viii
ŞEKİLLER LİSTESİ	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	7
3.1. Deney Alanı	7
3.2. Sentinel-1 Uydu Verisi Toplama	8
3.3. Nesne Verisi Toplama	9
3.3.1 Sentinel-1 Uydu Özellikleri ve İşleyişi	10
3.3.2. Google Earth Engine-Code Editor (GEE-CE) Platform Yapısı ve İşleyişi ..	13
3.4. Nesne Verilerinin Özellik Çıkarımı (Feature Extraction).....	14
3.5. Ön İşlem Süreci ve Veri Setinin Oluşturulması.....	14
3.6. Uygulanan Yöntemler.....	16
3.6.1. Uygulanan Makine Öğrenmesi Yöntemleri	16
3.6.2. Uygulanan Derin Öğrenme Yöntemleri.....	23
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	26
4.1. VV Bandına Ait Sonuçlar	28
4.1.1. Makine Öğrenmesi Sonuçları	28
4.1.2. Derin Öğrenme Sonuçları	31
4.2. VH Bandına Ait Sonuçlar	34
4.1.1. Makine Öğrenmesi Sonuçları	34
4.2.2. Derin Öğrenme Sonuçları	37
4.3. VV + VH Bandına Ait Sonuçlar	40
4.3.1. Makine Öğrenmesi Sonuçları	40
4.3.2. Derin Öğrenme Sonuçları	43
5. SONUÇLAR VE ÖNERİLER	49
5.1 Sonuçlar	50
5.2 Öneriler	50
KAYNAKLAR	53
ÖZGEÇMİŞ	56

ÇİZELGE LİSTESİ

Tablo 3.1. Sentinel-1 uydusu spektral bant parametreleri özellikleri (Conradsen ve ark. 2003)	13
Tablo 3.2. Veri setlerine uygulanan modellerin yüzdece başarı oranları.....	48
Tablo 3.3. Uydu görüntülerin yardımıyla müsilaçlı bölge üzerinde nesne tespiti üzerine yapılan çalışmaların karşılaştırılması.....	48

ŞEKİLLER LİSTESİ

Şekil 3.1. İş akış diyagramı	7
Şekil 3.2. Çalışma alanı Google Earth uydu görüntüsü.....	8
Şekil 3.3. Çalışma alanının Sentinel-1 uydusu VV bant görüntüsü	8
Şekil 3.4. Çalışma alanının Sentinel-1 uydusu VH bant görüntüsü	9
Şekil 3.5. Seçilen 1300 adet noktanın ham görüntüsü.....	9
Şekil 3.6. Seçilen 1300 adet noktanın Sentinel-1 uydusu VV bant görüntüsü.....	10
Şekil 3.7. Seçilen 1300 adet noktanın Sentinel-1 uydusu VH bant görüntüsü.....	10
Şekil 3.8. Sentinel-1 Modları (European Space Agency, 2023).....	12
Şekil 3.9. VV bandı için oluşturulan veri seti.....	15
Şekil 3.10. VH bandı için oluşturulan veri seti.....	16
Şekil 3.11. SVM mimarisi (AKCA, 2020)	17
Şekil 3.12. Karar Ağaçları mimarisi (Ulgen, 2017)	19
Şekil 3.13. Naive Bayes mimarisi (Sawla, 2018)	20
Şekil 3.14. KNN mimarisi (Ulgen, 2017).....	21
Şekil 3.15. SGD mimarisi (Akıncı, 2021)	22
Şekil 3.16. Rastgele Orman mimarisi (Tafralı, 2022)	23
Şekil 3.17. CNN mimarisi (Ergin, 2018).....	24
Şekil 3.18. LSTM mimarisi (Choubey, 2020).....	25
Şekil 3.19. VV veri setinin dağılımı	26
Şekil 3.20. VH veri setinin dağılımı	27
Şekil 3.21. VV+VH veri seti dağılımı	27
Şekil 3.22. VV bandı için kullanılan KNN modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	28
Şekil 3.23. VV bandı için kullanılan DT modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	29
Şekil 3.24. VV bandı için kullanılan NB modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	29
Şekil 3.25. VV bandı için kullanılan SVM modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	30
Şekil 3.26. VV bandı için kullanılan SGD modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	30
Şekil 3.27. VV bandı için kullanılan RF modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	31
Şekil 3.28. VV bandı için kullanılan CNN modelindeki katmanlar ve çıkış boyutları ..	31
Şekil 3.29. VV bandı için kullanılan CNN modelindeki döngü sayısı 10 için sistemin doğruluk ve kayıp grafikleri	32
Şekil 3.30. VV bandı için kullanılan CNN modelindeki (a) döngü sayısı 5 (b) döngü sayısı 10 (c) döngü sayısı 20 (d) döngü sayısı 15 için kayıp ve doğruluk değerleri.....	32
Şekil 3.31. VV bandı için kullanılan LSTM modelindeki katmanlar ve çıkış boyutları	33
Şekil 3.32. VV bandı için kullanılan LSTM modelindeki döngü sayısı 2 için sistemin doğruluk ve kayıp grafikleri	33
Şekil 3.33. VV bandı için kullanılan LSTM modelindeki (a) döngü sayısı 1 (b) döngü sayısı 3 (c) döngü sayısı 7 (d) döngü sayısı 5 için kayıp ve doğruluk değerleri.....	34
Şekil 3.34. VH bandı için kullanılan KNN modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	35
Şekil 3.35. VH bandı için kullanılan DT modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	35
Şekil 3.36. VH bandı için kullanılan NB modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	35

Şekil 3.37. VH bandı için kullanılan SVM modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	36
Şekil 3.38. VH bandı için kullanılan SGD modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	36
Şekil 3.39. VH bandı için kullanılan RF modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı	37
Şekil 3.40. VH bandı için kullanılan CNN modelindeki katmanlar ve çıkış boyutları ..	37
Şekil 3.41. VH bandı için kullanılan CNN modelindeki döngü sayısı 10 için sistemin doğruluk ve kayıp grafikleri	38
Şekil 3.42. VH bandı için kullanılan CNN modelindeki (a) döngü sayısı 5 (b) döngü sayısı 10 (c) döngü sayısı 20 (d) döngü sayısı 15 için kayıp ve doğruluk değerleri.....	39
Şekil 3.43. VH bandı için kullanılan LSTM modelindeki katmanlar ve çıkış boyutları	39
Şekil 3.44. VH bandı için kullanılan LSTM modelindeki döngü sayısı 3 için sistemin doğruluk ve kayıp grafikleri	39
Şekil 3.45. VH bandı için kullanılan LSTM modelindeki (a) döngü sayısı 1 (b) döngü sayısı 3 (c) döngü sayısı 7 (d) döngü sayısı 5 için kayıp ve doğruluk değerleri.....	40
Şekil 3.46. VV+VH bant verilerini içeren veri seti için kullanılan KNN modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranları	41
Şekil 3.47. VV+VH bandı için kullanılan DT modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı.....	41
Şekil 3.48. VV+VH bandı için kullanılan NB modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı.....	42
Şekil 3.49. VV+VH bandı için kullanılan SVM modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı.....	42
Şekil 3.50. VV+VH bandı için kullanılan SGD modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı.....	43
Şekil 3.51. VV+VH bandı için kullanılan RF modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı.....	43
Şekil 3.52. VV+VH bandı için kullanılan CNN modelindeki katmanlar ve çıkış boyutları	44
Şekil 3.53. VV+VH bandı için kullanılan CNN modelindeki döngü sayısı 10 için sistemin doğruluk ve kayıp grafikleri	45
Şekil 3.54. VV+VH bandı için kullanılan CNN modelindeki (a) döngü sayısı 5 (b) döngü sayısı 10 (c) döngü sayısı 20 (d) döngü sayısı 15 için kayıp ve doğruluk değerleri	45
Şekil 3.55. VV+VH bandı için kullanılan LSTM modelindeki katmanlar ve çıkış boyutları	46
Şekil 3.56. VV+VH bandı için kullanılan LSTM modelindeki döngü sayısı 3 için sistemin doğruluk ve kayıp grafikleri	46
Şekil 3.57. VV+VH bandı için kullanılan LSTM modelindeki (a) döngü sayısı 1 (b) döngü sayısı 3 (c) döngü sayısı 7 (d) döngü sayısı 5 için kayıp ve doğruluk değerleri..	47

SİMGELER VE KISALTMALAR

VV:	Dikey Gönderme/Dikey Alma
VH:	Dikey Gönderme/Yatay Alma
HH:	Yatay Gönderme/Yatay Alma
HV:	Yatay Gönderme/Dikey Alma
SAR:	Sentetik Açıklıklı Radar
SGD:	Stokastik Dereceli Azalma
SVM:	Destek Vektör Makinaları
RF:	Rastgele Orman
NB:	Naive Bayes
DT:	Karar Ağaçları
KNN:	K-En Yakın Komşuluk
TT&C:	Telemetry ve Kontrol Sistemi
LSTM:	Tekrarlayan Sinir Ağları
CNN:	Evrişimli Sinir Ağları
GPS:	Küresel Konumlandırma Sistemi
GEE:	Google Earth Engine
GEE-CE:	Google Earth Engine-Code Editor
AVHRR:	Gelişmiş Çok Yüksek Çözünürlüklü Radyometre
OBIA:	Nesne Tabanlı Görüntü Analizi
ELM:	Aşırı Öğrenme Makinaları
EDT:	Transformatör
Grad-CAM:	Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama
CSAR:	C-Bandı Açık Sentetik Açıklıklı Radar
SW:	Şerit Haritası Modu
IM:	İnterferometrik Geniş Alan Modu
EW:	Ekstra Geniş Alan Modu
WV:	Dalga Modu
API:	Uygulama Programlama Arayüzü
UA:	Uzaktan Algılama
LR:	Lojistik Regresyon
ROC:	İşletim Karakteristiği Alıcı
LSTM:	Uzun Kısa Süreli Bellek

GB: GigaBayt

W: Watt

Ah: Amper Saat

Kbit/s: Saniyedeki Kilo bit Ykleme Hızı

M: Metre

Km²: Kilometre Kare

Mm: Milimetre

Kg: Kilogram

Km: Kilometre

Mbit/s: Saniyedeki Mega Bit Ykleme Hızı

1. GİRİŞ

Marmara Denizi'ndeki müsilaj sorunu ilk olarak Ekim 2007'de ortaya çıkmıştır. Balıkçıların "deniz salyası" olarak adlandırdıkları bu oluşum, yoğun yapısı nedeniyle su ürünleri avcılığının önünde engel oluşturmaktadır. Ayrıca müsilaj olayı Marmara Denizi'ndeki tür çeşitliliğini de ciddi şekilde etkilemektedir (Garipağaoğlu Uğur ve Dinçer 2022).

Deniz Salyası adı ile bilinen bu oluşum denizin dip kısımlarına inerek burada bulunan deniz bitkilerini etkilemektedir. Deniz yosunu toprağın su tutması ve tanecikli bir yapıda olmasını sağlayan bir deniz bitkisidir. Bu göreviyle bitkilerin kök sistemleri için önemli olan yararlı mikroorganizmaların sayısını arttırmaktadır. Fakat müsilaj olayı deniz yosunu gibi deniz bitkilerini olumsuz etkilemektedir. Bu da deniz ekosisteminde dengesizliklere sebep olmaktadır. Özetle müsilaj denizdeki varoluşsal dengeyi bozmaktadır.

Mayıs 2021'de Marmara Denizi'nde müsilaj olayının ciddi boyutlara ulaştığı görülmektedir. Bu kapsamda müsilaj alanlarının erken tespiti deniz ekosistemi ve balıkçılık faaliyetlerinin sürdürülebilirliği gibi olaylar için hem zamansal hem de ekonomik açıdan önem taşımaktadır.

Doğada bulunan çeşitli nesne ve türlerin tanımlanması, otomatik olarak saptanması ve bu nesnelerin özelliklerinin çıkarılması günümüz dünyasında sıklıkla kullanılmakta ve büyük önem arz etmektedir. Aktif ve pasif görüntüleme sistemleri bu doğrultuda hem maliyet hem de kolaylık açısından avantajlı konumdadır. Sentinel-1 uydusu da aktif bir görüntüleme sistemi aracıdır. Sentinel-1 uydusu, ürettiği elektromanyetik sinyalleri antenleri aracılığıyla yaymakta ve görüntülediği yüzey alanından yansıyan sinyalleri üzerinde bulunan antenler aracılığıyla toplamaktadır. Ayrıca, Sentinel-1 uydusu elektromanyetik sinyal kullandığı için atmosferik olaylar ve hava durumlarından etkilenmemektedir. Aktif bir sensör olduğundan dolayı da hem gündüz hem gece görüntü alabilmektedir. Sentinel-1 uydusundan alınan tüm görüntülerin piksel çözünürlüğü 10 metredir.

Derin öğrenme ve makine öğrenmesi modellemelerinin uzaktan algılama sistemleri ile kullanılması ile birlikte uzaktan algılama sistemleri günümüzde daha çok kullanılmaya başlanmıştır. Kullanılan derin öğrenme ve makine öğrenmesi modellemeleri ile birçok alanda, çok sayıda veri içeren nesnelerin tespiti büyük ölçüde kolaylaşmaktadır. Ayrıca derin öğrenme ve makine öğrenmesi yöntemleri bu verilerin

modellemeler sonucundaki doğruluk ve başarı oranlarını karşılaştırma açısından etkili bir konuma sahiptir.

Bu çalışma 14-24 Mayıs 2021 tarihlerinde Marmara Denizi Armutlu-ZeytinBağı bölgesinde meydana gelen müsilağ olayını manuel olarak işaretlediğimiz toplam 1300 noktada Sentinel-1 uydusu zaman serilerini kullanarak farklı bantlar (VV-VH) ile elde edilen yansıma değerlerine derin öğrenme ve makine öğrenme modellerini uygulanarak bu müsilağ alanlarının tespit edilebilirliğinin araştırılmasını sunmaktadır.

Bu alanda uygulanan derin öğrenme ve makine öğrenmesi modellerinin başarı oranı çok yüksek bulunmuştur. Bu da müsilağ bölgelerini kolay ayırt edebilmek adına önemlidir. Ayrıca noktaların farklı tarihlerde aynı bölge üzerinden alınması fakat birbirinden ayırt edilebilir veriler olması bu başarı oranına büyük katkı sağlamaktadır.

Önerilen çalışmada oluşturulan özgün veri seti ile müsilağlı alanların otomatik tespit edildikten sonra deniz kirliliğine karşı önlem ve bu kirliliğe erken safhada müdahale edilebilmesi amaçlanmıştır.

Bölüm 3'te çalışma alanı görüntüsü, görüntü işleme adımları, derin öğrenme ve makine öğrenmesi modelleri ayrıntılı bir şekilde verilmiştir. Bölüm 4'te Elde edilen yansıma değerleri, uygulanan makine öğrenmesi ve derine öğrenme modellerinin sonuçları ve başarıları verilmiştir. Bölüm 5'te kullanılan modellere göre sistemim başarısı ve kullanılabilirliği ele alınmıştır.

2. KAYNAK ARAŞTIRMASI

Uzaktan algılama teknolojisinden elde edilen bilgiler, canlı türlerinin yaşam alanlarının belirlenmesi, detaylandırılması, türlerin dağılımı ve alansal değişimi tespit etmeyi sağlamaktadır (Şimsek Bağcı, 2022). Makine öğrenmesi aracılığıyla nesne tespiti ve sınıflandırma son zamanlarda yaygın hale gelmiştir (Acar ve Altun, 2021). Literatürde uzaktan algılama verileri kullanılarak müsilaçlı alan tespiti, müsilaçlı alan izlenmesi, makine öğrenmesi ve derin öğrenme yöntemlerinin müsilaçlı alan tespiti veya izlenmesi için kullanılması ile ilgili yapılan çalışmalar taranmıştır. Taranan bu çalışmalar aşağıda verilmiştir.

Abacı ve ark. (2022), hem geleneksel hem de derin öğrenme algoritmalarını kullanarak müsilaçlı erken bir aşamada tespit etmek için Sentinel-2 multispektral verilerini ve PRISMA hiper spektral verilerini analiz etmişlerdir. Uydu verilerinden yüksek doğrulukla müsilaçlı tespit etmenin mümkün olduğunu, temizlik işi için zamandan ve paradan tasarruf edildiğini göstermişlerdir (Abacı ve ark. 2022).

Taşkın ve ark. (2021) tarihli Sentinel-2A görüntülerini sınıflandırarak yeni bir nesne tabanlı görüntü analizi (OBIA) yaklaşımı paradigması kullanarak İstanbul, Kocaeli, Yalova ve Bursa kıyılarına odaklanarak Marmara Denizi çevresinde yoğun olarak gözlenen müsilaç oluşumlarını belirlemeyi amaçlamıştır. 19 ve 24 Mayıs 2021, müsilaçlı en yoğun olduğu tarihler (Kavzaoğlu ve ark. 2021).

Uğur ve ark. (2021), uzaktan algılama (UA) teknikleri yardımıyla Marmara Denizi'ndeki mevcut müsilaç oluşumunu dikkate alarak müsilaç tespiti için bir metodoloji geliştirmiştir. Bu amaçla Sentinel-2 uydu görüntüleri Google'ın Earth Engine (GEE) platformu ve Random Forest (RF) algoritması ile sınıflandırılarak 10.03.2021 tarihinden 06.06.2021 tarihine kadar müsilaç oluşumu belirlenmiştir (Uğur ve ark. 2021).

Tassan (1993), Adriyatik Denizi'ndeki belirli meteorolojik koşullar altında meydana gelen bir olay olan alg çiçeklenmesinden ("müsilaç") beyaz bir gelgiti saptamak için AVHRR verilerini kullanan bir algoritma geliştirdi. Daha sonra onları test etti ve haritasını çıkardı (Tassan 1993).

Kavzaoğlu ve Göral (2022), bulut tabanlı Google Earth Engine'i (GEE) kullanarak İzmit Körfezi'ndeki deniz yüzeyindeki müsilaç kümelerini etkili bir şekilde haritalamak için Mayıs ve Temmuz 2021 arasında alınan bulutsuz ve parçalı bulutlu Sentinel-2 görüntülerinden tahmin edilen beş su indeksi kullandı. Burada yaklaşık 6 km² deniz yüzeyini kaplamakla başlayan müsilaç agregalarının 24 Mayıs'ta en yüksek

seviyeye ulaştığını ve temmuz sonunda azaldığını gözlemlemişlerdir (Kavzaoglu ve Göral 2022).

Aylin ve ark. (2022), orta (Sentinel-2) ve yüksek uzamsal çözünürlüklü (Worldview-3) uydu görüntülerini kullanarak Marmara Denizi'ndeki İzmit Körfezi'ndeki farklı müsilaç türlerinin spektral özelliklerini sunmuştur. Destek vektör makinesi (SVM) sınıflandırıcısı, 725 ila 950 nm arasında değişen kızılötesi bölgede ayırt edilebilir spektral farklılıklara sahip üç farklı müsilaç türünü tespit etmek için kullanıldı (Tuzcu Kokal ve ark. 2022).

Acar (2020), Sentinel-1 SAR uydu verilerini kullanarak Diyarbakır'daki tarım arazilerindeki EDT'leri (Transformatörleri) makine öğrenmesi yöntemiyle tespit etmeye çalışmıştır. Çalışmasında ELM (Extreme Machine Learning) kullanmış ve 85,47% doğruluk oranına ulaşmıştır (Acar 2020).

Yağcı ve ark. (2022), 2021 yılı çiçeklenme döneminde kaba mekânsal çözünürlüklü MODIS ürünlerinden müsilaç oluşumlarının günlük olarak izlenmesini ve tespitini incelemişlerdir. Sonuçları Sentinel-2A görüntülerinden elde edilen referans müsilaç veri setleri ve müsilaç oluşumları üzerindeki kısımlar spektrometre ölçümleri ile doğrulamıştır. Sonuçlar, MODIS yüzey yansıtma profillerinin alan spektral ölçümleri ile yüksek oranda ilişkili olduğunu ve tahmini müsilaç oluşumlarının mekânsal olarak Sentinel-2A ile örtüştüğünü ortaya çıkarmışlardır (Yağcı ve ark. 2022).

Kavzaoglu ve ark. (2021), Sentinel-2 uydu görüntüsünün dört spektral bandı arasındaki ilişkiyi kullanan 'müsilaç indeksi' ile müsilaç kaplı alanların tespitini hedeflemişlerdir. Bu indeksten faydalanılarak 14, 19 ve 24 Mayıs 2021 tarihli uydu görüntüleri için müsilaç indeks haritalarını oluşturmuşlardır. Sentinel-2 için tanımlanan müsilaç indeksi ile müsilaç oluşumlarının hızlı bir şekilde tespit ve analizinde önemli bir veri seti oluşturulabileceği göstermişlerdir. Ayrıca 17 Mayıs 2021 tarihli Landsat-8 termal uydu görüntüsü yardımıyla temiz deniz yüzeyi ve müsilaç oluşumlarının yüzey sıcaklıklarını analiz etmişlerdir. Sonuç olarak, müsilaç alanlarının yüzey sıcaklığının ortalama deniz yüzey sıcaklığına göre 3°C'ye kadar daha yüksek olduğu tespit etmişlerdir (Kavzaoglu ve ark. 2021).

Kavzaoglu ve ark. (2021), İstanbul, Kocaeli, Yalova ve Bursa kıyıları başta olmak üzere, Marmara Denizi'nin tamamında yoğun olarak gözlenen müsilaç oluşumlarını, 19 ve 24 Mayıs 2021 tarihli Sentinel-2A görüntülerini sınıflandırarak belirlemeyi amaçlamamışlardır. OBIA (nesne tabanlı görüntü analizi) yaklaşımı kullanmışlardır. Temsili ve homojen görüntü nesneleri oluşturmak için çoklu

özünürlüklü segmentasyon uygulamışlar ve tematik haritalar oluşturmak için de Rastgele Orman (RF) sınıflandırıcı kullanılarak bir sınıflandırma yapmışlardır. Sonuçlarının 90%'ın üzerinde doğruluk değerine sahip olduğunu göstermişlerdir (Kavzaoğlu ve ark. 2021).

Hacıfendioğlu ve ark. (2022), uydu görüntülerinden müsilağ alanlarının tespitini iyileştirmek için transfer öğrenme yöntemlerini önermişlerdir. Musilağ olayları nedeniyle zor zamanlar geçiren Marmara Denizi çalışma alanı olarak seçmişlerdir. Veri setini, müsilağ görüntülerini konvolüsyonel sinir ağı (CNN) modelleri ile sınıflandırmak için eğitildi ve daha sonra müsilağ alanlarını lokalize etmek için yeniden kullanmışlardır. Bireysel CNN modelleri için artık ağılar (ResNet)-50, görsel geometri grubu (VGG)-16, VGG-19 ve Inception-V3 kullanmışlardır. Öğrenilen davranışı görselleştirmek için gradyan ağırlıklı sınıf aktivasyon haritalama (Grad-CAM) tekniğı kullanıldı. Özel bir CNN modeli oluşturmuşlar ve müsilağ alanlarını daha iyi lokalize etmek için en verimli konvolüsyonel katman dikkate alınarak birleşim üzerinden kesişme ile gerçek müsilağ alanlarıyla karşılaştırmalar yapmışlardır. Özel CNN modelinin diğer modellere göre üstün yerelleştirme performansı gösterdiği sonucuna varmışlardır (Hacıfendioğlu ve ark. 2022).

Bağcı ve ark. (2022), tarımsal ürünlere ait Sentinel-1 uydu görüntü indeksleri ve derin öğrenme mimarisi birlikte kullanılarak tarımsal ürünlerden Mısır ve Pamuk'un tespitinin yapılması amaçlamışlardır. Çalışmalarında kullandıkları Sentinel-1 uydu görüntü veri setini, Google Earth Engine Code Editor (GEE-CE) yardımıyla elde etmişlerdir. Bu veri setleri 2016-2021 yılları arasındaki Haziran, Temmuz, Ağustos, Eylül aylarına ait toplam 434 görüntüden oluşmaktadır. Daha sonra, GEE-CE ortamında her bir tarımsal ürüne karşılık gelen görüntülerdeki yansıma değerlerinin elde edilmesi için çeşitli ön işlemler yapmışlardır. Bu yansıma değerleri, derin öğrenme ağı girişine verilerek sistemin performans değerleri hesaplanmışlardır. Sonuç olarak, Sentinel-1 uydu görüntülerinin yansıma değerleri derin öğrenme mimarisi ile birlikte kullanıldığında 95% doğruluk değerine kadar ulaşmışlardır (Bağcı ve ark. 2022).


Bakış ve Acar (2023), Marmara bölgesindeki müsilağlı ve temiz alan verilerini Sentinel-1 uydusu kullanılarak almışlardır. Sonrasında bu verilere bir derin öğrenme mimarisi katmanı olan LSTM (Uzun Kısa Süreli Bellek) uygulayarak çok yüksek sonuçlar elde etmişlerdir (Bakış ve Acar ,2023).

Önerilen çalışmamızın literatüre ana katkıları şunlardır;

- a. Müsilaj alanlarını otomatik tespit etmek için makine öğrenmesi ve LSTM tekniklerinin ilk kez Sentinel-1 uydu verileri ile yapılması,
- b. Çalışma sonucunda çok yüksek doğruluk değerlerinin elde edilmesi
- c. Müsilaj alanlarını otomatik tespit ettikten sonra erken müdahale ile denizdeki canlıların ölmesi, görüntü kirliliği gibi durumların önüne geçilmesi
- d. Müsilaj alanlarının tespiti için 2 adet veri ile ilk kez eş zamanlı olarak hem derin öğrenme hem de makine öğrenmesini birada kullanarak verilerin doğruluğunu ve otomatik tespit etme başarısını sunmak,
- e. Müsilajın en çok meydana geldiği zaman aralıklarını otomatik tespit edip bu alanlara zamanından öncede müdahale edilerek müsilaj düzeyini en aza indirmek.

3. MATERYAL VE YÖNTEM

Tezde kullanılan materyaller, uygulanan yöntemler ve verilerin nasıl elde edildiği bu bölümde verilmektedir. Önerilen çalışma birkaç aşamadan oluşmaktadır. Şekil 3.1’de, önerilen çalışmaya ait iş akış diyagramı verilmiştir.




Şekil 3.1. İş akış diyagramı

Şekil 3.1’de görüldüğü üzere çalışma belirli aşamalardan oluşmaktadır. Bu aşamalar aşağıdaki gibi sıralanabilir;

1. Müsilajlı alanı belirleme ve bu alandan veri toplama
2. Müsilajlı alan üzerinden alınan verilerin işleme süreci
3. İşleme sonra elde edilen verilerden özellik çıkarımı
4. Öznitelik vektörlerinin belirlenmesi (Tarihler)
5. Elde edilen veri setlerin makine öğrenmesi ve derin öğrenme uygulanması
6. Uygulanan yöntemler sonucu müsilajın tahmin edilmesi

3.1. Deney Alanı

Bu çalışmada Marmara Denizi'ne kıyısı bulunan Armutlu ve Zeytinbağı ilçeleri arasında kalan bölgede 2021 yılı için 17 Mayıs ve 22 Mayıs tarihlerinde müsilajlı bölge için 1300 nokta, 21 Haziran ve 22 Haziran tarihlerinde ise temiz alan için aynı bölge üzerinde 1300 nokta seçilmiştir. Seçilen noktaların koordinatları hiç değiştirilmeden sadece tarih aralıkları değiştirilmiştir. Deney alanı Şekil 3.2’de verilmiştir.




Şekil 3.2. Çalışma alanı Google Earth uydu görüntüsü

3.2. Sentinel-1 Uydu Verisi Toplama

Bu bölümde Google Earth Engine Code Editor Platformu (<https://code.earthengine.google.com>) yardımıyla 4 farklı tarihe (17 Mayıs, 22 Mayıs, 21 Haziran ve 22 Haziran 2021) ait VV ve VH polarizasyonlu Sentinel-1 uydu görüntüleri kullanılmıştır. Çalışma alanını kapsayan Sentinel-1 VV-VH bant görüntüleri sırasıyla Şekil 3.3'te ve Şekil 3.4'te gösterilmektedir.




Şekil 3.3. Çalışma alanının Sentinel-1 uydusu VV bant görüntüsü




Şekil 3.4. Çalışma alanının Sentinel-1 uydusu VH bant görüntüsü

3.3. Nesne Verisi Toplama


Bu aşamada toplam 1300 örnek ile müsilaj alanı ve temiz alanın coğrafi koordinatları GPS cihazı yardımıyla kaydedilmiş ve daha sonra kaydedilen veriler GEE-CE platformunun kod yazım arayüzüne aktarılmıştır. Kod yazım arayüzüne aktarılan bu nesne verileri yine kod yazım arayüzünde belirli kodlar yazılarak istenilen zaman aralığında zaman serileri kullanılarak Sentinel-1 uydu verilerine aktarılmıştır. Nesne verisi olarak işaretlenen 1300 adet noktanın ham, VV, VH görüntüleri sırasıyla Şekil 3.5'te, Şekil 3.6'da ve Şekil 3.7'de verilmiştir.



Şekil 3.5. Seçilen 1300 adet noktanın ham görüntüsü



Şekil 3.6. Seçilen 1300 adet noktanın Sentinel-1 uydusu VV bant görüntüsü



Şekil 3.7. Seçilen 1300 adet noktanın Sentinel-1 uydusu VH bant görüntüsü

3.3.1 Sentinel-1 Uydusu Özellikleri ve İşleyişi

Sentinel-1 uyduları baş müteahhit olarak Thales Alenia Space Italy başkanlığında, Astrium UK tarafından geliştirilen, elektronik sistem altı merkezi radar ile birleştirilen, 'C-SAR' yüklemesinden sorumlu Astrium Germany ile birlikte bir endüstriyel consosoryum tarafından inşa edilmiştir (Attema ve ark. 2007). Sentinel-1, gece gündüz çalışan, C-bandı sentetik açıklıklı radar (C-SAR) görüntüleme gerçekleştiren, elektromanyetik sinyal ile çalışmasından dolayı hava durumundan bağımsız olarak görüntü elde etmelerini sağlayan kutup yörüngesindeki iki uydudan oluşan bir takımyıldızı içerir (European Space Agency 2023). Sentinel-1 gönderdiği elektromanyetik sinyallerin geri algılanması için üzerinde bulunan antenleri kullanır. C-

SAR cihazı, bir iletim zinciri (H veya V'ye değiştirilebilir) ve H ve V polarizasyonu için iki paralel alma zinciri aracılığıyla uygulanan ikili polarizasyonda (HH+HV, VV+VH) çalışmayı destekler. Çift polarizasyon verileri, arazi örtüsü sınıflandırması ve deniz buzunu uygulamaları için kullanışlıdır. (European Space Agency 2023)

Sentinel-1 uydusu dört özel alım modunda çalışır:

1. **Şerit Haritası (SM):** Şerit Haritası, 80 km'lik dar bir tarama genişliği üzerinde 5 m'ye 5 m çözünürlükte kapsama alanı sağlar. Işın geliş açısı ve yükseklik ışın genişliği değiştirilerek altı görüntüleme şeridinden biri seçilebilir (European Space Agency, 2023).
2. **İnterferometrik Geniş Alan (IW):** İnterferometrik Geniş şerit (IW) modu, büyük bir şerit genişliğini (250 km) orta düzeyde bir geometrik çözünürlükle (5 m'ye 20 m) birleştirmeye olanak tanır. İnterferometri, Doppler spektrumunun (azimut alanında) ve dalga sayısı spektrumunun (yükseklik alanında) yeterli örtüşmesiyle sağlanır. IW modu, kara üzerinden varsayılan edinme modudur (European Space Agency, 2023).
3. **Ekstra Geniş Alan (EW):** Ekstra Geniş Alan görüntüleme modu, geniş kapsama alanı ve kısa tekrar ziyaret sürelerinin talep edildiği deniz, buz ve kutup bölgesi operasyonel hizmetleri için tasarlanmıştır. EW modu, IW moduna benzer şekilde çalışır fakat daha düşük bir çözünürlükle sonuçlanır (20 m'ye 40 m). EW modu, IW modunda olduğu gibi interferometri için de kullanılabilir (European Space Agency, 2023).
4. **Dalga Modu (WV):** Sentinel-1 Dalga modu, küresel okyanus dalgası modelleri ile birlikte, açık okyanuslardaki dalgaların yönünü, dalga boyunu ve yüksekliklerini belirlemeye yardımcı olabilir. Dalga modu edinimleri, dönüşümlü olarak iki farklı geliş açısında elde edilen 20 km'ye 20 km'lik şerit harita görüntülerinden oluşur. Dalga görüntüleri her 100 km'de bir elde edilir ve aynı geliş açısındaki görüntüler 200 km ile ayrılır (European Space Agency, 2023).

Tablo 3.1’de Sentinel-1 uydusu spektral bant parametreleri özellikleri verilmiştir.

Tablo 3.1. Sentinel-1 uydusu spektral bant parametreleri özellikleri (Conradsen ve ark. 2003)

Spektral Bantlar	Piksel Boyutları	Açıklama
VV	10 metre	Tek eş-polarizasyon, dikey gönderme/dikey alma
VH	10 metre	Çift bant çapraz polarizasyon, dikey iletim/yatay alma
HV	10 metre	Çift bant çapraz polarizasyon, yatay gönderme/dikey alma
HH	10 metre	Tek eş polarizasyon, yatay gönderme/yatay alma

3.3.2. Google Earth Engine-Code Editor (GEE-CE) Platform Yapısı ve İşleyişi

Google Earth Engine (GEE), genel bir veri kataloğu olan, bilgi işlem altyapısı sahip, jeouzsamsal API’lerden oluşan bulut tabanlı bir platform arayüzüne sahip ve Code Editör kısmında java ve python programlama dillerinin kullanıldığı çok fonksiyonlu bir platformdur. GEE, kullanıcıların Google altyapısında depolanan coğrafi kaynaklı görüntüler ve bunların yanı sıra vektörler üzerinde çeşitli algoritmalar çalıştırmasına olanak sağlamaktadır. Ayrıca API, görüntüleme ve veri analizleri bağlamında verilere uygulanabilecek bir işlev kitaplığı sağlamaktadır. GEE’nin genel veri kütüphanesi, büyük çoğunlukla kamuya açık bir şekilde görüntü ve veri kümelerini içermektedir. (Anomin 2021). GEE platformu, bulut tabanlı coğrafi veri kümelerinin bilimsel olarak incelemesini görselleştirip bu görselleri işlemek için çok verimli bir UA platformudur (Gorelick ve ark. 2017). Bu görselleştirmeler hem zamansal hem de maliyet açısından son derece katkı sağlamaktadır. GEE, veri sayısının çokluğu ve araştırmacılara daha az malzeme ve maliyet ile araştırma yapılabilmesi için büyük imkanlar sunmaktadır. Geçmişte büyük boyutlu uydu verilerinin ofis ortamındaki bilgisayarlarda kaydedilip işlenmesi ve analiz edilmesi gerekirken şimdi GEE’nin bulut bilişim gücü sayesinde vektör verileri bulut ortamında işlenmesine olanak tanımaktadır (Kumar ve ark 2018). Bu durum verilerin çok kolay bir şekilde depolanıp kullanılabilmesi açısından önemli bir yere sahiptir. GEE kullanırken piksel seçimlerinde mean, median min, max vb. farklı yöntemler kullanılmaktadır. Aynı zamanda GEE aracı ile bulut oranlarının az olduğu bölgeleri seçerken kod panelinden yararlanılarak bulutluluk oranının istenildiği şekilde seçilebilmesine olanak sağlamaktadır (Mateo-García ve ark. 2018). GEE platformu ile birlikte uzaktan algılama sistemlerindeki çalışmalar artmış ve bu platform uzaktan algılama alandaki gelişmelere paralel çalışmalar yapabilme olanağını arttırmıştır. Çevre, iklim, arazi örtüsü, jeoloji, nüfus, hastalık ve afet gibi birçok veri seti içerdiğinden büyük verilere GEE ile kolaylıkla erişilebilmektedir (Praticò ve ark. 2021). GEE Python

ve Java altyapısı ile çalışabilmektedir. Landsat-8, Sentinel-1 ve Sentinel-2 uydularının verileri GEE-CE arayüzü kullanılarak erişilebilen uydulardır. GEE içerisindeki veriler, kullanıcıya hazır bir şekilde gelmekte ve herhangi bir ön işlem süreçlerinden geçmeden kullanılabilirler. Bu çalışmada GEE-CE aracılığıyla java programla dili kullanılarak Sentinel-1 uydu verilerine erişilmiş ve bu veriler kullanılmıştır.

3.4. Nesne Verilerinin Özellik Çıkarımı (Feature Extraction)

Uzaktan algılama sistemlerinin gelişmesiyle beraber birçok alanda uzaktan algılama verilerinin önemi artmıştır. Bu alanlardan biri de su alanlarıdır. Nesne olarak seçilen bu su alanlarında suyun yansımaya değerleriyle belirli sınıflandırmalar yapmak zordur. Bunun sebebi su yüzeyinden elde edilen yansımaya değerlerinin birbirine çok yakın olmasıdır. Fakat müsilaj su üzerinde tabaka oluşturduğu için müsilajlı su yüzeyinden alınan yansımaya değerleri ile gerçek su yüzeyinden alınan yansımaya değerleri arasında ciddi farklılıklar oluşabilmektedir. Bu da su alanı için yansımaya değerleriyle sınıflandırma yapabilme olanağı sağlamaktadır.

Bu çalışmada nesne verilerinin özellik çıkarımı için GEE platformu aracılığıyla Sentinel-1 uydusu spektral bant parametreleri (VV-VH) kullanılmıştır. Bu spektral bant parametreleri GEE platformu üzerinde müsilaj bölgesinde işaretlenen 1300 adet noktanın her biri için belirli tarihlerde müsilajlı alanın yansımaya değerlerini, belirli tarihlerde ise temiz alan için yansımaya değerleri vermektedir. Elde edilen bu yansımaya değerleri müsilaj alan üzerinden işaretlenen her bir noktanın ayrı ayrı özelliğini vermektedir. VV ve VH bant parametreleri için ayrı ayrı yansımaya değerleri alınmıştır. Nesne verileri, daha önceden yapılmış ve müsilajın olduğu doğrulanmış bölge üzerinden farklı tarihler aralığında alınmıştır. Dolayısıyla her iki spektral bant için elde edilen yansımaya değerleri gerçeği yansıtmaktadır.

3.5. Ön İşlem Süreci ve Veri Setinin Oluşturulması

Mayıs 2021’de Marmara Denizi’nde müsilaj seviyesinin ciddi boyutlara geldiği görülmektedir. Bu sebeple Marmara Denizi’nde müsilajın yüksek seviyede görüldüğü Armutlu-ZeytinBağı bölgesinde toplam 1300 adet su noktası seçilmiştir. Bu su noktaları GEE platformu üzerinde manuel olarak işaretlenirken Özellik Toplama (Feature Collection) kısmı seçilmiştir. Bu kısım işaretlenen her bir nokta için yansımaya değeri vermesini sağlamaktadır. Bu kısım seçilip işaretleme yapılırken müsilajlı alan piksel piksel yaklaştırılarak işaretleme yapılmıştır. İşaretleme tamamlandıktan sonra her bir noktanın coğrafi koordinatlarının GEE-CE kısmına işlenmesi gerekmektedir.

Dolayısıyla işaretlenen her bir noktanın coğrafi koordinatları bir fonksiyon oluşturularak GEE-CE arayüzüne GPS yardımıyla işlenmiştir.

Veri setini oluşturmak için elde edilen yansıma değerlerinin tabloya aktarılması ve daha sonra işlenmesi için istenilen formata dönüştürülmesi gerekmektedir. İşaretlenen 1300 adet nokta değiştirilmeden hem VV hem de VH bandı için 17 Mayıs ve 22 Mayıs için müsilaçlı alan yansıma değerleri, 21 Haziran ve 22 Haziran için temiz alan yansıma değerleri alınmıştır. Daha sonra elde edilen yansıma değerleri GEE platformu üzerinden .xlsx formatlı Excel dosyalarına dönüştürülmüştür. Toplamda 4 adet Excel dosyası oluşturulmuştur. Bu dosyalar 17 Mayıs ve 22 Mayıs tarihlerinde müsilaçlı alan için VV ve VH bantları yansıma değerlerini, 21 Haziran ve 22 Haziran tarihlerinde temiz alan için VV ve VH bantları yansıma değerlerini içermektedir. Daha sonra hem VV hem de VH bandı için müsilaç ve temiz alan verileri .csv formatlı tek bir Excel dosyasına dönüştürülerek her bir bant için ayrı 2 adet veri seti oluşturulmuştur. Oluşturulan 2 adet veri setine ilişkin görsel Şekil 3.9'da ve Şekil 3.10'da verilmiştir. Bu veri setlerine sonradan makine öğrenmesi ve derin öğrenme yöntemleri uygulanmıştır.

Sample Number	May17(M)-Jun22(T)	May22(M)-Jun21(T)	Class	
0	0	-19.005	-28.474	1
1	1	-19.005	-28.474	1
2	2	-17.107	-28.544	1
3	3	-17.107	-28.544	1
4	4	-17.928	-28.952	1
...	...	...	...	...
2595	2595	-26.864	-15.690	0
2596	2596	-25.752	-15.353	0
2597	2597	-29.599	-15.690	0
2598	2598	-26.864	-15.690	0
2599	2599	-25.400	-15.465	0

2600 rows × 4 columns

Şekil 3.9. VV bandı için oluşturulan veri seti

	Sample Number	May17(M)-June21 (T)	May22(M)-June22(T)	Class
	0	-25.927	-32.774	1
	1	-25.927	-32.774	1
	2	-26.232	-32.395	1
	3	-26.232	-32.395	1
	4	-26.289	-32.343	1
	...	...	...	...
	2595	-32.866	-26.981	0
	2596	-32.910	-27.116	0
	2597	-32.839	-26.981	0
	2598	-32.866	-26.981	0
	2599	-33.073	-26.903	0

2600 rows × 4 columns

Şekil 3.10. VH bandı için oluşturulan veri seti

Oluşturulan veri setine çeşitli görselleştirmeler uygulanmış ve dağılım grafikleri elde edilmiştir. Bu görseller araştırma sonuçları ve tartışma kısmında ele alınacaktır.

3.6. Uygulanan Yöntemler

Şekil 3.9’da ve Şekil 3.10’da görüldüğü üzere 2 adet veri setimiz mevcuttur. Bu iki veri seti birleştirilip 3. bir veri seti oluşturulmuştur. Bu veri setlerine (VV bandı için veri seti, VH bandı için veri seti, VV+VH kombinasyonu için veri seti) ayrı ayrı makine öğrenmesi ve derin öğrenme modelleri uygulanmıştır.

3.6.1. Uygulanan Makine Öğrenmesi Yöntemleri

3 adet veri setinin her birine 6 adet makine öğrenmesi yöntemi uygulanmıştır. Uygulanan makine öğrenmesi yöntemleri: SVM, DT, NB, KNN, SGD, RF’dir.

3.6.1.1. Destek Vektör Makinası (Support Vector Machine-SVM)

Destek Vektör Makinaları regresyon analizlerinde, sınıflandırmalarda ve birbirinden aykırı değerlerin tespit edilmesinde kullanılan denetimli bir makine öğrenmesi yöntemidir. Karar Destek Vektör Makinaları olarak da adlandırılırlar. Kullanılan karar fonksiyonlarına Kernel fonksiyonları adı verilir.

SVC, NuSVC ve LinearSVC ikili veya çoklu sınıflandırma için kullanılan vektör makinaları öğrenme yöntemleridir. SVR, NuSVR, LinearSVR regresyon analizlerinde kullanılan vektör makinaları öğrenme yöntemleridir.

Genel olarak avantajları şunlardır;


- Boyutu yüksek olan dizilerde etkili bir yöntemdir.

- Örnek sayısının boyut sayısına oranla daha az olduğu durumda da etkilidir.
- Karar verme fonksiyonu kullanımı sırasında her bir eğitim noktası için bir alt kümeyi kullanır. Dolayısıyla hafıza olarak hem etkili hem de verimli bir yöntemdir.
- Farklı Kernel fonksiyonları sunar, yani çok yönlü bir öğrenme yöntemidir.

Genel olarak dezavantajları şunlardır;

- Veri setinde bulunan sütun sayısı (öznitelik sayısı), satır sayısından (örnek sayısı) fazla ise, veri seti her Kernel fonksiyonu ile doğru çalışmamaktadır. Bu durumda aşırı öğrenme olmaması açısından uygun Kernel fonksiyonu seçilmelidir.
- Karar destek vektör makinaları doğrudan olası tahminler vermez. Bu olası tahminler daha karmaşık olan çapraz doğrulama yöntemi kullanılarak hesaplanır.

SVM makine öğrenmesi yöntemine ilişkin görsel Şekil 3.11’de verilmiştir.



Şekil 3.11. SVM mimarisi (AKCA, 2020)

Tabloda siyah renk ve beyaz renk olmak üzere iki sınıf mevcuttur. Sınıflandırma problemlerindeki asıl amaç gelecek verinin hangi sınıfta yer alacağını kararını vermektir. Bu sınıflandırmayı yapabilmek için iki sınıfı ayıran bir doğru çizilir ve bu doğrunun ± 1 'i arasında kalan yeşil bölgeye Margin adı verilir. Margin ne kadar geniş ise iki veya daha fazla sınıf o kadar iyi ayrıştırılır (AKCA, 2020).

3.6.1.2. Karar Ağaçları (Decision Tree-DT)

Karar Ağaçları regresyon analizlerinde, sınıflandırma problemlerinde kullanılan denetimli bir makine öğrenmesi yöntemidir. Bu yöntemde amaç istenilen kararlar doğrultusunda yapısında bulunan yaprak, dal ve kökler aracılığıyla sisteme girilen verinin hangi sınıfa ait olacağını tahmin edebilen bir model oluşturmaktadır.


Genel olarak avantajları şunlardır;

- Yapısından dolayı oluşturulan modeli anlamak ve yorumlamak basittir.
- Veri hazırlığı için kullanılan süre çok azdır. Fakat veride eksik değer bulunmaması gerekmektedir.
- Hem sayısal verileri hem de kategorik verileri işleme özelliğine sahiptir. Fakat hali hazırda kullanılan scikit-learn kütüphanesi kategorik verilerle işlem yapmayı desteklememektedir.
- Çok sayıda çıkış verisi ile oluşabilecek sorunları çözebilir.
- Beyaz kutu modeli kullanılarak belirli durumlarda sonuçların yorumlanması ve gözlemlenmesi daha kolay hale gelmektedir.
- İstatistiksel veriler kullanılarak oluşturulan modelin doğruluğu test edilebilir, bu da sistemin güvenilirliği açısından önemlidir.
- Performans açısından etkili bir yöntemdir.

Genel olarak dezavantajları şunlardır;

- Verilerin iyi bir şekilde genellenmemesi ile çok karmaşık ağaç yapıları meydana gelebilir. Bunun sonucunda budama işleme yapılması gerekmektedir.
- Verilerde meydana gelen en ufak değişiklikler farklı bir karar ağacı modeli oluşturulmasına neden olabilir. Bu da sistemin kararsız çalışmasına sebebiyet verebilir.
- Tahminleri ne çok açıktır ne de sürekli. Bu sebepten ötürü bilinen veri noktalarının ayrık veri kümesi dışında yeni veri oluşturma gibi işlemlerde iyi değildir.
- Karmaşık problemleri kolayca ifade edemediği için öğrenilmesi zor kavramlar vardır.
- Verilerin Karar Ağacı modeline uydurmadan baskın olan sınıflar için veri setinin dengelenmesi gerekmektedir. Dengelenmemesi ön yargılı ağaçlar oluşturabilir.

Karar Ağaçları makine öğrenmesi yöntemine ilişkin görsel Şekil 3.12’de verilmiştir.



Şekil 3.12. Karar Ağaçları mimarisi (Ulgen, 2017)

3.6.1.3. Naive Bayes (NB)

Naive Bayes yöntemi, toplam sınıf sayısı verilen her bir özellik çifti arasında “naive” koşullu bağımsızlık varsayımıyla bayes teoremi ile birlikte uygulamaya dayalı denetimli bir makine öğrenmesi yöntemidir. Sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Gaussian, Multinomial, Complement, Bernoulli, Categorical, out-of-core gibi çeşitleri mevcuttur.

Genel olarak avantajları şunlardır;

- Çalışma açısından hızlıdır, bu özelliği çok zaman kazandırabilir.
- Çok sınıfa sahip tahmin problemlerini çözmek için uygun bir yöntemdir.
- Özelliklerinin bağımsız olduğu kanaati doğru ise, diğer tüm modellerden daha iyi çalışabilir ve eğitim için çok az veri gerektirir.
- Sayısal verilere göre kategorik verilerle daha iyi çalışır.

Genel olarak dezavantajları şunlardır;

- Naive Bayes tüm özelliklerin tamamen rastsal olarak gerçekleştiğini öne sürdüğü için gerçek hayattaki verilerle doğru çalışmayabilir.
- Veri setinde bulunmayan değişkenlere 0 olasılık değerini yüklemektedir. Bu da sistemin verimli çalışması adına engeldir. Bu soruna “sıfır frekans sorunu” denir.

- Tahminler bazı durumlarda tahmin edilenin tam tersi olabilmektedir. Bu neden çıktıları doğruluk açısından optimize değildir.
- Diğer makine öğrenmesi yöntemlerine oranla çok daha az kullanılırlar.

Naive Bayes makine öğrenmesi yöntemine ilişkin görsel Şekil 3.13'te verilmiştir.

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

THE PROBABILITY OF "B" BEING TRUE GIVEN THAT "A" IS TRUE

THE PROBABILITY OF "A" BEING TRUE

THE PROBABILITY OF "A" BEING TRUE GIVEN THAT "B" IS TRUE

THE PROBABILITY OF "B" BEING TRUE

Şekil 3.13. Naive Bayes mimarisi (Sawla, 2018)

3.6.1.4.K-En Yakın Komşuluk (K-Nearest Neighbours -KNN)

Komşuluğa dayalı sınıflandırmalar koşullu ve genellemeye bağlı olmayan öğrenme modelleridir. Yalnızca eğitim verisinde bulunan örnekleri kullanır. Sınıflandırma sistemi her nokta için ayrı ayrı yapılır. Bu her noktanın en yakın komşu noktalarının ortalaması alınarak hesaplanır. Hangi nokta en çok yakın komşuya sahipse o nokta hedef noktası olarak belirlenir. K-En Yakın Komşuluk bir komşuluğa dayalı makine öğrenmesi yöntemidir. Hedef noktalarını (her bir k noktası) baz alarak öğrenmeyi uygular. En sık kullanılan komşuluğa bağlı makine öğrenmesi modeli K-En Yakın Komşuluk modelidir. Bu modelde kullanılan çeşitli uzaklık hesaplama algoritmaları mevcuttur. Öklidyen, Manhattan, Chebyshev, Hamming, Minkowski, Manahalobis, Havarsiene, Levenshtein, Sorensen-Dice, Jacckard KNN modeli için uzaklık hesaplama algoritmalarıdır.

Genel olarak avantajları şunlardır;

- Sistem verilerini eğitme açısından diğer öğrenme yöntemleri ile kıyaslandığında sistemi eğitmen bu model için daha kolaydır.
- Model boyunca sistemin işleyişi ve analizleri sayısal olarak takip edilebilir.
- Karmaşık veriler içeren veri setlerinde güzel işler çıkarır ve etkilidir.

- Düzenlenebilirliğinin ve uygulanabilirliğinin kolay olması.

Genel olarak dezavantajları şunlardır;

- Sistem süreçleri bakımında birçok adıma sahip olduğundan modelin uygulanması için yüksek donanım gerekmektedir.
- Sistem süreçleri bakımında çok adım ve işlem sayısı olduğundan modeli oluşturmak zaman almaktadır (yüksek boyutlu veriler için).
- Yüksek performans için uzaklık ölçümünde hangi algoritmanın kullanılması gerektiğinin bulunması zaman alabilmektedir.

K-En Yakın Komşuluk makine öğrenmesi yöntemine ilişkin görsel Şekil 3.14’te verilmiştir.



Şekil 3.14. KNN mimarisi (Ulgen, 2017)

3.6.1.5. Stokastik Dereceli Azalma (Stochastic Gradient Descent-SGD)

Stokastik Dereceli Azalma yöntemi, SVM ve LR (Lojistik Regresyon) gibi kayıp fonksiyonlarının bulunduğu yerlerde lineer sınıflandırma ve regresyon analizi yapmak için çok etkili bir yöntemdir. Eski bir makine öğrenmesi yöntemi olması rağmen son zamanlarda ilgi odağı haline gelmiştir. Metinleri sınıflandırma, doğal dil işleme gibi alanlara uygulanmıştır ve yüksek başarı elde edilmiştir. Bu yöntemin sınıflandırmalarda ve regresyon analizlerinde kullanıldığı bilinse de aslında tam anlamıyla makine öğrenmesi yöntemi değildir. En güzel şekilde tabir edilmesi gerekirse bu yöntem için bir optimizasyon tekniğidir, denilebilir. Çalışma prensibi, fonksiyonlara ait parametreleri devamlı güncelleyerek bu fonksiyonların en küçük değerine ulaşmaktır. Hipotez fonksiyonu, maliyet fonksiyonu, hata fonksiyonu birer dereceli azalma fonksiyonudur.

Genel olarak avantajları şunlardır;

- Verimli bir yöntemdir.
- Verileri istenildiği şekilde optimize etme fırsatı sunar. Yani uygulama açısından kolaydır.

Genel dezavantajları şunlardır;

- Modelin uygulanması için düzenleme ve iterasyon parametresi gibi bazı girdilerin girilmesi gerekmektedir.
- Ölçeklendirmeye karşı hassastır, yanlış sonuçlar doğurabilir.

Stokastik Dereceli Azalma makine öğrenmesi yöntemine ilişkin görsel Şekil 3.15'te verilmiştir.



Şekil 3.15. SGD mimarisi (Akıncı, 2021)

3.6.1.6.Rastgele Orman (Random Forest-RF)

Rastgele Orman yöntemi için sistem eğitilmeden önce bazı parametrelerin ayarlanması gerekmektedir. Bu parametreler düğüm hacmi, ağaç sayısı ve toplam öznitelik sayısıdır. Bu parametreler belirlendikten sonra Rastgele Orman yöntemiyle sınıflandırmalar ve regresyon analizleri yapılabilir.

Rastgele Orman, aslında Karar Ağaçlarının birbiri ile bağlanmasından meydana gelir. Yöntemle kullanılan her ağaç eğitim kümesinden alınan veri örneklerinden oluşur. Daha sonra bu ağaçlar birbirileri ile bağlanır ve aralarından ilişki sağlanır. Ağaçların bağlanmasıyla Rastgele Orman Oluşur. Bu ağaçların çıktılarının ağırlıklı ortalamasını alarak doğru sonuca ulaşmaya çalışılır.

Rastgele Orman yöntemi finans, sağlık hizmeti, e-ticaret alanlarında sıklıkla kullanılmaktadır.

Genel olarak avantajları şunlardır;


- Aşırı öğrenmenin riski azdır.
- Esneklik sağlar.
- Önemli öznitelikleri belirlemede kolaylık sağlar.

Genel olarak dezavantajları şunlardır;

- Zaman alan bir süreçtir.
- Ekstra harici kaynak gerektirebilir (veri boyutu büyük olduğunda).

- Diğer yöntemlere göre daha yapısı daha karmaşıktır.

Rastgele Orman makine öğrenmesi yöntemine ilişkin görsel Şekil 3.16'da verilmiştir.



Şekil 3.16. Rastgele Orman mimarisi (Tafralı, 2022)

3.6.2. Uygulanan Derin Öğrenme Yöntemleri

3 adet veri setinin her birine 2 adet derin öğrenme yöntemi uygulanmıştır. Uygulanan derin öğrenme yöntemleri: CNN ve LSTM'dir.

3.6.2.1. Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN)

Evrişimsel Sinir Ağları (CNN) modeli günümüzde görüntü tanıma, görüntü sınıflandırma, nesne algılama ve tespiti vb. yapmak için kullanılan bir derin öğrenme modelidir.

CNN modeli görüntüleri sınıflandırmada, girdi görüntüleri almada ve görüntüleri en efektif şekilde tanımlayan bir çıkış verisi elde eder. CNN ile görüntüleri farklı yönleriyle ele alıp, bu görüntüleri birbirinden ayırt etmek mümkündür. Ayrıca CNN'de ön işleme adımları yok denecek kadar azdır.

CNN'in kendi içinde ayrılmış hazır mimarileri bulunmaktadır. Bu mimariler LeNet, AlexNet, GoogLeNet, VGGNet vb. olarak sıralanabilir.

CNN genel yapısında giriş katmanı haricinde verilerin bazı süreçlerden geçtiği katmanlar bulunmaktadır. Bu katmanlar; evrişimsel katman, aktivasyon katman, kesme (kırpma) katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıkış katmanı'dır.

a-) Evrişimsel Katman (Convolutional Layer): Bu katman sistemin temel yapı taşıdır. Sisteme verilen görüntünün özellikleri anlar. Bu özellikleri çıkarmak için görüntüye bazı filtreler uygular. Eğer görüntünün ayrıntılı özellikleri isteniyorsa birden fazla filtre kullanılabilir.


b-) Aktivasyon Katmanı (Non-Linearity Layer): Bu katman evrişimsel katmandan hemen sonra gelir. Bu katmanda gerekli aktivasyon fonksiyonları (ReLU gibi) kullanılır. En hızlı ve en doğru çalışan aktivasyon fonksiyonu ReLu'dur.

c-) Havuzlama Katmanı (Pooling Layer): Bu katman genellikle CNN'deki oluşturulan ardışık evrişimsel katmanları arasına eklenir. Bu katmanın hesaplama sayısını ve ağ içinde parametreleri azaltır. Bu sayede ağdaki olası risk durumları (uyumsuzluk vs.) kontrol altına alınmış olur. Birçok havuzlama (pooling) işlemi mevcuttur fakat en popülerleri max pooling'dir. Yine aynı prensipte çalışan average pooling, ve L2-norm pooling algoritmaları da kullanılmaktadır. Çoğu kullanıcı bu katmanı kullanmayı tercih etmez. Bunun yerine kullanılan filtreleri çeşitli şekillerde kaydırarak sonuca ulaşmayı hedeflerler.

d-) Düzleştirme Katmanı (Flattening Layer): Bu katmanın temel amacı bir sonraki tam bağlantı katmanı için giriş verileri hazırlamaktır. Basit bir şekilde düşünecek olursak bu katman çok boyutlu bir veriyi tek boyuta dönüştürüp tam bağlantı katmanına aktarır.

e-) Tam-Bağlantı Katmanı (Fully-Connected Layer): Bu katman CNN mimarisin en son katmanıdır. Bu katmanda kullanılacak aktivasyon fonksiyonu çıkış verisinin sayısına göre değişmektedir. Örneğin bu tezle müsilaçlı alan ve temiz alan diye 2 sınıfımız mevcut. Sınıf sayımız 2 olduğundan dolayı bu katmanda 'sigmoid' fonksiyonu kullanılmıştır.

CNN derin öğrenme yöntemine ilişkin görsel Şekil 3.17'de verilmiştir.




Şekil 3.17. CNN mimarisi (Ergin, 2018)

3.6.2.2.Uzun Kısa Süreli Bellek (LSTM)

LSTM yöntemi dahili bir belleğe sahip olan, her veri girişi için aynı işlevleri yerine getirebilen, geçmişe dönük verileri kullanan ve bu verilerle yeni sonuçlar üretebilen, geçmişe dönebildiği için tekrarlayan bir ağa sahip olan bir derin öğrenme modelidir.

LSTM çıktı verileri ürettikten sonra bu veri kopyalayarak geri besleme ile sisteme gönderir. Her seferinde bir önceki kullandığı veriyi hafızasında tutar. Kısaca LSTM’de tüm veriler birbirileri ile bağlantılıdır.

LSTM derin öğrenme yöntemine ilişkin görsel Şekil 3.18’de verilmiştir.




Şekil 3.18. LSTM mimarisi (Choubey, 2020)


4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Önerilen çalışma birkaç aşamadan oluşmaktadır. Öncelikle çalışma alanı olarak müsilağın yoğun olarak gözlemlendiği Marmara Denizi'ndeki Armutlu-ZeytinBağı bölgesi, deney alanı (su alanı) olarak seçilmiştir. Daha sonra seçilen bu bölge üzerinde manuel olarak 1300 adet nokta işaretlenmiştir. Müsilağın yoğun olduğu tarihlerde (Mayıs 2021), seçilen bu noktaların konumları GPS ile kaydedilmiş ve bu konumlar Sentinel-1 uydusuna aktarılmıştır. Veri setini oluşturmak için Sentinel-1 uydusu spektral band parametreleri (VV-VH) kullanılarak her bir nokta için yansımaya değerleri elde edildi. Yine aynı noktalar kullanılarak sadece tarih aralıkları değiştirilerek temiz su alanının da yansımaya değerleri elde edilmiş ve veri setine eklenmiştir. Amaç VV- VH- VV+VH bantları kullanılarak bölgenin müsilağlı olup olmadığını otomatik bir şekilde belirlemektir. Bu amaçla yansımaya değerlerinin bulunduğu veri setlerine, müsilağın otomatik olarak tespit edilebilmesi için makine öğrenmesi ve derin öğrenme modelleri uygulanmıştır. Önerilen çalışmaya ait blok diyagramı Şekil 3.1'de verilmiştir.


Oluşturulan veri setlerinin dağılımına ait şekiller sırasıyla Şekil 3.19'da Şekil 3.20'de, Şekil 3.21'de verilmiştir.



Şekil 3.19. VV veri setinin dağılımı



Şekil 3.20. VH veri setinin dağılımı



Şekil 3.21. VV+VH veri seti dağılımı

Sonuçlar konfüzyon matris, ROC eğrisi ve sistemin başarı oranı olarak üç kısma ayrılmaktadır. Konfüzyon matris 2x2'lik bir matristir. Bu matris üzerinde 1.satır 1.sütun ve 2.satır 2.sütun üzerinde bulunan değerler doğru tahmin edilen test verilerini içerirken 1.satır 2.sütun ve 2.satır 1.sütun üzerindeki değerler ise yanlış tahmin edilen sonuçları göstermektedir. ROC eğrisinin x ekseni bize yanlış pozitif oran (FPR) gösterirken y ekseni gerçek pozitif oranı (TPR) göstermektedir. ROC eğrisi üzerinden bulunan AUC

değeri bize sistemin başarısını sunmaktadır. Bu oran 0-1 arasında değişmektedir. Maksimum başarıya sahip bir sistem için bu değer 1 olmaktadır. Doğruluk oranı bize test verilerinin yüzde ne kadarının doğru bir şekilde tahmin edildiğini göstermektedir.


Sonuçlara ait grafikler ve diğer bulgular Python programlama dilini kullanan Jupyter Notebook üzerinden alınmıştır. Ayrıca uygulanan tüm yöntemler yine bu platform aracılığıyla yapılmıştır.

4.1. VV Bandına Ait Sonuçlar

Bu bölümde VV bandına ait veri setine uygulanan makine öğrenmesi ve derin öğrenme yöntemlerinin sonuçları sunulmaktadır.


4.1.1. Makine Öğrenmesi Sonuçları

K-En Yakın Komşuluk (KNN) modeli uygulanırken en önemli girdilerden biri komşuluk değeridir. Bu değer manuel olarak el ile girilmektedir. VV bandı için bu komşuluk değeri sırasıyla 1, 5 ve 10 olarak seçilerek uygulanmıştır. Tüm komşuluk değerleri için sonuçlarımız maksimum başarı göstermektedir. Bu da veri setimizin içerdiği değerlerin birbirinden ne kadar kolay ayırt edilebileceğini göstermektedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.22’de verilmiştir.




Şekil 3.22. VV bandı için kullanılan KNN modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Decision Tree-DT (Karar Ağaçları) uygulanırken maksimum derinlik 2 olarak seçilmiştir. Bu da dallanma sayısını azaltıp verileri daha dar bir süzgeçten geçirerek doğrudan sonuca ulaşma fırsatı sağlamaktadır. Uygulanan DT yöntemi için sistemin başarısı maksimum seviyededir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.23’te verilmiştir.




Şekil 3.23. VV bandı için kullanılan DT modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Naive Bayes (NB) modeli az veri ile büyük işler başarabilen bir sistemdir. Dolayısıyla toplam 5200 adet veri ile maksimum başarı oranı bu model ile elde edilmiştir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.24'te verilmiştir.




Şekil 3.24. VV bandı için kullanılan NB modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Destek Vektör Makineleri (SVM) modeli için kullanılan çekirdek özelliği linear olarak seçilmiştir. Bu model için de sistemin başarısı maksimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.25'te verilmiştir.




Şekil 3.25. VV bandı için kullanılan SVM modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Stokastik Dereceli Azalma (SGD) yöntemi her adımda rastgele alınan bir veri üzerinde işlem yaparak ve işlem yaptığı bu noktaları sürekli değiştirerek optimum sonuca ulaşmaya çalışır. Kullanılan bu model için sistemin başarısı optimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.26'da verilmiştir.



Şekil 3.26. VV bandı için kullanılan SGD modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Rastgele Orman (RF) modeli karar ağaçlarının çoklu hali olarak düşünülebilir. Ayrıca karar ağaçlarına nazaran daha verileri ayrıntılı olarak analiz ederek optimum sonuca ulaşmaya çalışır. Bu model için sistemin başarısı maksimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.27'de verilmiştir.



Şekil 3.27. VV bandı için kullanılan RF modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

4.1.2. Derin Öğrenme Sonuçları

Bu kısımda kullanılan CNN ve LSTM derin öğrenme modellerine ait sonuçlar bulunmaktadır.


CNN modeli için kullanılan katmanlar ve çıkış boyutları Şekil 3.28’de gösterilmiştir. Şekil 3.28. incelendiğinde toplamda 2 adet havuzlama, 3 adet konvolüsyon katmanı, 1 adet dense katmanı, 1 adet dense (çıkış) katmanı kullanılmıştır.

Layer (type)	Output Shape	Param #
conv2d_120 (Conv2D)	(None, 4, 4, 64)	128
max_pooling2d_80 (MaxPooling2D)	(None, 4, 4, 64)	0
conv2d_121 (Conv2D)	(None, 4, 4, 64)	4160
max_pooling2d_81 (MaxPooling2D)	(None, 4, 4, 64)	0
conv2d_122 (Conv2D)	(None, 4, 4, 64)	4160
dense_80 (Dense)	(None, 4, 4, 128)	8320
dense_81 (Dense)	(None, 4, 4, 1)	129
=====		
Total params: 16,897		
Trainable params: 16,897		
Non-trainable params: 0		


Şekil 3.28. VV bandı için kullanılan CNN modelindeki katmanlar ve çıkış boyutları

Kullanılan bu katmanlara göre sistemin başarı düzeyini gösteren grafik ve doğruluk oranı aynı görüntü üzerinde Şekil 3.29’da verilmiştir. Ayrıca modelin döngü (epoch) sayısına göre sistemin başarı düzeyinin değişiminin gözlemlenebileceği görüntü

Şekil 3.30’da verilmiştir. Şekil 3.30’da görüldüğü gibi sistemin başarısı, epoch sayısı arttıkça artmaktadır. Fakat bu epoch sayısını çok yüksek seçebileceğimiz anlamına gelmemektedir. Bunun sebebi derin öğrenme sisteminin aşırı öğrenme olayına maruz kalmasıdır. Bir derin öğrenme sisteminin aşırı öğrenmeye maruz kalması ile birlikte sonuç kısmında başarı oranı yüksek olmasına rağmen aykırı sonuçlar bulabilmektedir. Epoch 15 ve 20 için doğruluk değerleri incelendiğinde birbirine yakın değerler olduğu gözükmemektedir. Dolayısıyla bu sistem için en optimum epoch değeri 15 olarak gösterilebilir. Epoch 15 için doğruluk değeri yaklaşık 97% seviyesindedir.



Şekil 3.29. VV bandı için kullanılan CNN modelindeki döngü sayısı 10 için sistemin doğruluk ve kayıp grafikleri



Şekil 3.30. VV bandı için kullanılan CNN modelindeki (a) döngü sayısı 5 (b) döngü sayısı 10 (c) döngü sayısı 15 (d) döngü sayısı 20 için kayıp ve doğruluk değerleri


LSTM modeli için kullanılan katmanlar ve çıkış boyutları Şekil 3.31’de gösterilmiştir. Şekil 3.31 incelendiğinde toplamda 3 adet LSTM (Uzun Kısa Süreli Bellek) katmanı, 1 adet dense katmanı, 1 adet dense (çıkış) katmanı kullanılmıştır.

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 1, 64)	16896
lstm_1 (LSTM)	(None, 1, 64)	33024
lstm_2 (LSTM)	(None, 128)	98816
dense (Dense)	(None, 32)	4128
dense_1 (Dense)	(None, 1)	33

=====
Total params: 152,897
Trainable params: 152,897
Non-trainable params: 0
=====

Şekil 3.31. VV bandı için kullanılan LSTM modelindeki katmanlar ve çıkış boyutları

Kullanılan bu katmanlara göre sistemin başarı düzeyini gösteren grafik ve doğruluk oranı aynı görüntü üzerinde Şekil 3.32’de verilmiştir. Ayrıca modelin döngü (epoch) sayısına göre sistemin başarı düzeyinin değişiminin gözlemlenebileceği görüntü Şekil 3.33’te verilmiştir. Şekil 3.33’te görüldüğü gibi sistemin başarısı, epoch sayısı ile değişmektedir. Epoch sayısını 5’ten 7’ye çıkardığımız zaman doğruluk değerinin düştüğü görülmektedir. Bu da sistemin aşırı öğrenmeye maruz kaldığını göstermektedir. Dolayısıyla bu sistem için en optimum epoch değeri 5 olarak gösterilebilir. Epoch 5 için doğruluk değeri yaklaşık 97% seviyesindedir.



Şekil 3.32. VV bandı için kullanılan LSTM modelindeki döngü sayısı 2 için sistemin doğruluk ve kayıp grafikleri

Epoch 1/3
114/114 [=====] - 3s 7ms/step - loss: 0.3638 - accuracy: 0.7821 - val_loss: 0.1396 - val_accuracy: 0.9353
(a) Epoch=1

Epoch 1/7
114/114 [=====] - 3s 7ms/step - loss: 0.3960 - accuracy: 0.8077 - val_loss: 0.1733 - val_accuracy: 0.9583
Epoch 2/7
114/114 [=====] - 0s 4ms/step - loss: 0.1309 - accuracy: 0.9547 - val_loss: 0.1128 - val_accuracy: 0.9673
Epoch 3/7
114/114 [=====] - 0s 4ms/step - loss: 0.1178 - accuracy: 0.9582 - val_loss: 0.1590 - val_accuracy: 0.9590
Epoch 4/7
114/114 [=====] - 0s 4ms/step - loss: 0.1205 - accuracy: 0.9610 - val_loss: 0.1065 - val_accuracy: 0.9667
Epoch 5/7
114/114 [=====] - 0s 4ms/step - loss: 0.1210 - accuracy: 0.9580 - val_loss: 0.1035 - val_accuracy: 0.9660
Epoch 6/7
114/114 [=====] - 0s 4ms/step - loss: 0.1092 - accuracy: 0.9626 - val_loss: 0.1007 - val_accuracy: 0.9615
Epoch 7/7
114/114 [=====] - 0s 4ms/step - loss: 0.1141 - accuracy: 0.9580 - val_loss: 0.1509 - val_accuracy: 0.9583
(c) Epoch=7

Epoch 2/3
114/114 [=====] - 0s 4ms/step - loss: 0.1203 - accuracy: 0.95609
Epoch 3/3
114/114 [=====] - 0s 4ms/step - loss: 0.1220 - accuracy: 0.95622
(b) Epoch=3

Epoch 1/5
114/114 [=====] - 3s 7ms/step - loss: 0.4392 - accuracy: 0.71635
Epoch 2/5
114/114 [=====] - 0s 4ms/step - loss: 0.1315 - accuracy: 0.95615
Epoch 3/5
114/114 [=====] - 0s 4ms/step - loss: 0.1199 - accuracy: 0.95628
Epoch 4/5
114/114 [=====] - 0s 4ms/step - loss: 0.1123 - accuracy: 0.96667
Epoch 5/5
114/114 [=====] - 0s 4ms/step - loss: 0.1154 - accuracy: 0.96667
(d) Epoch=5


Şekil 3.33. VV bandı için kullanılan LSTM modelindeki (a) döngü sayısı 1 (b) döngü sayısı 3 (c) döngü sayısı 7 (d) döngü sayısı 5 için kayıp ve doğruluk değerleri

4.2. VH Bandına Ait Sonuçlar

Bu bölümde VH bandına ait veri setine uygulanan makine öğrenmesi ve derin öğrenme yöntemlerinin sonuçları sunulmaktadır. Makine öğrenmesi modelleri için başarı düzeyi VV bandı ile aynı (maksimum) çıkmaktadır. Dolayısıyla grafikler ve sonuçlar birbirinin aynısıdır.


4.1.1. Makine Öğrenmesi Sonuçları

K-En Yakın Komşuluk (KNN) modeli uygulanırken en önemli girdilerden biri komşuluk değeridir. Bu değer manuel olarak el ile girilmektedir. VH bandı için bu komşuluk değeri sırasıyla 1, 5 ve 10 olarak seçilerek uygulanmıştır. Tüm komşuluk değerleri için sonuçlarımız maksimum başarı göstermektedir. Bu da veri setimizin içerdiği değerlerin birbirinden ne kadar kolay ayırt edilebileceğini göstermektedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.34'te verilmiştir.




Şekil 3.34. VH bandı için kullanılan KNN modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Decision Tree-DT (Karar Ağaçları) uygulanırken maksimum derinlik 2 olarak seçilmiştir. Bu da dallanma sayısını azaltıp verileri daha dar bir süzgeçten geçirerek doğrudan sonuca ulaşma fırsatı sağlamaktadır. Uygulanan DT yöntemi için sistemin başarısı maksimum seviyededir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.35'te verilmiştir.



Şekil 3.35. VH bandı için kullanılan DT modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı


Naive Bayes (NB) modeli az veri ile büyük işler başarabilen bir sistemdir. Dolayısıyla toplam 5200 adet veri ile maksimum başarı oranı bu model ile elde edilmiştir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.36'da verilmiştir.



Şekil 3.36. VH bandı için kullanılan NB modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı


Destek Vektör Makineleri (SVM) modeli için kullanılan çekirdek özelliği linear olarak seçilmiştir. Bu model için de sistemin başarısı maksimum düzeydedir. Sonuçları

içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde **Şekil 3.37**'de verilmiştir.




Şekil 3.37. VH bandı için kullanılan SVM modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Stokastik Dereceli Azalma (SGD) yöntemi her adımda rastgele alınan bir veri üzerinde işlem yaparak ve işlem yaptığı bu noktaları sürekli değiştirerek optimum sonuca ulaşmaya çalışır. Kullanılan bu model için sistemin başarısı optimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde **Şekil 3.38**'de verilmiştir.



Şekil 3.38. VH bandı için kullanılan SGD modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Rastgele Orman (RF) modeli karar ağaçlarının çoklu hali olarak düşünülebilir. Ayrıca karar ağaçlarına nazaran daha verileri ayrıntılı olarak analiz ederek optimum sonuca ulaşmaya çalışır. Bu model için sistemin başarısı maksimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde **Şekil 3.39**'da verilmiştir.



Şekil 3.39. VH bandı için kullanılan RF modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

4.2.2. Derin Öğrenme Sonuçları

Bu kısımda kullanılan CNN ve LSTM derin öğrenme modellerine ait sonuçlar bulunmaktadır.


CNN modeli için kullanılan katmanlar ve çıkış boyutları Şekil 3.40'da gösterilmiştir. Şekil 3.40. incelendiğinde VV bandı ile aynı, toplamda 2 adet havuzlama, 3 adet konvolüsyon katmanı, 1 adet dense katmanı, 1 adet dense (çıkış) katmanı kullanılmıştır.

Layer (type)	Output Shape	Param #
conv2d_120 (Conv2D)	(None, 4, 4, 64)	128
max_pooling2d_80 (MaxPooling2D)	(None, 4, 4, 64)	0
conv2d_121 (Conv2D)	(None, 4, 4, 64)	4160
max_pooling2d_81 (MaxPooling2D)	(None, 4, 4, 64)	0
conv2d_122 (Conv2D)	(None, 4, 4, 64)	4160
dense_80 (Dense)	(None, 4, 4, 128)	8320
dense_81 (Dense)	(None, 4, 4, 1)	129
=====		
Total params: 16,897		
Trainable params: 16,897		
Non-trainable params: 0		


Şekil 3.40. VH bandı için kullanılan CNN modelindeki katmanlar ve çıkış boyutları

Kullanılan bu katmanlara göre sistemin başarı düzeyini gösteren grafik ve doğruluk oranı aynı görüntü üzerinde Şekil 3.41'da verilmiştir. Ayrıca modelin döngü

(epoch) sayısına göre sistemin başarı düzeyinin değişiminin gözlemlenebileceği görüntü Şekil 3.42’de verilmiştir. Şekil 3.42’de görüldüğü gibi sistemin başarısı, epoch sayısı arttıkça artmaktadır. Fakat bu epoch sayısını çok yüksek seçebileceğimiz anlamına gelmemektedir. Bunun sebebi derin öğrenme sisteminin aşırı öğrenme olayına maruz kalmasıdır. Bir derin öğrenme sisteminin aşırı öğrenmeye maruz kalması ile birlikte sonuç kısmında başarı oranı yüksek olmasına rağmen aykırı sonuçlar bulabilmektedir. Epoch 5 ve 10 olduğunda sistemin başarı düzeyi çok düşük seviyededir. Fakat sistemin Epoch değeri 15 olduğu zaman sistem aksine en yüksek başarı düzeyindedir. Bu sebepten ötürü sistemin başarısının optimum düzeyde olması için Epoch değeri 15-20 bandında seçilmelidir. Epoch 15 ve 20 için doğruluk değeri 100% seviyesindedir.



Şekil 3.41. VH bandı için kullanılan CNN modelindeki döngü sayısı 10 için sistemin doğruluk ve kayıp grafikleri




Şekil 3.42. VH bandı için kullanılan CNN modelindeki (a) döngü sayısı 5 (b) döngü sayısı 10 (c) döngü sayısı 20 (d) döngü sayısı 15 için kayıp ve doğruluk değerleri

LSTM modeli için kullanılan katmanlar ve çıkış boyutları Şekil 3.43’de gösterilmiştir. Şekil 3.43. incelendiğinde VV bandı ile aynı, toplamda 3 adet LSTM (Uzun Kısa Süreli Bellek) katmanı, 1 adet dense katmanı, 1 adet dense (çıkış) katmanı kullanılmıştır.


Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 1, 64)	16896
lstm_1 (LSTM)	(None, 1, 64)	33024
lstm_2 (LSTM)	(None, 128)	98816
dense (Dense)	(None, 32)	4128
dense_1 (Dense)	(None, 1)	33
=====		
Total params: 152,897		
Trainable params: 152,897		
Non-trainable params: 0		

Şekil 3.43. VH bandı için kullanılan LSTM modelindeki katmanlar ve çıkış boyutları

Kullanılan bu katmanlara göre sistemin başarı düzeyini gösteren grafik ve doğruluk oranı aynı görüntü üzerinde Şekil 3.44’te verilmiştir. Ayrıca modelin döngü (epoch) sayısına göre sistemin başarı düzeyinin değişiminin gözlemlenebileceği görüntü Şekil 3.45’te verilmiştir. Şekil 3.45’te görüldüğü gibi sistemin başarısı, epoch sayısı ile değişmemektedir. Epoch sayısını 1 olduğu zaman bile sistemin başarısı maksimum düzeydedir. Fakat kayıp değerlerde artma azalma meydana gelmektedir. Bu da sistemin epoch değeri arttıkça aşırı öğrenmeye maruz kalmasından dolayıdır. Bu yüzden bu sistem için en optimum epoch değeri 3 olarak gösterilebilir. Epoch 3 için doğruluk değeri 100% seviyesindedir.



Şekil 3.44. VH bandı için kullanılan LSTM modelindeki döngü sayısı 3 için sistemin doğruluk ve kayıp grafikleri




Şekil 3.45. VH bandı için kullanılan LSTM modelindeki (a) döngü sayısı 1 (b) döngü sayısı 3 (c) döngü sayısı 7 (d) döngü sayısı 5 için kayıp ve doğruluk değerleri

4.3. VV + VH Bandına Ait Sonuçlar

Bu bölümde VV ve VH bantlarına ait sonuçlar birleştirilip elde edilen VV+VH veri setine uygulanan makine öğrenmesi ve derin öğrenme yöntemlerinin sonuçları sunulmaktadır.


4.3.1. Makine Öğrenmesi Sonuçları

K-En Yakın Komşuluk (KNN) modeli uygulanırken en önemli girdilerden biri komşuluk değeridir. Bu değer manuel olarak el ile girilmektedir. VV bandı için bu komşuluk değeri sırasıyla 1, 5 ve 10 olarak seçilerek uygulanmıştır. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.46’da verilmiştir.




Şekil 3.46. VV+VH bant verilerini içeren veri seti için kullanılan KNN modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranları

Decision Tree-DT (Karar Ağaçları) uygulanırken maksimum derinlik 2 olarak seçilmiştir. Bu da dallanma sayısını azaltıp verileri daha dar bir süzgeçten geçirerek doğrudan sonuca ulaşma fırsatı sağlamaktadır. Uygulanan DT yöntemi için sistemin başarısı VV ve VH bantlarını içeren ayırık veri setlerine oranla daha düşük seviyededir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.47’de verilmiştir.




Şekil 3.47. VV+VH bandı için kullanılan DT modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Naive Bayes (NB) modeli az veri ile büyük işler başarabilen bir sistemdir. Dolayısıyla toplam 5200 adet veri ile maksimum başarı oranı bu model ile elde edilmiştir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.48’de verilmiştir.




Şekil 3.48. VV+VH bandı için kullanılan NB modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Destek Vektör Makineleri (SVM) modeli için kullanılan çekirdek özelliği linear olarak seçilmiştir. Bu model için de sistemin başarısı maksimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.49’da verilmiştir.




Şekil 3.49. VV+VH bandı için kullanılan SVM modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Stokastik Dereceli Azalma (SGD) yöntemi her adımda rastgele alınan bir veri üzerinde işlem yaparak ve işlem yaptığı bu noktaları sürekli değiştirerek optimum sonuca ulaşmaya çalışır. Kullanılan bu model için sistemin başarısı optimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde Şekil 3.50’de verilmiştir.



Şekil 3.50. VV+VH bandı için kullanılan SGD modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

Rastgele Orman (RF) modeli karar ağaçlarının çoklu hali olarak düşünülebilir. Ayrıca karar ağaçlarına nazaran daha verileri ayrıntılı olarak analiz ederek optimum sonuca ulaşmaya çalışır. Bu model için sistemin başarısı maksimum düzeydedir. Sonuçları içeren konfüzyon matrisi, ROC eğrisi ve başarı oranı aynı görüntü üzerinde **Şekil 3.51**'de verilmiştir.



Şekil 3.51. VV+VH bandı için kullanılan RF modeli için sistemin ROC eğrisi, konfüzyon matrisi ve doğruluk oranı

4.3.2. Derin Öğrenme Sonuçları


Bu kısımda VV+VH bandına uygulanan CNN ve LSTM derin öğrenme modellerine ait sonuçlar bulunmaktadır.

CNN modeli için kullanılan katmanlar ve çıkış boyutları Şekil 3.52'de gösterilmiştir. Şekil 3.52. incelendiğinde toplamda 2 adet havuzlama, 3 adet konvolüsyon katmanı, 1 adet dense katmanı, 1 adet dense (çıkış) katmanı kullanılmıştır.


Layer (type)	Output Shape	Param #
conv2d_12 (Conv2D)	(None, 2, 2, 64)	128
max_pooling2d_8 (MaxPooling 2D)	(None, 2, 2, 64)	0
conv2d_13 (Conv2D)	(None, 2, 2, 64)	4160
max_pooling2d_9 (MaxPooling 2D)	(None, 2, 2, 64)	0
conv2d_14 (Conv2D)	(None, 2, 2, 64)	4160
dense_8 (Dense)	(None, 2, 2, 128)	8320
dense_9 (Dense)	(None, 2, 2, 1)	129
=====		
Total params: 16,897		
Trainable params: 16,897		
Non-trainable params: 0		

Şekil 3.52. VV+VH bandı için kullanılan CNN modelindeki katmanlar ve çıkış boyutları

Kullanılan bu katmanlara göre sistemin başarı düzeyini gösteren grafik ve doğruluk oranı aynı görüntü üzerinde Şekil 3.53’de verilmiştir. Ayrıca modelin döngü (epoch) sayısına göre sistemin başarı düzeyinin değişiminin gözlemlenebileceği görüntü Şekil 3.54’te verilmiştir. Şekil 3.54’te görüldüğü gibi sistemin başarısı, epoch sayısı arttıkça artmaktadır. Fakat bu epoch sayısını çok yüksek seçebileceğimiz anlamına gelmemektedir. Bunun sebebi derin öğrenme sisteminin aşırı öğrenme olayına maruz kalmasıdır. Bir derin öğrenme sisteminin aşırı öğrenmeye maruz kalması ile birlikte sonuç kısmında başarı oranı yüksek olmasına rağmen aykırı sonuçlar bulabilmektedir. Epoch 5 ve 10 olduğunda sistemin başarı en iyi düzeydedir. Fakat sistemin Epoch değeri 15 ve üzeri seçildiğinde sistemin başarısında orantısız artışlar ve azalmalar olduğu gözlemlenmektedir. Bu da sistemin aşırı öğrenmeye girdiğini göstermektedir. Bu sebepten ötürü sistemin başarısının optimum düzeyde olması için Epoch değeri 10 bandında seçilmelidir. Epoch 10 için doğruluk değeri 71.83% seviyesindedir.



Şekil 3.53. VV+VH bandı için kullanılan CNN modelindeki döngü sayısı 10 için sistemin doğruluk ve kayıp grafikleri




Şekil 3.54. VV+VH bandı için kullanılan CNN modelindeki (a) döngü sayısı 5 (b) döngü sayısı 10 (c) döngü sayısı 20 (d) döngü sayısı 15 için kayıp ve doğruluk değerleri

LSTM modeli için kullanılan katmanlar ve çıkış boyutları Şekil 3.55'te gösterilmiştir. Şekil 3.55 incelendiğinde toplamda 3 adet LSTM (Uzun Kısa Süreli Bellek) katmanı, 1 adet dense katmanı, 1 adet dense (çıkış) katmanı kullanılmıştır.

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 1, 64)	16896
lstm_1 (LSTM)	(None, 1, 64)	33024
lstm_2 (LSTM)	(None, 128)	98816
dense (Dense)	(None, 32)	4128
dense_1 (Dense)	(None, 1)	33
=====		
Total params: 152,897		
Trainable params: 152,897		
Non-trainable params: 0		

Şekil 3.55. VV+VH bandı için kullanılan LSTM modelindeki katmanlar ve çıkış boyutları

Kullanılan bu katmanlara göre sistemin başarı düzeyini gösteren grafik ve doğruluk oranı aynı görüntü üzerinde Şekil 3.56'da verilmiştir. Ayrıca modelin döngü (epoch) sayısına göre sistemin başarı düzeyinin değişiminin gözlemlenebileceği görüntü Şekil 3.57'de verilmiştir. Şekil 3.57'de görüldüğü gibi sistemin başarısı, epoch sayısı ile orantılı olarak artmaktadır. Fakat epoch sayısı 7 için sistemin 6. epochtaki değeri 7.Epochtaki değerinden fazladır. Bunun sebebi sistemin aşırı öğrenmeye maruz kalmasıdır. Dolayısıyla seçilebilecek en optimum epoch değeri 3-6 aralığında olmalıdır. Epoch 3 için doğruluk değeri 86.6% seviyesindedir.



Şekil 3.56. VV+VH bandı için kullanılan LSTM modelindeki döngü sayısı 3 için sistemin doğruluk ve kayıp grafikleri

228/228 [=====] - 7s 9ms/step - loss: 0.4595 - accuracy: 0.7341 - val_loss: 0.3362 - val_accuracy: 0.8 833	Epoch 1/3 228/228 [=====] - 7s 9ms/step - loss: 0.4556 - accuracy: 0.7554 - val_loss: 0.3212 - val_accuracy: 0.8 651
(a) Epoch=1	Epoch 2/3 228/228 [=====] - 1s 6ms/step - loss: 0.3161 - accuracy: 0.8510 - val_loss: 0.3013 - val_accuracy: 0.8 333
Epoch 1/7 228/228 [=====] - 7s 10ms/step - loss: 0.4330 - accuracy: 0.7835 - val_loss: 0.3372 - val_accuracy: 0.8 8721	Epoch 3/3 228/228 [=====] - 1s 6ms/step - loss: 0.2900 - accuracy: 0.8551 - val_loss: 0.2746 - val_accuracy: 0.8 660
Epoch 2/7 228/228 [=====] - 1s 6ms/step - loss: 0.3405 - accuracy: 0.8224 - val_loss: 0.3347 - val_accuracy: 0.7 808	(b) Epoch=3
Epoch 3/7 228/228 [=====] - 1s 6ms/step - loss: 0.3166 - accuracy: 0.8378 - val_loss: 0.2925 - val_accuracy: 0.8 696	Epoch 1/5 228/228 [=====] - 7s 9ms/step - loss: 0.4276 - accuracy: 0.7791 - val_loss: 0.3615 - val_accuracy: 0.8 413
Epoch 4/7 228/228 [=====] - 1s 6ms/step - loss: 0.2865 - accuracy: 0.8516 - val_loss: 0.2718 - val_accuracy: 0.8 859	Epoch 2/5 228/228 [=====] - 1s 6ms/step - loss: 0.3313 - accuracy: 0.8474 - val_loss: 0.3487 - val_accuracy: 0.8 346
Epoch 5/7 228/228 [=====] - 1s 6ms/step - loss: 0.2663 - accuracy: 0.8724 - val_loss: 0.3300 - val_accuracy: 0.8 500	Epoch 3/5 228/228 [=====] - 1s 7ms/step - loss: 0.3042 - accuracy: 0.8527 - val_loss: 0.2854 - val_accuracy: 0.8 535
Epoch 6/7 228/228 [=====] - 1s 6ms/step - loss: 0.2700 - accuracy: 0.8651 - val_loss: 0.2435 - val_accuracy: 0.9 861	Epoch 4/5 228/228 [=====] - 1s 7ms/step - loss: 0.2751 - accuracy: 0.8587 - val_loss: 0.2771 - val_accuracy: 0.8 875
Epoch 7/7 228/228 [=====] - 1s 6ms/step - loss: 0.2490 - accuracy: 0.8887 - val_loss: 0.2362 - val_accuracy: 0.8 978	Epoch 5/5 228/228 [=====] - 1s 6ms/step - loss: 0.2529 - accuracy: 0.8758 - val_loss: 0.2320 - val_accuracy: 0.9 845
(c) Epoch=7	(d) Epoch=5

Şekil 3.57. VV+VH bandı için kullanılan LSTM modelindeki (a) döngü sayısı 1 (b) döngü sayısı 3 (c) döngü sayısı 7 (d) döngü sayısı 5 için kayıp ve doğruluk değerleri

Uygulanan makine öğrenmesi ve derin öğrenme modellerine ait başarı oranları Tablo 3.2’de verilmiştir. Makine öğrenmesi ve derin öğrenme modellerinin her bir veri seti üstündeki başarı oranlarını gösteren istatistiksel metrikler Tablo 3.2’de verilmiştir. Tablo incelendiğinde makine öğrenmesi modellerinin başarısı dikkat çekmektedir. Tüm veri setleri için uygulanan bu makine öğrenmesi modellerindeki başarı oranlarının minimum değeri 99% seviyesindedir. Bu da veri setimizin birbirinden ayrılabilen veriler içerdiğini ve makine öğrenmesi modelleri ile sağlıklı bir şekilde çalışılabileceğini göstermektedir. Fakat derin öğrenme modellerinin tüm veri setlerindeki başarısı makine öğrenmesi modelleri ile kıyaslandığında daha düşük kalmaktadır. Bunun sebebi veri setlerimizin çok sayıda veri içermemesinden dolayı veya derin öğrenme sistemindeki ağırlık değerlerinin mutlak sonuç için uygun alınamamasından kaynaklı olabilir. VV ve VH veri setleri ayrı ayrı derin öğrenme modellerinde de yüksek başarı oranı vermiştir. Fakat VV+VH bandının birleştirilmiş olduğu veri setinde başarı oranı yaklaşık 30% oranında düşmüştür. Bu oran her 10 veriden 3’ünün yanlış tahmin edilmesi anlamına gelmektedir.

Tablo 3.2. Veri setlerine uygulanan modellerin yüzde başarı oranları

	Derin Öğrenme		Makine Öğrenmesi					
	CNN	LSTM	DT	RF	NB	SGD	KNN	SVM
VV Bandına Ait Veri Seti	84%	96%	100%	100%	100%	100%	100%	100%
VH Bandına Ait Veri Seti	97%	100%	100%	100%	100%	100%	100%	100%
VV+VH Bandına Ait Veri Seti	72%	87%	98%	99%	99%	99%	99%	99%

Literatürde yapılan benzer çalışmalar karşılaştırma tablosu olarak Tablo 3'te verilmiştir. Tablo 3.3 incelendiğinde geçmiş zamanlarda yapılan çalışmalara kıyasla sistemimizin başarı oranı yüksektir. Tablodan da görüleceği üzere daha önce müsilaçlı bölge Sentinel-1 uydusu ile çalışılmamıştır. Bu da çalışmamızın özgünlüğünü ortaya koymaktadır. Çalışmada sadece derin öğrenme ile değil makine öğrenmesi kullanılarak da maksimuma yakın sonuçlar elde edilmiştir.

Tablo 3.3. Uydu görüntülerin yardımıyla müsilaçlı bölge üzerinde nesne tespiti üzerine yapılan çalışmaların karşılaştırılması

Veri Seti Aracı	Deney Alanı	Doğruluk	Metot	Referans
Sentinel-2A & MODIS	Müsilaçlı Bölge	90%	Musilaç İndex (MI) Formülü	(Yagci et al. 2022)
Sentinel-2	Müsilaçlı Bölge	97%	Vescovi Index + LR + (RF) & U-Net Segmentasyon	(Abaci et al. 2022)
Sentinel-2 & Landsat-8	Müsilaçlı Bölge	99%	Rastgele Orman (RF)	(Kavzaoglu et al. 2021)
Sentinel-2	Müsilaçlı Bölge	99.9%	Rastgele Orman (RF)	(Ugur et al. 2021)
Google Earth Pro Uydusu	Müsilaçlı Bölge	100%	CNN Deep Learning	(Haciefendioglu et al. 2022)
Sentinel-2	Müsilaçlı Bölge	>90%	Rastgele Orman (RF)	(Kavzaoglu et al. 2021)
Sentinel-1	Müsilaçlı Bölge	100%	LSTM, CNN, DT, NB, SVM, RF, SGD, KNN	Önerilen Yaklaşım

5. SONUÇLAR VE ÖNERİLER

Günümüz dünyasında uzaktan algılama sistemlerinin önemi her geçen gün daha çok kullanılmakta ve önemi artmaktadır. Kullanılan bu uzaktan algılama yöntemleri sadece uydu görüntüleri ile sınırlandırılmamalıdır. Sonuç olarak uzak bir mesafedeki nesnenin tespiti bile bir uzaktan algılama çalışmasıdır. Ve bu tespitler sensörler ile de yapılabilmektedir. Önerilen çalışmada uzaktan kullanılan algılama sistemi Sentinel-1 uydusudur.

Bu çalışma 2021 Mayıs ayında Marmara Denizi'ndeki müsilaj olayından esinlenerek yapılmıştır. Ayrıca günümüzde de hala kıyı bölgelerinde, sahillerde ortaya çıkabilen bu müsilajlar deniz ekosistemine ciddi zararlar verebilmektedir. İnsanlar tarafından çok bilinmese de bu müsilaj oluşumu gözle görülmeyen deniz tabanında da meydana gelebilmektedir. Meydana gelen bu müsilaj deniz tabanında bulunan bitkilere ciddi zararlar verebilmekte ve bitkilerde yapısal bozukluk ve işlev eksiklikleri meydana getirebilmektedir. Bunun yanında müsilaj deniz yüzeyinde bulanıklık, tortu şeklinde bir yapı oluşturmaktadır. Bu yapılar hem doğal deniz görüntüsünü bozmakta hem de görüntü kirliliği oluşturarak doğal dengeyi bozmaktadır. Bunun gibi birçok etkisi bulunmaktadır. Bunlardan en önemlilerinden biri ise balıkçılık faaliyetlerinin sürdürülebilirliğini kısıtlamasıdır. Müsilajın yoğun olduğu bölgelerde balıklar etkilenmekte ve balık ölümleri meydana gelebilmektedir. Buna bağlı olarak balık sayıları azalmakta ve balıkçılık faaliyetlerinde kısıt meydana getirebilmektedir.

Önerilen çalışmada 2021 Mayıs ayında müsilajın etkisinin yoğun hissedildiği Marmara Denizi'ndeki Armutlu-Zeytinbağı bölgesi müsilaj alanı olarak belirlenmiştir. Daha sonra bu bölge üzerinden toplamda 1300 adet nokta GEE-CE platformu üzerinden işaretlenmiştir. İşaretlenen bu noktalar GEE-CE platformu (java altyapısına sahip) üzerinden kodlama ile Sentinel-1 uydusuna 4 farklı tarih aralığında aktarılmıştır. Bu tarihler 17 Mayıs, 22 Mayıs, 21 Haziran, 22 Haziran'dır. 17 Mayıs ve 22 Mayıs tarihleri müsilajlı alan verilerini içermektedir. 21 Haziran ve 22 Haziran tarihleri ise temiz alan verilerini içermektedir. Bu verilerin noktalar değişmeden sadece tarih aralığı değiştirilerek alındığı unutulmamalıdır. Sentinel-1 uydusu VV-VH bant parametreleri kullanılarak bu noktaların bu bantlara karşılık gelen geri saçılım değerleri alınıp 2 adet veri setinde birleştirilmiştir. Bu 2 veri seti daha sonra birleştirilerek 1 adet veri seti daha oluşturulmuştur. Bu 3 adet veri setine ayrı ayrı toplamda 6 makine öğrenmesi modeli, 2 derin öğrenme modeli uygulanmıştır.

5.1 Sonuçlar

Veri setlerine uygulanan makine öğrenmesi ve derin öğrenme modellerinin sonuçları bu kısımda sunulmaktadır. Uygulanan makine öğrenmesine ait sonuçlar konfüzyon matrisi, ROC eğrisi ve yüzdece doğruluk oranı, derin öğrenmeye ait sonuçlar ise doğruluk-kayıp grafiği ve değerleri, model katmanları ve epoch (döngü) sayısına göre sistemin değişen başarı oranlarını içermektedir. Konfüzyon matrisi 2x2'lik bir matristir. Bu matriste diyagonal olan değerler doğru tahmin edilen değerleri diyagonal olmayan değerler ise yanlış tahmin edilen değerleri göstermektedir. Örneğin VV+VH bandı için uygulana DT modeli için konfüzyon matrisini incelediğimizde 1560 adet test verisinden 1532 adet verinin doğru tahmin edildiği, 28 verinin ise yanlış tahmin edildiği görülmektedir. Bu değerlerden doğruluk oranı da hesaplanabilir. Bu değer $(1532/1560) * 100 = 98.2\%$ 'dir. ROC eğrisi üzerinde bulunan AUC değeri de bize sistemin başarı oranını vermektedir. Konfüzyon matrisi üzerinden hesapladığımız değerler kıyaslayınca değerlerin aynı olduğu görülmektedir. Doğruluk oranı konfüzyon matrisi dışında Jupyter Notebook üzerinden metrics.score kullanılarak ayrıca bulunmuştur. Bu değer de yine aynı şekilde hem ROC eğrisi hem de konfüzyon matrisi ile desteklenmektedir.

Derin öğrenme modellemeleri için kullanılan doğruluk kayıp grafikleri ve doğruluk oranı, model katmanları, epoch sayısına oranla değişen doğruluk değerleri yine Jupyter Notebook üzerinden elde edilmiştir.

Bir sonraki kısımda müsilağ en kolay, en doğru ve en zahmetsiz şekilde nasıl tespit edilebilir, müsilağın önüne geçmek mümkün mü, müsilağ tespiti sonra neler yapılmalı gibi sorulara değinilmiştir.

5.2 Öneriler ve Tartışma

Önerin bu tez çalışmasında müsilağın deniz ekosistemi üzerine etkilerinin yanı sıra dolaylı yoldan insan yaşamını da etkileyebileceği açıklanmıştır. Dolayısıyla bu olumsuz etkileri yok etmek veya etkilerini azaltmak için birçok yöntem geliştirebilir. Bu çalışmada önerilen yöntem gözle tespit edilemeyecek yerlerde müsilağın tespiti için makine öğrenmesi ve derin öğrenme yöntemlerinin kullanılabilirliğini sunmaktadır. Önerilen çalışmada Mayıs 2021 tarihinde Marmara Denizi'nde meydana gelen müsilağ bölgesine ait veriler kullanılmıştır. Bu veriler SAR (Sentetik Açıklıklı Radar) olan Sentinel-1 uydusu kullanılarak elde edilmiştir. Uydu çalışılan bölgeye sinyaller göndererek bu sinyallerin geri saçılım değerleri sayısal olarak vermektedir. Dolayısıyla bu uzaktan algılama sistemlerini kullanmak hem maliyetsiz hem zahmetsiz hem de çok kolaydır.

GEE-CE (Google Earth Engine-Code Editor) platformu aracılığıyla elde edilen veri setleri csv formatında alınarak manuel olarak düzenlenmiş ve makine öğrenmesi ve derin öğrenme modellerinin uygulanabileceği hale getirilmiştir. Buradan yola çıkarak verilerin elde edilme aşamasında bu platform kullanılarak çeşitli kodlar eşliğinde csv formatı halinde veriler elde edebilmek mümkündür. Dolayısıyla uzaktan algılama sistemleri ile birlikte bu platform müsilaçlı alan tespiti için kullanılabilir.

Uygulanan modellerin başarı oranlarına bakıldığında en yüksek başarı oranları VV ve VH bandına ait veri setlerinin ayrı 2 veri seti olarak kullanıldığı zaman elde edilmiştir. VH bandının VV bandına göre derin öğrenme modelleri için daha verimli ve başarılı olduğu fakat makine öğrenmesi modelleri için her iki veri setinin de maksimum verimlilikte çalıştığı görülmektedir. VV+VH bandına ait veri setine bakıldığında başarı düzeyi diğer iki ayrı veri setine oranla derin öğrenme başarısı düşük seviyededir. Fakat makine öğrenmesi başarı oranı yüksek seviyededir. Buradan elde edilebilecek bazı çıkarımlar şunlardır;

- Derin öğrenme modeli kullanılacaksa en uygun bant VH bandıdır.
- Hem VV hem VH bandına ait veriler karma olarak değil de ayrı ayrı incelendiğinde çok daha yüksek sonuçlar vermektedir.
- Makine öğrenmesi modelleri VV, VH, VV+VH modelleri için çok yüksek verimlilikte çalışmaktadır.
- Veri sayısı arttıkça derin öğrenme modellerinin başarı oranları artabilmektedir. Dolayısıyla çok daha fazla örnek sayısına sahip VV+VH karma veri seti derin öğrenme modelleri için yüksek sonuçlar verebilir.

Önerilen çalışmamız diğer çalışmalarla kıyaslandığında birçok açıdan ön plandadır. Müsilaçlı bölge daha önceden hiç SAR görüntüleri ile çalışılmamıştır. Bunun yerine optik görüntüler ile çalışılmıştır. Ayrıca makine öğrenmesi modellerinden DT, NB, SGD, KNN, derin öğrenme modellerinden LSTM daha önce müsilaçlı veriler üzerinde kullanılmamıştır. Elde edilen sonuçlara bakılarak müsilaçlı bölge için SAR görüntülerinin de kullanılabilmesi ve çok yüksek doğruluk değerleri elde edilebileceği açıktır.

Tüm bu sonuçlar ele alındığında önerilen tez çalışmasının önemi ve doğruluk derecesi yüksek seviyededir. Nihayetinde bu çalışmaya bakarak, makine öğrenmesi ve derin öğrenme modelleri kullanılarak müsilaçlı alan tespiti yapılabilir ve bunun sonucunda ise erken safhada müdahale edilerek deniz ekosistemine olası ciddi zararlar,

müsilajın yaydığı kötü koku, görüntü kirliliği, balıkçılık aktivitelerinin kısıtlanması, denizdeki oksijen seviyesinin azalması gibi durumların önüne geçilebilir.

KAYNAKLAR

- Abaci, B., Dede, M., Yuksel, S. E., & Yilmaz, M. (2022, April). Mucilage detection from hyperspectral and multispectral satellite data. In *Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imaging XXVIII* (Vol. 12094). SPIE.
- 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. DOI: 10.17694/bajece.863147
- Acar, E. (2020). Detection of unregistered electric distribution transformers in agricultural fields with the aid of Sentinel-1 SAR images by machine learning approaches. *Computers and Electronics in Agriculture*, 175, 105559.
- Agency, E. S., & European Space Agency. (2020). *The European Space Agency*. ESA Sentinel Online Website: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1> [Eriřim Tarihi: 31 Ocak 2023].
- AKCA, M. F. (2020, Ağustos 25). *Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi-2)*. Medium: <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vektor-makineleri-makine-ogrenmesi-serisi-2-94e576e4223e> [Eriřim Tarihi: 31 Ocak 2023].
- Akdemir, B., Güneř, S. and Genç, A., 2009, Artificial neural network training models in prediction of concrete compressive strength using euclidean normalization method, *3rd Int. Conf. on Complex Systems and Applications-ICCSA 2009*, Le Havre-France, 160-165.
- Akıncı, B. (2021, Nisan 11). *GRADIENT DESCENT (DERECELİ AZALMA) NEDİR ?* Medium: <https://medium.com/@bsradogn/gradient-descent-dereceli-azalma-nedir-49333e74c0f0> [Eriřim Tarihi: 31 Ocak 2023].
- Anomin, (2021). Get Started with Earth Engine Eriřim: [<https://developers.google.com/earth-engine/guides/getstarted>], Eriřim Tarihi: 15 Mayıs 2023.
- Attema, E., Bargellini, P., Edwards, P., Levrini, G., Lokas, S., Moeller, L., ... & Snoeij, P. (2007). Sentinel-1-the radar mission for GMES operational land and sea services. *ESA bulletin*, 131, 10-17.
- 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.
- Bakış, E. & Acar, E. (2023) Aktif Uzaktan Algılama Verileri Kullanılarak LSTM (Uzun Kısa Süreli Bellek) Yöntemi İle Müsilaj Bölgelerinin Otomatik Olarak Tespit Edilmesi. ''AY, F. Z. *Uluslararası Biliřim Kongresi Bildiriler Kitabı*'' , 20 Mart 2023, Batman.
- Choubey, V. (2020, Temmuz 23). *Understanding Recurrent Neural Network (LSTM) and Long Short Term Memory(LSTM)*. Medium: <https://medium.com/analytics-vidhya/undestanding-recurrent-neural-network-LSTM-and-long-short-term-memory-lstm-30bc1221e80d> [Eriřim Tarihi: 31 Ocak 2023].
- Ergin, T. (2018, Ekim 2). *Convolutional Neural Network (ConvNet ya da CNN) nedir, nasıl çalışır?* Medium: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> [Eriřim Tarihi: 31 Ocak 2023].

- 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.
- Haciefendioğlu, K., Başağa, H. B., Baki, O. T., & Bayram, A. (2023). Deep learning-driven automatic detection of mucilage event in the Sea of Marmara, Turkey. *Neural Computing and Applications*, 35(9), 7063-7079.
- Kavzoğlu, T., & Göral, M. (2022). Google Earth Engine for Monitoring Marine Mucilage: Izmit Bay in Spring 2021. *Hydrology*, 9(8), 135.
- Kavzoğlu, T., Çölkesen, İ., Sefercik, U. G., & Öztürk, M. Y. (2021). Marmara Denizi'ndeki müsilaj oluşumlarının çok zamanlı optik ve termal uydu görüntülerinden makine öğrenme algoritması ile tespiti ve analizi. *Harita Dergisi*, 166, 1-9.
- KAVZOĞLU, T., TONBUL, H., ÇÖLKESEN, İ., & SEFERCİK, U. G. (2021). The use of object-based image analysis for monitoring 2021 marine mucilage bloom in the sea of marmara. *International Journal of Environment and Geoinformatics*, 8(4), 529-536.
- Kumar, L., & Mutanga, O. (2018). Google Earth Engine applications since inception: Usage, trends, and potential. *Remote Sensing*, 10(10), 1509.
- Mateo-García, G., Gómez-Chova, L., Amorós-López, J., Muñoz-Marí, J., & CampsValls, G. (2018). Multitemporal cloud masking in the Google Earth Engine. *Remote Sensing*, 10(7), 1079.
- Praticò, S., Solano, F., Di Fazio, S., & Modica, G. (2021). Machine learning classification of mediterranean forest habitats in google earth engine based on seasonal sentinel2 time-series and input image composition optimisation. *Remote Sensing*, 13(4), 586.
- Sawla, S. (2018, Haziran 9). *Introduction to Naive Bayes for Classification*. Medium: <https://medium.com/@srishtisawla/introduction-to-naive-bayes-for-classification-baefeb43a2d> [Erişim Tarihi: 31 Ocak 2023].
- Şimşek Bağcı, R. (2022). *Derin transformer kodlayıcı tekniği ve farklı zaman-serisi uydu görüntüleri kullanılarak pamuk ve mısır bitki alanlarının belirlenmesi* (Master's thesis, Batman Üniversitesi Lisansüstü Eğitim Enstitüsü).
- Tafraı, S. (2022, Haziran 6). *Yapay Öğrenme: Rastgele Orman*. Medium: <https://medium.com/machine-learning-türkiye/yapay-öğrenme-rastgele-orman-e8debdc886e7> [Erişim Tarihi: 31 Ocak 2023].
- Tassan, S. (1993). An algorithm for the detection of the White-Tide ("mucilage") phenomenon in the Adriatic Sea using AVHRR data. *Remote sensing of environment*, 45(1), 29-42.
- Torres, R., Snoei, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., ... & Rostan, F. (2012). GMES Sentinel-1 mission. *Remote sensing of environment*, 120, 9-24.
- Tuzcu Kokal, A., Olgun, N., & Musaoğlu, N. (2022). Detection of mucilage phenomenon in the Sea of Marmara by using multi-scale satellite data. *Environmental Monitoring and Assessment*, 194(8), 585.
- Uğur, A. C. A. R., YILMAZ, O. S., ÇELEN, M., ATEŞ, A. M., GÜLGİN, F., & ŞANLI, F. B. (2021). Determination of mucilage in the sea of marmara using remote sensing techniques with google earth engine. *International Journal of Environment and Geoinformatics*, 8(4), 423-434.
- UĞUR, N. G., & DİNÇER, F. F. İ. Avrupa Birliği Turizm Politikalarının Türk Turizmine Etkilerinin Çevre ve Sürdürülebilirlik Bağlamında Analizi: Marmara Denizi Müsilaj Sorunu. *Uluslararası Kültürel ve Sosyal Araştırmalar Dergisi (UKSAD)*, 8(1), 48-61.

- Ulgen, E. K. (2017, Ekim 16). *Makine Öğrenimi Bölüm-2 (k-En Yakın Komşuluk)*. Medium: <https://medium.com/@k.ulgen90/makine-öğrenimi-bölüm-2-6d6d120a18e1> [Erişim Tarihi: 31 Ocak 2023].
- Ulgen, E. K. (2017, Kasım 12). *Makine Öğrenimi Bölüm-5 (Karar Ağaçları)*. Medium: <https://medium.com/@k.ulgen90/makine-öğrenimi-bölüm-5-karar-ağaçları-c90bd7593010> [Erişim Tarihi: 31 Ocak 2023].
- Yagci, A. L., Colkesen, I., Kavzoglu, T., & Sefercik, U. G. (2022). Daily monitoring of marine mucilage using the MODIS products: a case study of 2021 mucilage bloom in the Sea of Marmara, Turkey. *Environmental Monitoring and Assessment*, 194(3), 170.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Enes BAKIŞ
Uyruğu : Türkiye

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Üniversite	: Batman Üniversitesi	2021

Yüksek Lisans	: Batman Üniversitesi	2023
---------------	-----------------------	------

Doktora	: -
---------	-----

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2022	Batman Malabadi M.T.A.L.	Ücretli Öğretmen
2022	Piri Reis Üniversitesi	Araştırma Görevlisi

UZMANLIK ALANI: Elektrik-Elektronik Mühendisi

YABANCI DİLLER: İngilizce

YAYINLAR:

1-) Bakış, E. & Acar, E. (2023) Aktif Uzaktan Algılama Verileri Kullanılarak LSTM (Uzun Kısa Süreli Bellek) Yöntemi İle Müsilaj Bölgelerinin Otomatik Olarak Tespit Edilmesi. ''AY, F. Z. Uluslararası Bilişim Kongresi Bildiriler Kitabı'', 20 Mart 2023, Batman.