



T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



SU KALİTESİ PARAMETRELERİNİN
UZAKTAN ALGILAMA VE DERİN ÖĞRENME
TEKNİKLERİYLE MODELLENMESİ

Osman KARAKOÇ

DOKTORA TEZİ

Harita Mühendisliği Anabilim Dalı

Şubat-2026
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Osman KARAKOÇ tarafından hazırlanan “Su Kalitesi Parametrelerinin Uzaktan Algılama ve Derin Öğrenme Teknikleriyle Modellenmesi” adlı tez çalışması 10/02/2026 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Hakan KARABÖRK

.....

Danışman

Doç. Dr. İlkey BUĞDAYCI

.....

Üye

Prof. Dr. Bilgehan NAS

.....

Üye

Doç. Dr. Pınar BACAKSIZ

.....

Üye

Dr. Öğr. Üyesi Abdullah VARLIK

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE 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.

Osman KARAKOÇ

10/02/2026

ÖZET

DOKTORA TEZİ

SU KALİTESİ PARAMETRELERİNİN UZAKTAN ALGILAMA VE DERİN ÖĞRENME TEKNİKLERİYLE MODELLENMESİ

Osman KARAKOÇ

**NECMETTİN ERBAKAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
DOKTORA TEZİ**

Danışman: Doç. Dr. İlkey BUĞDAYCI

2026, 162 Sayfa

Jüri

**Doç. Dr. İlkey BUĞDAYCI
Prof. Dr. Hakan KARABÖRK
Prof. Dr. Bilgehan NAS
Doç. Dr. Pınar BACAŞIZ
Dr. Öğr. Üyesi Abdullah VARLIK**

Küresel ölçekte artan su kirliliği ve su kaynakları üzerindeki baskılar, doğal ekosistemlerin dengesini tehdit eden en önemli çevre sorunlarından biri haline gelmiştir. Hızlı nüfus artışı, sanayileşme, iklim değişimi ve arazi örtüsü değişimi gibi çeşitli insan kaynaklı faaliyetler yüzey sularının kalitesini olumsuz yönde etkilemekte su kütlelerinin düzenli bir şekilde izlenmesini zorunlu kılmaktadır. Uzaktan algılama teknikleri, yüksek spektral çözünürlüklü veri setleri ve çok bantlı gözlem kapasiteleri sayesinde, su kalitesi parametrelerinin sinoptik ölçekte izlenmesi ve mekânsal olarak modellenmesinde güçlü bir altyapı sunmaktadır. Son yıllarda, uzaktan algılama tabanlı su kalitesi araştırmalarında, doğrusal olmayan ilişkileri çözümleme ve gizli örüntüleri öğrenme yeteneği sayesinde makine ve derin öğrenme yaklaşımları sıklıkla tercih edilmektedir.

Bu çalışma kapsamında, Landsat-8 uydu görüntülerinden temin edilen veriler makine ve derin öğrenme teknikleriyle entegre edilerek; Mogan Gölü'nün 2018-2024 tarihleri arasındaki klorofil-a (CHL-A) ve askıda katı madde (AKM) konsantrasyonları ile secchi diski derinliği (SDD) değerleri modellenmiştir. Su kalitesi parametreleri ile uydu görüntülerinin bantları ve hesaplanan spektral indeksler arasındaki ilişkiler ilk aşamada Rastgele Orman (RO) modeli kullanılarak analiz edilmiştir. Devamında, Yapay Sinir Ağları (YSA) ve Evrişimli Sinir Ağları (ESA) modelleri ile çok katmanlı ve yüksek temsil gücüne sahip kestirim modelleri geliştirilmiştir. Mekânsal ilişkileri öğrenme kabiliyeti sayesinde, parametrelerin tümünde en yüksek performans sağlayan ESA modeli kullanılarak tematik haritalar üretilmiştir. Tematik haritalar üzerinden gerçekleştirilen piksel bazlı istatistiksel analizler ile kestirim sonuçlarının mekânsal tutarlılığı ve zamansal davranışı ayrıntılı olarak incelenmiştir. Ayrıca çalışma tarihlerine ait sıcaklık, yağış, rüzgâr ve toz taşınımına ilişkin veriler analiz edilerek göl ve çevresindeki meteorolojik koşullar değerlendirilmiştir.

Elde edilen sonuçlar, Mogan Gölü su kalitesinin değerlendirilmesi, ekosistem süreçlerinin sürdürülebilirliği açısından önemli bilgiler sunmakta ve uzaktan algılama tabanlı derin öğrenme yaklaşımlarının su kalitesi izleme çalışmalarındaki potansiyelini ortaya koymaktadır.

Anahtar Kelimeler: Uzaktan Algılama, Derin Öğrenme, Spektral İndeks, Landsat-8, Su Kalitesi.

ABSTRACT

Ph.D THESIS

MODELLING OF WATER QUALITY PARAMETERS WITH REMOTE SENSING AND DEEP LEARNING TECHNIQUES

Osman KARAKOÇ

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES OF
NECMETTİN ERBAKAN UNIVERSITY
DOCTOR OF PHILOSOPHY
IN GEOMATICS ENGINEERING**

Advisor: Doç. Dr. İlkey BUĞDAYCI

2026, 162 Pages

Jury

**Doç. Dr. İlkey BUĞDAYCI
Prof. Dr. Hakan KARABÖRK**

**Prof. Dr. Bilgehan NAS
Doç. Dr. Pınar BACAŞIZ
Assoc. Prof. Dr. Abdullah VARLIK**

Increasing water pollution and pressures on water resources on a global scale have become one of the most significant environmental issues threatening the balance of natural ecosystems. Various human-induced activities such as rapid population growth, industrialization, climate change, and land cover change negatively impact the quality of surface waters, making the regular monitoring of water bodies imperative. Remote sensing techniques, with their high spectral resolution datasets and multispectral observation capabilities, provide a robust infrastructure for monitoring water quality parameters at a synoptic scale and modeling them spatially. In recent years, machine and deep learning approaches have been frequently preferred in remote sensing-based water quality research due to their ability to analyze nonlinear relationships and learn hidden patterns.

Within the scope of this study, data obtained from Landsat-8 satellite images were integrated using machine and deep learning techniques to model chlorophyll-a (CHL-A) and suspended solids (SS) concentrations, as well as secchi disk depth (SDD) values for Lake Mogan between 2018 and 2024. The relationships between water quality parameters and satellite image bands and calculated spectral indices were initially analyzed using a Random Forest (RF) model. Subsequently, multi-layer prediction models with high representational power were developed using Artificial Neural Networks (ANN) and Convolutional Neural Networks (CNN) models. Thanks to its ability to learn spatial relationships, thematic maps were produced using the ESA model, which provided the highest performance across all parameters. The spatial consistency and temporal behavior of the prediction results were examined in detail through pixel-based statistical analyses performed on the thematic maps. Furthermore, data related to temperature, precipitation, wind, and dust transport for the study dates were analyzed to evaluate the meteorological conditions in and around the lake.

The results obtained provide important information regarding the assessment of Mogan Lake water quality and the sustainability of ecosystem processes, and demonstrate the potential of remote sensing-based deep learning approaches in water quality monitoring studies.

Keywords: Remote Sensing, Deep Learning, Spectral Indices, Landsat-8, Water Quality.

Bu tez formüle edilemeyen birikimlerin çıktısıdır...

ÖNSÖZ

Bu doktora tezi kapsamında, uzaktan algılama ve derin öğrenme teknikleri entegre biçimde kullanılarak çok kaynaklı verilerin bütünleşik analizine dayalı bir yaklaşım benimsenmiş, su kalitesi parametreleri modellenerek tematik haritalar üretilmiştir. Bu kapsamda elde edilen sonuçların, su kaynaklarının stratejik ve otonom yönetimine yönelik bilimsel araştırmalara ışık tutması ve literatüre yöntemsel açıdan özgün katkılar sağlaması beklenmektedir.

Doktora çalışmamın her aşamasında zamanını ve birikimini büyük bir özveriyle paylaşan, akademik vizyonu ve çözüm odaklı yaklaşımıyla bu çalışmanın bilimsel çerçevesinin oluşturulmasında ve yürütülmesinde belirleyici rol oynayan danışman hocam Doç. Dr. İlkey BUĞDAYCI'ya en içten teşekkürlerimi ve derin şükranlarımı sunarım. Yüksek lisans tez danışmanlığımı yürüten ve doktora çalışmama danışmanım olarak başlayan; Antalya Bilim Üniversitesi Rektörü olarak atanması nedeniyle danışmanlık süreci sona eren kıymetli hocam Prof. Dr. Semih EKERCİN'e, akademik yönelimin şekillenmesinde yol gösterici katkıları ve sunduğu değerli destekler için teşekkür ederim. Doktora tez izleme komitesi sürecinde sundukları kıymetli görüşler ve yönlendirici değerlendirmelerle bu çalışmanın olgunlaşmasında önemli ölçüde katkılar sağlayan Prof. Dr. Hakan KARABÖRK ve Dr. Öğr. Üyesi Abdullah VARLIK hocalarıma teşekkürlerimi sunarım. Ayrıca tez savunmam sürecinde değerlendirmeleri ve görüşleriyle çalışmama bilimsel açıdan önemli katkılar sunan jüri üyeleri Prof. Dr. Bilgehan NAS ve Doç. Dr. Pınar BACAŞIZ hocalarıma teşekkürlerimi sunarım.

Doktora tezi kapsamında gerekli araştırma izinlerinin sağlanması ve kullanılan verilerin temini noktasında sunduğu kesintisiz destek için, personeli olmaktan her zaman onur duyduğum T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'na teşekkürlerimi sunarım. Tabiat Varlıklarını Koruma Genel Müdürlüğü bünyesinde Şube Müdürü olarak görev yapan Emrah MANAP başta olmak üzere, ilgili şube müdürlüğünün tüm değerli çalışanlarına ve Aydın Çevre, Şehircilik ve İklim Değişikliği İl Müdürlüğü bünyesinde görev yapan Şube Müdürü Muharrem Barış PEKCAN'a sürece sağladığı katkılar nedeniyle teşekkürlerimi sunarım. Çalışma sürecinin tüm aşamalarında verdiği destek ve motivasyonumu artıran katkıları için değerli arkadaşım Emre SAVRAN'a teşekkür ederim.

Hayatım boyunca attığım her adımda varlıklarıyla bana güç veren, emekleri ve inançlarıyla bugünlere ulaşmamı sağlayan sevgili annem Bedriye KARAKOÇ ve babam Mustafa KARAKOÇ'a sonsuz teşekkürlerimi sunarım. Doktora sürecinin yoğun ve zorlu aşamalarında her daim yanımda olan; sabrı, anlayışı ve koşulsuz desteğiyle gücüme güç katan sevgili eşim Kübra KARAKOÇ'a en derin minnettarlığımı sunarım.

Bu yolculuğun en anlamlı motivasyon kaynaklarından biri olan; henüz dünyaya gözlerini açmamış, varlığıyla umudu, geleceği ve sorumluluğu yeniden tanımlayan canım oğlum Atlas KARAKOÇ'a bu çalışmayı sevgi ve umutla armağan ediyorum...

Osman KARAKOÇ
KONYA-2026

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vii
İÇİNDEKİLER	viii
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. UZAKTAN ALGILAMA VE KESTİRİM MODELLERİ	14
3.1. Elektromanyetik Enerji	14
3.2. Elektromanyetik Spektrum	16
3.3. Cisimlerin Spektral Yansıtma Özellikleri	20
3.3.1. Suyun spektral yansıtma özellikleri	22
3.4. Uzaktan Algılama ve Su Kalitesi	23
3.5. Su Kalitesi Parametreleri	25
3.5.1. Klorofil-a	27
3.5.2. Askıda katı madde	29
3.5.3. Secchi disk derinliği	29
3.6. Kestirim Modelleri	31
3.6.1. Rastgele orman (RO)	31
3.6.2. Yapay sinir ağları (YSA)	34
3.6.3. Evrişimli sinir ağları (ESA)	40
3.6.3.1. Girdi katmanı	42
3.6.3.2. Evrişim katmanı	42
3.6.3.3. Aktivasyon katmanı	43
3.6.3.4. Havuzlama katmanı	45
3.6.3.5. Sınıflandırma katmanı	47
4. MATERYAL VE YÖNTEM	48
4.1. Çalışma Alanı	48
4.2. Su Kalitesi Ölçüm Verileri	54
4.3. Uydu Görüntüleri	57
4.4. Spektral İndeksler	61
4.5. Doğruluk Analizi	63
4.6. Meteorolojik Etkenler	65
4.7. Kullanılan Yazılım ve Platformlar	71
4.8. Yöntemin Akış Diyagramı	72

5. KESTİRİM MODELLERİ VE DOĞRULUK ANALİZİ.....	76
5.1. Klorofil-a Kestirim Modelleri.....	76
5.1.1. Rastgele orman modeli	76
5.1.2. Yapay sinir ağı modeli	80
5.1.3. Evrişimli sinir ağı modeli	80
5.1.4. Doğrulukların değerlendirilmesi.....	82
5.1.5. Tematik haritaların üretilmesi.....	84
5.2. Askıda Katı Madde Kestirim Modelleri	85
5.2.1. Rastgele orman modeli	85
5.2.2. Yapay sinir ağı modeli	87
5.2.3. Evrişimli sinir ağı modeli	88
5.2.4. Doğrulukların değerlendirilmesi.....	89
5.2.5. Tematik haritaların üretilmesi.....	91
5.3. Secchi Diski Derinliği Kestirim Modelleri.....	92
5.3.1. Rastgele orman modeli	92
5.3.2. Yapay sinir ağı modeli	94
5.3.3. Evrişimli sinir ağı modeli	95
5.3.4. Doğrulukların değerlendirilmesi.....	96
5.3.5. Tematik haritaların üretilmesi.....	98
5.4. Kestirilen Su Kalitesi Parametrelerinin İstatistiksel Analizi	100
5.4.1. Standart sapma ve ortalama değerler analizi	100
5.4.2. Piksel bazlı dağılım ve korelasyon analizi.....	102
5.4.3. Dağılım özellikleri ve değişkenlik analizi	105
6. SONUÇLAR VE ÖNERİLER.....	110
KAYNAKLAR	113
EKLER	125

ŞEKİLLER LİSTESİ

Şekil 3.1. Elektromanyetik enerjinin dalga yayılımı	14
Şekil 3.2. Enerji ve dalga boyu arasındaki ilişkinin grafiksel gösterimi	15
Şekil 3.3. Elektromanyetik spektrumun bantları ve uzaktan algılamadaki işlevleri	18
Şekil 3.4. Yeryüzüne ulaşan enerjinin spektral etkileşimi.....	20
Şekil 3.5. Yeryüzü nesnelerinin spektral yansıtım eğrileri.....	21
Şekil 3.6. Klorofil pigmentlerinin absorpsiyon spektrumu	28
Şekil 3.7. Secchi diski ve ölçüm prensibinin şematik gösterimi	30
Şekil 3.8. RO algoritmasının temel mimarisi	33
Şekil 3.9. YSA ve biyolojik sinir hücresi	36
Şekil 3.10. YSA algoritmasının temel mimarisi.....	38
Şekil 3.11. ESA algoritmasının temel mimarisi	40
Şekil 3.12. Aktivasyon fonksiyonları	44
Şekil 3.13. Ortalama havuzlama tekniği.....	45
Şekil 3.14. Maksimum havuzlama tekniği	46
Şekil 4.1. Çalışma alanı haritası	49
Şekil 4.2. Gölbaşı bölgesi su toplama havza sınırları.....	50
Şekil 4.3. GÖÇKB sınırları.....	51
Şekil 4.4. GÖÇKB sınırları içerisinde bulunan doğal sit alanları	52
Şekil 4.5. Mogan Gölü ve çevresinin farklı dönemlere ait görüntüleri	53
Şekil 4.6. Su örnekleme lokasyonları	55
Şekil 4.7. Çalışma tarihlerine ait sıcaklık haritaları.....	66
Şekil 4.8. Çalışma tarihlerine ait yağış haritaları.....	67
Şekil 4.9. Çalışma tarihlerine ait rüzgâr haritaları	68
Şekil 4.10. Çalışma tarihlerine ait toz taşınım haritaları	70
Şekil 4.11. Kullanılan yazılım ve platformlar	71
Şekil 4.12. Yöntemin akış diyagramı	73
Şekil 5.1. RO modeli için CHL-A kısmi bağımlılık grafikleri	78
Şekil 5.2. RO modeli için CHL-A değişkenlerinin önem derecesi	79
Şekil 5.3. CHL-A parametresinin model bazlı dağılımı ve çizgisel grafikleri	83
Şekil 5.4. CHL-A parametresinin mekânsal dağılımına ilişkin tematik haritalar	84
Şekil 5.5. RO modeli için AKM kısmi bağımlılık grafikleri.....	86
Şekil 5.6. RO modeli için AKM değişkenlerin önem derecesi	87
Şekil 5.7. AKM parametresinin model bazlı dağılımı ve çizgisel grafikleri.....	90
Şekil 5.8. AKM parametresinin mekânsal dağılımına ilişkin tematik haritalar	91
Şekil 5.9. RO modeli için SDD kısmi bağımlılık grafikleri	93
Şekil 5.10. RO modeli için SDD değişkenlerin önem derecesi.....	94
Şekil 5.11. SDD parametresinin model bazlı dağılımı ve çizgisel grafikleri	97
Şekil 5.12. SDD parametresinin mekânsal dağılımına ilişkin tematik haritalar.....	98
Şekil 5.13. Ortalama değerlerin zamansal analizi	101
Şekil 5.14. Parametrelere ait korelasyon ısı haritası.....	103
Şekil 5.15. Piksel bazlı dağılım analizi.....	104
Şekil 5.16. Kutu grafiklerinin karşılaştırmalı analizi	105
Şekil 5.17. CHL-A parametresine ait histogram grafikleri	107
Şekil 5.18. AKM parametresine ait histogram grafikleri	108
Şekil 5.19. SDD parametresine ait histogram grafikleri.....	109

TABLÖLAR LİSTESİ

Tablo 3.1. Uzaktan algılamada kullanılan spektrum bölgeleri	17
Tablo 3.2. Su kalitesi parametrelerinin uzaktan algılama tabanlı optik etkinlikleri	24
Tablo 3.3. Kıta içi yerüstü su kaynakları için kalite sınıfı kriterleri	26
Tablo 3.4. YSA mimarilerinin tarihsel özeti	35
Tablo 3.5. YSA ve insan nöronu yapısının karşılaştırılması.....	36
Tablo 4.1. Numune alınan noktaların genel özellikleri.....	56
Tablo 4.2. Landsat-8 uydusunun genel özellikleri	58
Tablo 4.3. Landsat-8 spektral bant özellikleri.....	59
Tablo 4.4. Kullanılan uydu görüntüleri.....	60
Tablo 5.1. CHL-A parametresinin model performansları	82
Tablo 5.2. AKM parametresinin model performansları	89
Tablo 5.3. SDD parametresinin model performansları	96
Tablo 5.4. Standart sapma ve ortalama değerler analizi	100
Tablo 5.5. Piksel bazlı korelasyon analizi sonuçları	103

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

SİMGELER

c	Işık Hızı
E	Enerji
F_q	Çekirdeğin Uzamsal Boyutu
$f(x)$	Aktivasyon Fonksiyonunun Çıktısı
h	Planck Sabiti
Hz	Hertz
i	Girdi Boyutu
j	Sınıf
J	Joule
k	Pencere Boyutu
L	Litre
m	Metre
m	Örnek Sayısı
m^3	Metreküp
mg	Miligram
mg/L	Miligram/Litre
$\mu g/L$	Mikrogram/Litre
mm	Milimetre
m/sn	Metre/Saniye
μm	Mikrometre
nm	Nanometre
n_q	Giriş Uzayının Uzamsal Boyutu
n_{q+1}	Çıktı Uzayının Uzamsal Boyutu
o	Çıktı Boyutu
$p(j t)$	Görelî Olasılık
R	Korelasyon Katsayısı
R^2	Determinasyon Katsayısı
s	Adım Sayısı
$s(t)$	Fonksiyon
t	Zaman
V	Frekans
X	Girdi Verisi
X_i	Tahmin Değeri
X_{max}	Girdi Verisindeki En Büyük Değer
X_{min}	Girdi Verisindeki En Küçük Değer
X^l	Normalizasyon Uygulanmış Veri
Y_i	Gerçek Değer
$\bar{Y}$	Gerçek Değerlerin Ortalaması
W	Watt
w	Çekirdek
X	Girdi Verisi
λ	Dalga Boyu
θ_K	Rastgele Vektör

KISALTMALAR

AB	Avrupa Birliđi
ABD	Amerika Birleşik Devletleri
AI	Yapay Zeka
AKM	Askıda Katı Madde
ALI	Gelişmiş Arazi Görüntüleyici
ANN	Yapay Sinir Ağları
BİAS	Sistematik Hata Yönü
BM	Birleşmiş Milletler
BOD	Biyokimyasal Oksijen İhtiyacı
CAMS	Copernicus Atmosfer İzleme Hizmeti
CBS	Coğrafi Bilgi Sistemleri
CDOM	Renkli Çözünmüş Organik Madde
CHL-A	Klorofil-a
CNN	Evrişimli Sinir Ağları
COD	Kimyasal Oksijen İhtiyacı
ÇDP	Çevre Düzeni Planı
ÇŞİDB	Çevre, Şehircilik ve İklim Değışikliđi Bakanlıđı
DEM	Sayısal Yükseklik Modeli
DO	Çözünmüş Oksijen
DL	Derin Öğrenme
DN	Dijital Numara
EC	Elektriksel İletkenlik
ESA	Evrişimli Sinir Ağları
ERTS	Dünya Kaynakları Teknoloji Uydusu
ETM	Geliştirilmiş Tematik Haritalayıcı
GEE	Google Earth Engine
GEOS	Goddard Yer Gözlem Sistemi
GÖÇKB	Gölbaşı Özel Çevre Koruma Bölgesi
IFS	Entegre Tahmin Sistemi
IR	Termal Kızılötesi
LASRC	Kara Yüzeyi Yansıma Kodu
LSTM	Uzun Kısa Süreli Bellek
L1TP	Düzey-1 Hassas Arazi Düzeltmeli Ürün
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
ML	Makine Öğrenme
MNDWI	Değıştirilmiş Normalize Fark Su İndeksi
MSE	Ortalama Karesel Sapma
NASA	Ulusal Havacılık ve Uzay Dairesi
NDVI	Normalize Edilmiş Fark Bitki Örtüsü İndeksi
NDWI	Normalize Fark Su İndeksi
NH3-N	Amonyak
NIR	Yakın Kızılötesi
NOAA	Ulusal Okyanus ve Atmosfer Dairesi
NSE	Nash-Sutcliffe Model Verimlilik Katsayısı
OLI	Operasyonel Arazi Görüntüleyici
PCA	Temel Bileşen Analizi
PO4	Çözünebilir Reaktif Fosfor

PSL	Fizik Bilimleri Laboratuvarı
RELU	Doğrultulmuş Doğrusal Birim
RF	Rastgele Orman
RMSE	Kök Ortalama Kare Hatası
RO	Rastgele Orman
SDD	Secchi Diski Derinliği
SS	Askıda Katı Madde
SSS	Deniz Yüzey Tuzluluğu
SWIR	Kısa Dalga Kızılötesi
TIR	Termal Kızılötesi
TIRS	Termal Kızılötesi Sensör
TM	Tematik Haritalayıcı
TN	Toplam Azot
TOC	Toplam Organik Karbon
TP	Toplam Fosfor
TSM	Toplam Askıda Katı Madde
TUR	Bulanıklık
TVKGM	Tabiat Varlıklarını Koruma Genel Müdürlüğü
UA	Uzaktan Algılama
USGS	Amerika Birleşik Devletleri Jeolojik Araştırmalar Merkezi
YSA	Yapay Sinir Ağları
WHO	Dünya Sağlık Örgütü
VNIR	Görünür ve Yakın Kızılötesi
WT	Su Sıcaklığı
WQI	Su Kalitesi İndeksi

1. GİRİŞ

Su, biyolojik yaşamın sürekliliği ve ekosistemlerin işlevsel bütünlüğü noktasında vazgeçilmez bir yaşam kaynağıdır. Tüm canlı faaliyetlerinden tarımsal üretime, sanayi faaliyetlerinden doğal dengeye kadar uzanan birçok alanda su kaynaklarının varlığı kritik önemlidir. Bu nedenle, su kaynaklarının korunması, yönetimi ve düzenli olarak izlenmesi çevre yönetiminin temel yapı taşı oluşturmaktadır. Dünya genelinde yaklaşık 2 milyar insanın güvenli şekilde yönetilen içme suyu hizmetlerine erişimden yoksun olduğu bilinmektedir (WHO, 2023). İnsan kaynaklı çevresel değişimler yüzey suyu kalitesini tehdit etmekte su kalitesindeki sürdürülebilir kalkınma hedeflerine ulaşılmasını engellemektedir. Su kaynaklarının başarılı bir şekilde analiz edilebilmesi için bilimsel yöntemlere dayalı izleme tekniklerinin yürütülmesi ve temin edilen sonuçların stratejik açıdan karar verme süreçlerine entegre edilmesi gerekmektedir. Bu durum, yalnızca ekolojik dengenin korunması için değil, aynı zamanda toplumların ekonomik ve sosyal refahının güvende tutulması açısından da hayati bir öneme sahiptir.

Su kalitesi parametrelerine ilişkin tespitler yaygın olarak geleneksel yöntemlere dayalı saha örnekleme metoduyla yapılmakta olup çoğu su kütlesi için sürekli veri sağlanamamaktadır (Filazzola vd., 2020). Geleneksel su kalitesi izleme yöntemleri, kapsamlı saha örnekleme ve laboratuvar analizleri gerektirdiklerinden hem yüksek maliyetli hem de yoğun emek isteyen süreçlerdir. Bunun yanında, bazı su kütlelerine erişimin fiziksel koşullar nedeniyle oldukça güç hatta zaman zaman imkânsız olması, bu yöntemlerin uygulanabilirliğini ciddi ölçüde sınırlandırmaktadır (Gholizadeh vd., 2016). Her ne kadar sabit izleme istasyonları aracılığıyla düzenli örnekleme sağlanabilse de örnek sayısının sınırlı olmasından kaynaklı hem mekânsal hem de zamansal ölçekte yetersiz kalınmaktadır (Virdis vd., 2022). Uydu sistemleri, teknolojiye paralel olarak hızla gelişmekte ve yüksek spektral, mekânsal ve zamansal kapsamı sayesinde sınırlamaların üstesinden gelebilecek kapasiteye sahip başarılı çözümler sunmaktadır (Llodrà-Llabrés vd., 2023). Nitekim, su kalitesi konsantrasyonlarının tahmininde uydu verilerinin kullanılması, geniş alanları kapsayan verileri sayesinde sinoptik ölçekte analizler gerçekleştirilmesine imkân tanımaktadır. Bunun yanı sıra, uzaktan algılama teknikleri kullanılarak saha çalışmaları ile erişilebilmesi güç ya da imkânsız olan alanlarda da su kalitesinin tahmin edilmesi mümkündür. Landsat gibi uzun yıllara ait arşiv kaydı bulunan uydu verileri ise geçmişte saha gözlemlerinin yapılamadığı durumlarda

geriye dönük su kalitesi analizlerinin gerçekleştirilmesine imkân sunar (Kulkarni vd., 2011). Uzaktan algılama tabanlı su kalitesi araştırmalarının temeli yansıtım değerlerinin kullanılmasına dayanmaktadır. Klorofil-a, askıda katı madde ve secchi diski derinliği gibi su kalitesi parametrelerinin kestiriminde yansıtım değerlerinden yararlanılmaktadır (Gholizadeh vd., 2016).

Son yıllarda, uzaktan algılama tabanlı su kalitesi araştırmalarında Makine Öğrenme (ML) tekniklerinin kullanımında önemli bir artış gözlenmektedir. Bu eğilim, matematiksel algoritma geliştirme süreçlerindeki ilerlemeler, hesaplama kapasitelerindeki artış, uydu sensör teknolojilerinin hızlı gelişimi ve kapsamlı veri setlerine erişimin giderek kolaylaşması gibi bir dizi etkene dayanmaktadır (Peterson vd., 2018). Veri setinden hiyerarşik yapılar ile anlamlı ilişkiler kurabilen ve ham verilerden doğrudan tahmin üretebilen Derin Öğrenme (DL) modelleri ise ML teknikleri arasında en güçlü algoritmalardandır. DL, bu yetenekleri sayesinde su kalitesi parametrelerinin kestiriminde ve mekânsal dağılımının haritalandırılmasında diğer yöntemlere kıyasla dikkat çekici avantajlar sağlamaktadır (Peterson vd., 2020). Uluslararası literatürde, uzaktan algılama teknolojisi ile ML ve DL tekniklerini entegre bir şekilde kullanarak su kalitesi parametrelerini kestiren ve modelleyen çok sayıda çalışma bulunmaktadır (Li vd., 2022; Chen vd., 2023; Perumal vd., 2023; Chellaiah vd., 2024; Ali vd., 2024). Araştırmacılar, uydu görüntüleri ile su kalitesi parametreleri arasında ML ve DL yaklaşımlarını kullanarak anlamlı ilişkiler tespit etmiştir.

Tez çalışmasının amacı, Landsat-8 uydu görüntüleri ve derin öğrenme teknikleri entegrasyonu ile, Bakanlar Kurulu'nun 90/1117 sayılı kararı ile ilan edilen Gölbaşı Özel Çevre Koruma Bölgesi (GÖÇKB) içerisinde yer alan ve Ankara'nın Gölbaşı ilçesi sınırlarında bulunan Mogan Gölü'ndeki klorofil-a (CHL-A) ve askıda katı madde (AKM) konsantrasyonları ile secchi diski derinliği (SDD) değerlerini modellemektir. Bu kapsamda çalışma, uydu görüntüleri ile zamansal olarak uyumlu sınırlı sayıda ölçüm verilerinin bütünleşik kullanımına dayanmaktadır. Su kalitesi çalışmalarında yeterli ve eşzamanlı ölçüm verisine ulaşmanın güç olması, özellikle küçük ölçekli göl sistemlerinde önemli bir kısıt oluşturmaktadır. Bu nedenle, sınırlı veri seti ile uydu tabanlı makine ve derin öğrenme yaklaşımlarının uygulanabilirliğinin ortaya konulması, hem Mogan Gölü'nün su kalitesinin güvenilir biçimde modellenmesi hem de veri kısıtlı koşullara yönelik literatürdeki metodolojik boşluğa katkı sağlanması açısından önem arz etmektedir. Bu kapsamda, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (ÇŞİDB)'nden temin edilen 2018-2024 yılları arasındaki su kalitesi ölçüm sonuçları

kullanılarak, Rastgele Orman (RO), Yapay Sinir Ağları (YSA) ve Evrişimli Sinir Ağları (ESA) modelleri uygulanmıştır. Uydu görüntülerinin bantları ve hesaplanan spektral indeksler ile su kalitesi konsantrasyonları arasındaki ilişki RO modeli ile test edilerek her üç parametre için de veri seti kontrollü bir şekilde genişletilmiştir. Mogan Gölü'nde su kalitesini etkileyen CHL-A, AKM ve SDD parametrelerini kestirmek üzere genişletilen veri seti kullanılarak YSA ve ESA modelleri ile algoritmalar geliştirilmiştir. Araştırma bulguları doğrultusunda, mekânsal ilişkileri modellemedeki üstün kapasitesi sayesinde en yüksek performansı sergileyen ESA modeli kullanılarak su kalitesi parametreleriyle ilişkili tematik haritalar üretilmiştir. Tematik haritalar üzerinden yürütülen piksel bazlı istatistiksel analizler ile kestirim sonuçlarının mekânsal dağılım özellikleri ve zamansal değişim eğilimleri ayrıntılı olarak incelenmiştir. Buna ek olarak çalışma tarihlerine ait sıcaklık, yağış, rüzgâr ve toz taşınımı verileri analiz edilerek göl ve yakın çevresindeki meteorolojik koşullar bütüncül bir yaklaşımla değerlendirilmiştir. Elde edilen sonuçların göldeki su kalitesinin değerlendirilmesi ve ekosistemin sürdürülebilirliğinin desteklenmesi açısından önemli çıktılar sunduğu değerlendirilmektedir. Ayrıca bu sonuçların gelecekte yürütülecek izleme ve yönetim çalışmalarının daha sistematik ve otonom bir yapıya kavuşturulmasına yönelik bilimsel bir altyapı oluşturduğu düşünülmektedir.

Tez çalışmasının ikinci bölümünde, uzaktan algılama tabanlı su kalitesi izleme çalışmalarına ilişkin literatür, zaman içerisindeki gelişimi yansıtacak şekilde ele alınmıştır. Bu kapsamda, alanın erken dönem uygulamalarından başlanarak güncel araştırmalara doğru ilerleyen bir yaklaşım benimsenmiştir. Literatürde yer alan çalışmalar kronolojik bir düzen içerisinde sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Bu bölümde, uzaktan algılama tabanlı modelleme yaklaşımlarının su kalitesi çalışmalarında kullanımına ilişkin literatür ayrıntılı biçimde incelenmiştir. Bu kapsamda, araştırmaların zaman içerisindeki gelişimini ortaya koymak amacıyla kaynaklar kronolojik bir yaklaşım benimsenerek ele alınmıştır. Literatürde yer alan erken tarihli ampirik çalışmalardan başlanarak, güncel makine ve derin öğrenme tabanlı yöntemlerin kullanıldığı araştırmalara doğru ilerleyen bir yapı izlenmiştir. Böylece, araştırma alanına ilişkin mevcut literatür tarihsel akış içerisinde sistematik bir biçimde sunulmuştur.

Ekercin, (2007), İstanbul Haliç'te yüksek çözünürlüğe sahip uydu görüntüleri ve dokuz adet istasyondan temin edilen veri desteğiyle mevcut su kalitesini haritalandırmıştır. Araştırmada klorofil-a, toplam askıda katı madde ve secchi diski derinliği parametreleri ile IKONOS uydu görüntüsü veri kaynakları olarak kullanılmıştır. Çoklu regresyon modeli ile hesaplanan korelasyon katsayısının $R^2 > 0,98$ olması, ölçülen ve tahmin edilen değerler arasında oldukça yüksek bir ilişkinin varlığını ortaya koymuştur.

Nas vd., (2008), Terra ASTER uydu görüntüsü ve eş zamanlı ölçüm verilerini kullanarak Beyşehir Gölü'ndeki klorofil-a parametresini modellemiştir. Çoklu regresyon tekniği ile elde edilen $R^2 > 0,86$ katsayısı uzaktan algılama verilerinin ölçüm verileriyle yüksek oranda ilişkili olduğunu göstermiştir.

Su vd., (2008), Spot uydu görüntülerini kullanarak Tayvan'da bir kıyı alanının su kalitesini tahmin etmek amacıyla tek ve çok değişkenli iki model oluşturmuştur. Secchi diski derinliği, bulanıklık ve toplam askıda katı madde parametreleri için piksele özgü spektral yansıma esasına dayanarak çok değişkenli su kalitesi tespit modeli ile entegre kıyı suyu kalitesini haritalandırmıştır.

Mancino vd., (2009), İtalya Monticchio'daki küçük göllerden oluşan bir uygulama alanında klorofil-a ve secchi diski derinliği parametrelerine bağlı olarak Landsat verileri ile su kalitesini analiz etmiştir. Çoklu regresyon modelleriyle hesaplanan katsayılar klorofil-a ve secchi diski derinliği için sırasıyla $R^2 = 0,72$ ve $R^2 = 0,82$ olup yüksek korelasyon saptanmıştır.

Kulkarni (2011), Doğu Teksas'ta yürütülen su kalitesi çalışmalarında Landsat TM görüntülerinin kullanılabilirliğini değerlendirmiştir. Bu kapsamda, klorofil-a, bulanıklık ve toplam askıda katı madde parametreleri uydu verileri kullanılarak tahmin edilmiştir.

Su kalitesinin belirlenmesine yönelik ek saha çalışmaları da gerçekleştirilerek ölçüm verileri regresyon analizlerine dahil edilmiştir. Araştırma bulguları, sudan yansıyan güneş ışığı miktarının su kalitesini belirleyen parametrelerle güçlü bir ilişki gösterdiğini ortaya koymuştur.

Somvanshi vd., (2012), Hindistanda bulunan Gomti Nehri'nde yerinde ölçüm verilerini ve IRS uydu görüntülerini kullanarak su kalitesi parametrelerini haritalandırmıştır. Regresyon analizlerinden temin edilen katsayılar her parametre için yüksek korelasyon bulunduğunu ortaya koymuştur. Model verileri kullanılarak tüm çalışma alanını kapsayan su kalitesi haritaları üretilmiştir.

Kavurmacı vd., (2013), EO-1 uydusunun Gelişmiş Arazi Görüntüleyici (ALI) sensörünü kullanarak Hirfanlı Baraj Gölü'nün su kalitesini haritalandırmıştır. Barajın 20 farklı noktasından alınan su örnekleri laboratuvar ortamında analiz edilmiş ve çoklu regresyon algoritması uygulanmıştır. Elde edilen $R^2 > 0,93$ katsayısı, ölçülen ve tahmin edilen veriler arasındaki yüksek uyumu ortaya koymuş; bu doğrultuda bulanıklık, askıda katı madde ve klorofil-a parametrelerine ilişkin tematik haritalar üretilmiştir.

Liu vd., (2013), Çin'in Hubei eyaletindeki Cihu Gölü'nde yapay sinir ağı, çoklu regresyon metodu ve uzaktan algılama veri setlerinin entegrasyonu ile su kalitesi parametrelerini tahmin etmiştir. IKONOS uydu görüntüsünün görünür ve yakın kızılötesi bantları kullanılarak geliştirilen modeller sonucunda yapay sinir ağının çoklu regresyon tekniğine kıyasla daha yüksek tahmin doğruluğuna sahip olduğu saptanmıştır.

Toming vd., (2016), Sentinel-2 uydu verilerini kullanarak 11 farklı gölden toplanan su örnekleri için regresyon analizleri gerçekleştirmiştir. Klorofil-a için $R^2 = 0,83$, çözünmüş organik karbon için $R^2 = 0,92$ ve renkli çözünmüş organik madde için $R^2 = 0,72$ katsayıları hesaplanmış olup anlamlı ilişkiler tespit edilmiştir.

Perivolioti vd., (2017), Yunanistan'ın kuzeyinde bulunan Koronia Gölü'nde Landsat uydu serisinin 1984-2016 görüntülerini veri kaynağı olarak kullanarak su kalitesi parametrelerini kestirmiştir. Termal radyasyon ile su sıcaklığı arasındaki ilişkiye yönelik gerçekleştirilen analizler, su sıcaklığının uydu görüntüleri kullanılarak güvenilir biçimde tahmin edilebilen bir parametre olduğunu ortaya koymuştur.

Toksöz ve Uysal, (2018), Muğla ili kıyı sularında 23 farklı lokasyondan toplanan su kalitesi parametrelerini Landsat-8 uydu görüntülerini işleyerek analiz etmiştir. Uzaktan algılama tekniğine dayalı veriler ile gerçek ölçüler arasında yüksek derecede ilişki bulunduğu tespit edilmiştir. Klorofil-a parametresinin NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi) ile mekânsal dağılımının kolaylıkla yapılabileceği saptanmıştır.

Batur ve Maktav, (2019), Gala Gölü'nde toplamda 60 noktadan alınan su örnekleri ile Sentinel-2A, Göktürk-2 ve Landsat-8 görüntülerini kullanarak PCA (Temel Bileşen Analizi) yöntemiyle dağılım haritaları üretmiştir. Araştırma sonucunda uygulanan yöntem ile hesaplanan değerlerin, su kalitesine yönelik parametreler ile yüksek derecede korelasyon gösterdiği saptanmıştır.

Flores-Anderson vd., (2020), Guatemala'da bulunan Atitlan Gölü'nde klorofil-a çözümlemesini hiperspektral sensörlere sahip Hyperion ile gerçekleştirmiştir. Hyperion ile bant oranı yaklaşımında optimum konumu tespit etmek için yinelemeli değerlendirmeler gerçekleştirilmiş olup en iyi sonucun mavi-yeşil bant oranı ile elde edildiği saptanmıştır.

Qi vd., (2020), Çin'deki Taihu Gölü'nde Landsat-8 görüntülerini kullanarak dört su kalitesi parametresi için LSTM (Uzun Kısa Süreli Bellek) tabanlı model oluşturmuştur. Taihu Gölü'ndeki izleme istasyonunda haftalık periyotlar ile ölçülen su kalitesi parametreleri veri seti olarak kullanılmıştır. Modelin farklı dönemlere ait uydu görüntülerine uygulanması ile çeşitli su kalitesi parametrelerinin ters görüntüleri elde edilmiştir.

Caballero ve Navarro, (2021), Pasifik Tayfun sezonunda (Goni ve Vamco Tayfunları) Sentinel-2 uydu görüntülerini kullanarak Laguna Gölü'ndeki klorofil-a ve toplam askıda katı madde konsantrasyonunun zamansal değişimini test etmiştir. Hızlı ve düzenli veri sunması sebebiyle tehlikeli durumlar esnasında uydu görüntülerinin önemli bir araç olduğu vurgulanmıştır.

Chu vd., (2021), Sentinel-2 uydu görüntülerini kullanarak kıyı ve iç sulardaki klorofil-a konsantrasyonuna yönelik mekânsal ve zamansal değişimleri test etmiştir. Çalışma sonuçları klorofil-a parametresinin mekânsal dağılımının haritalandırılmasında uydu görüntülerinin etkili bir çözüm sunduğunu göstermiştir.

Çıtakoğlu ve Özeren, (2021), Sakarya Havzası su kalitesi izleme istasyonunun 1995-2014 yılları arası verilerini kullanarak yapay sinir ağı modeli ile çözünmüş oksijen parametresini modellemiştir. Araştırma sonucunda çözünmüş oksijen parametresinin kestiriminde yüksek performans sağlanmıştır.

Mamun vd., (2021), Seul'ün kuzeydoğusunda bulunan Paldang Rezervuarı'nda Landsat-5 TM görüntülerinden ampirik modeller oluşturarak toplam fosfor, organik madde ve klorofil-a konsantrasyonunu izlemiştir. Araştırmada Landsat-5 uydusunun dört bant değeri ile yerinde elde edilen veriler arasındaki ilişki çoklu doğrusal regresyon

modeliyle test edilmiştir. Toplam fosfor için %67, organik madde için %65 ve klorofil-a için ise %72 doğruluk hesaplanmıştır.

Arias-Rodriguez vd., (2021), Meksika Ulusal Su Kalitesi İzleme Sisteminden 2013-2019 yılları arası için temin edilen ölçüm sonuçlarını ve Landsat-8, Sentinel-2 ve Sentinel-3 verilerini kullanarak Meksika’da bulunan beş gölde klorofil-a, bulanıklık, toplam askıda katı madde ve secchi diski derinliğini modellemiştir. Sentinel-3 sensörü çalışma alanları için Sentinel-2 ve Landsat-8’e kıyasla orta düzeyde daha iyi performans göstermiştir.

Adusei vd., (2021), Owabi Barajı rezervuarında Sentinel-2 ve Landsat-8 uydu verileri ile rastgele orman, çoklu doğrusal regresyon ve destek vektör makineleri metotlarını kullanarak su kalitesi parametrelerini haritalandırmıştır. Sentinel-2 verileri en yüksek performansı rastgele orman algoritması ile ($R^2 = \%95-99$, RMSE = 0,02-3,03) göstermiştir.

Ahmed vd., (2022), Rawal Havzası’nda uzaktan algılama ve derin öğrenme tekniklerine dayanan hibrit bir yaklaşımı araştırmıştır. Çalışmada derin öğrenme modelleri su kalitesi parametrelerinin çok adımlı tahminleri için kullanılmıştır. Rawal Havzası’nı kapsayan 2014-2021 yılları arasındaki Landsat-8 verileri kullanılarak su kalitesi parametreleri elde edilmiştir. Çift yönlü LSTM, çözünmüş oksijen parametresi için daha başarılı RMSE ile üstün performans göstermiştir.

Kırtıloğlu ve Karabörk (2022), Bafa Gölü’nde klorofil-a konsantrasyonunun kestiriminde algoritmaların performansını değerlendirmek üzere Sentinel-2 uydu görüntülerini kullanmıştır. Algoritmalarından elde edilen model doğrulukları ile klorofil-a kestiriminde başarılı sonuçlar saptanmıştır.

Li vd., (2022), Nandu Nehri’nde optik olarak aktif olmayan su kalitesi parametrelerini beş makine öğrenme algoritması ve Landsat-8 uydu görüntüleri kullanarak modellemiştir. Sahada toplanan 67 su örneği 2021-2022 yılları arasındaki Landsat-8 uydu görüntüleri ile eşleştirilmiş olup seçilen tüm modellerin çalışma alanındaki su kalitesi parametrelerini tahmin edebildiği sonucuna varılmıştır.

Wei vd., (2022), Çin’de yer alan Wuhan ve Huangshi şehirlerindeki göllerin su kalitesi seviyelerini tespit etmek için Landsat-8 verileri ve derin öğrenme tekniklerini kullanmıştır. Wuhan’daki göller için derin sinir ağları %93,37 genel doğruluk gösterirken, Huangshi göllerinde bu oran %96,39 olarak hesaplanmıştır. Deneysel sonuçlar derin öğrenme tekniklerinin diğer yaklaşımlara kıyasla üstün performans gösterdiğini ortaya koymaktadır.

Yang vd., (2022), Baiyangdian Gölü'nde mekânsal-zamansal füzyon yöntemi kullanarak Landsat, Sentinel-2 ve GaoFen-2 verilerini birleştirmiş ve yüksek çözünürlüğe sahip füzyon görüntüleri elde etmiştir. Araştırmada, evrişimli sinir ağı tabanlı bir tersine çevirme modeli tasarlanarak klorofil-a parametresi tahmin edilmiştir. Ölçülen ve model tarafından tahmin edilen klorofil-a değerleri arasında $R^2 = 0,80$ düzeyinde bir korelasyon saptanmıştır.

Li vd., (2022), Güney Çin Denizi ile Pearl Nehri arasındaki bir geçiş bölgesinde hiperspektral verilere dayalı olarak klorofil-a alımı için entegre bir model geliştirmiştir. Farklı mevsim koşullarında klorofil-a ve bulanıklık konsantrasyonlarının değişimine odaklanılan çalışmada iki farklı ayda saha çalışmaları gerçekleştirilmiştir. Sentinel-2 uydu görüntülerine uygulanan eğim farkı indeks yönteminin klorofil-a için hatayı azaltan ve uygulanabilir bir yöntem olduğu sonucuna varılmıştır.

Qian vd., (2022), Qingcaosha Rezervuarı'nda uzaktan algılama, seyir izleme ve derin öğrenme metotlarını entegre bir şekilde kullanarak yeni bir yaklaşım sunmuştur. Araştırmada derin sinir ağı sonuçlarının geleneksel makine öğrenimi yöntemlerine göre daha başarılı bir çözüm sunduğu saptanmıştır.

Guo vd., (2022), Kanada Simcoe Gölü'ndeki klorofil-a, toplam azot ve toplam fosfor konsantrasyonlarını çok modlu derin öğrenme modelleri, Landsat uydu verileri ve eş zamanlı su kalitesi ölçümleri ile kestirmiştir. Araştırmada çok modlu derin öğrenme modelleri yerinde ölçüm verileri ile eğitilerek bağımsız veri kümesi ile doğrulanmıştır. Araştırma sonuçları, modellerin klorofil-a, toplam fosfor ve toplam azot parametrelerini (MAE = %32,57, %42,58, %35,05), (Bias = %10,61, -%2,82, %13,66) yeterli düzeyde tahmin ettiğini göstermektedir.

Cen vd., (2022), Doğu Çin Denizi'nde klorofil-a parametresi için akıllı bir tahmin modeli geliştirmeyi amaçlamıştır. İki farklı ön işleme metodu ile işlenen 10 yıllık uydu gözlemleri klorofil-a konsantrasyonunu ve logaritmik verileri LSTM sinir ağı için eğitim veri seti olarak kullanmıştır. Tahmin doğruluğu 2021 yılı gözlem sonuçları kullanılarak kontrol edilmiştir. Araştırma sonuçları her iki ön işleme yöntemi ile temin edilen tahminlerin klorofil-a parametresinin mevsimsel değişimini başarılı şekilde simüle edebileceğini göstermiştir.

Virdis vd., (2022), Doğu Asya'daki tropikal nehir sularında 65 adet Sentinel-2 görüntüsü ile elde edilen zaman serisini kullanarak su kalitesi parametrelerini tespit etmiştir. Çalışma sonuçlarının Güneydoğu Asya ülkelerinde su kaynaklarının izlenmesi

ve yönetimi açısından su kalitesi izleme ağına entegre olabilecek seviyede bir potansiyel sergilediği sonucuna varılmıştır.

Zhang vd., (2022), Çin'deki Dongping Gölü için 2013-2018 yılları arasındaki su kalitesi değişimlerini tahmin etmek üzere çeşitli spektral özelliklerle desteklenen yeni bir derin öğrenme metodu uygulamıştır. Araştırma sonuçları yerinde gözlem ile elde edilen verilerin LSTM'den türetilen parametreler ile arasında güçlü uyum olduğunu göstermiştir.

Ahmed vd., (2023), Bağdat kentindeki Dicle Nehri'nin su kalitesi parametrelerini tespit etmek için 14 farklı noktada ölçüm gerçekleştirmiştir. Sıcaklık ve pH için $R^2 > 0,8$ hesaplanırken minimum R^2 değeri askıda katı madde parametresi için elde edilmiştir. Landsat-8 görüntülerinin kullanıldığı çalışmada spektral indekslerin dahil edilmesi ile model performansının olumlu yönde etkilendiği sonucuna varılmıştır.

Zhang vd., (2023), Çin'in Zhejiang eyaletindeki yedi büyük nehir boyunca 2016-2021 yılları arasında ölçülen su kalitesi verileri, yerinde saha çalışmaları ve Sentinel-2 uydu görüntülerini kullanarak nehir suyu kalitesini modellemiştir. Permanganat, toplam nitrojen ve toplam fosfor parametreleri için sırasıyla 0,68, 0,70 ve 0,82 korelasyon katsayıları hesaplanmıştır.

Akgün (2023), Kura Nehri'nin Ardahan sınırında kalan bölgesi için klorofil-a parametresini test ederek Göktürk-2 uydu görüntüsü ile haritalandırmıştır. Parametreler arasındaki ilişkiyi test etmek amacıyla gerçekleştirilen regresyon analizinden $R^2 = 0,95$ hesaplanmış ve klorofil-a tespitinde uydu görüntülerinin anlamlı sonuçlar verdiği saptanmıştır.

Mahmoud vd., (2023), Auburn Körfezi'nde kentsel bir yağmur suyu göletinde uzaktan algılama teknolojisi ve yersel ölçümler ile su kalitesinin mekânsal dağılımını gerçekleştirmiştir. Korelasyon ve temel bileşen analizi kullanılarak su kalitesi parametrelerindeki ilişki başarılı bir şekilde yakalanmış olup uzaktan algılama tekniklerinin güvenilir sonuçlar verdiği saptanmıştır.

Rodríguez-López vd., (2023), Villaricca göl sistemindeki klorofil-a konsantrasyonunu tespit etmek için 2014-2021 yılları arasını kapsayan 25 Landsat görüntüsü kullanmıştır. Çalışmada iki spektral indeks kullanılarak klorofil-a için geri kazanım algoritması üretilmiş ve yüzen alg indeksi $R^2 = 0,87$, çiçeklenme indeksi $R^2 = 0,59$ hesaplanmıştır.

Amieva vd., (2023), Kuzey İtalya ve İsviçre'yi kapsayan üç gölde klorofil-a konsantrasyonunu tahmin etmek için Sentinel-3 görüntülerinden türetilen düşük

çözünürlüğe sahip eğitim verileri ile PRISMA hiperspektral görüntülerini kullanmıştır. Geleneksel makine öğrenme metotları ile derin öğrenme modellerinin kullanıldığı çalışmada destek vektör regresyonu klorofil-a tahminlerinde üstün bir performans gösterirken, rastgele orman algoritmasının tahminlerin mekânsal çözünürlüğünü iyileştirmek noktasında en başarılı model olduğu ortaya çıkmıştır.

Kowe vd., (2023), Zimbabwe'deki Manyame Gölü'nde Sentinel-2 uydu görüntülerini kullanarak bulanıklık, toplam nitrojen, klorofil-a ve toplam askıda katı madde özelliklerini tespit etmiştir. Regresyona dayalı ampirik modeller ile toplam askıda katı madde için $R^2 = 0,90$, bulanıklık için $R^2 = 0,95$ ve toplam nitrojen için $R^2 = 0,63$ katsayıları hesaplanmıştır. Elde edilen katsayılar gerçek ve tahmin verileri arasında çok güçlü ilişki bulunduğunu ortaya koymuştur.

Loaiza vd., (2023), Landsat uydu görüntüleri ile her altı ayda bir dört farklı örnekleme lokasyonundan toplanan ölçüleri kullanarak yüzey suyu kalitesini tahmin etmiştir. Çoklu doğrusal regresyon metodu ile klorofil-a, toplam organik karbon ve toplam çözünmüş madde parametreleri için hesaplanan katsayılar sırasıyla $R^2 = 0,81$, $R^2 = 0,93$ ve $R^2 = 0,88$ olup su kalitesi parametreleri ile ilişkili haritalar üretilmiştir.

Chen vd., (2023), Çin'deki Nanfei Nehri için suyun optimal parametrelerini otomatik olarak bulabilen, kendi kendini optimize eden yeni bir makine öğrenmesi izleme yöntemi önermiştir. Catboost tabanlı bir optimizasyon yaklaşımının kullanıldığı araştırmada yöntemle ait beş temel hiperparametrenin su kalitesi parametrelerinin tahmin performansı üzerinde belirgin düzeyde etkili olduğu belirlenmiştir.

Villota-González vd., (2023), Meksika'da bulunan Cajititlán ve Zapotlán göllerinde su kalitesi parametrelerini tahmin etmek üzere izleme istasyonundan alınan ölçüm verilerini kullanmıştır. Altı farklı makine öğrenme algoritması kullanılan araştırmada süper öğrenen algoritması ve çok katmanlı algılayıcı tahmin performansı bakımından diğerlerinden daha iyi sonuç vermiştir.

Yang vd., (2023), Çin'deki en büyük karstik sulak alan Huixian'da çok sensörlü uzaktan algılama görüntülerini kullanarak makine ve derin öğrenme yöntemlerini karşılaştırmıştır. Çoklu erişim modellerinin geliştirildiği araştırma sonuçları derin öğrenmenin daha yüksek R^2 değeri ile diğer yöntemlere kıyasla yüksek performans gösterdiğini ortaya koymaktadır.

Najafzadeh ve Basirian, (2023), Hudson Nehri'ndeki Su Kalitesi İndeksini (WQI) Landsat-8 uydu verileri ve dört farklı Yapay Zeka (AI) modelini kullanarak tahmin etmiştir. Landsat-8 uydu görüntülerinin spektral indeksleri ile su kalitesi parametreleri

arasındaki ilişki çoklu doğrusal regresyon modeli ile kurulmuştur. Araştırma sonuçları uydu görüntülerinin yapay zeka modelleri ile entegrasyonunun su kalitesinin tahmininde etkin gücünü ortaya koymaktadır.

Rodríguez-López vd., (2023), Güney Amerika kıtasındaki Llanquihue Gölü'nde klorofil-a kestirimi için uzaktan algılama ve makine öğrenme tekniklerini kullanmıştır. 0,64-0,93 aralığında değişen belirleme katsayıları tüm modellerin klorofil-a kestiriminde başarılı olduğunu göstermiştir.

Devi ve Mamatha, (2024), Hindistan'da bulunan Saki Gölü'nde makine öğrenme, doğrusal regresyon ve k-nn regresyonu modelleriyle bulanıklık konsantrasyonlarını tahmin eden başarılı bir yaklaşım sunmuştur. 2014-2017 yılları arasında ölçülen bulanıklık parametrelerini ve Landsat-8 uydu görüntülerini kullanarak, kırmızı bant yansımaları ve spektral indeksler ile model eğitilmiştir. Hiperparametre ayarı ile optimize edilen karar ağacı regresyonu $MAE = 3,246$, $RMSE = 3,802$ ve $R^2 = 0,776$ değerleri ile en iyi performansı göstermiştir.

Wang ve Chen, (2024), Çin'in Yunnan eyaletindeki Erhai Gölü'nde klorofil-a için yerinde ölçümler gerçekleştirerek sensörlerden temin edilen yansıma verilerinin tutarlılıklarını test etmiştir. Uzun vadeli klorofil-a tespiti için çok kaynaklı uzaktan algılama verilerine aşırı gradyan artırma algoritması öğretilmiş olup 20 yıllık bir süreyi kapsayan klorofil-a konsantrasyonu haritalandırılmıştır.

Bertone vd., (2024), Avustralya'da nehir ağzı lagünü olan Gold Coast Broadwater'daki klorofil-a ve askıda katı madde parametrelerini uydu görüntülerine dayalı olarak tahmin etmiştir. Çalışmada örnekleme bölgeleri gruplandırılmasıyla ampirik ve yarı ampirik tahmin modelleri geliştirilerek $R^2 = 0,40-0,75$ arasında değişen doğruluklar elde edilmiştir.

Ali vd., (2024), GLORIA veri setini kullanarak Çin'in çeşitli iç göllerindeki klorofil-a, secchi diski derinliği ve toplam askıda katı madde parametrelerini Sentinel-2 uydu verileri ile tahmin etmiştir. Çalışmada geliştirilen derin öğrenme modeli çeşitli makine öğrenme teknikleriyle karşılaştırılmıştır. Derin öğrenme modeli, hesaplanan $RMSE = 14,18$, $MAE = 7,42$, $MAPE = \%16$ değerleriyle klorofil-a tahmininde üstün performans göstermiştir.

Chellaiah vd., (2024), Kaveri Nehri boyunca çeşitli lokasyonlar için evrişimli sinir ağı ve uzun kısa süreli bellek algoritmalarını birleştiren yeni bir hibrit model ile $\%98,40$ 'lık bir doğruluk elde etmiştir. Araştırmada su kalitesi parametrelerinin daha önceden tanımlanan eşik değerleri aşması durumunda paydaşları derhal bilgilendiren

gerçek zamanlı bir uyarı sistemi kurularak etkili su kalitesi izleme, zamanında müdahale ve bilinçli karar alma noktasında başarılı çözümler sunulmuştur.

Etheram vd., (2024), Su kalitesi endeksini tahmin etmek için hibrit bir model geliştirerek farklı tahmin modelleriyle karşılaştırmıştır. Modelden elde edilen veriler nash-sutcliffe verimlilik katsayısını %4-20 ve %2,1-19 oranında artırmıştır. Su kalitesi endeksinin mekânsal ve zamansal tahminlerinde hibrit modelin güvenilir bir araç olduğu saptanmıştır.

Elias vd., (2024), Landsat-8 görüntülerine uygulanan makine öğrenme metotlarını kullanarak Tana Gölü'nde optik olmayan su kalitesi konsantrasyonlarını yapay sinir ağları, rastgele orman, adaboost, gradient boosting ve destek vektör regresyonu metotları ile tahmin etmiştir.

Rodríguez-López vd., (2024), Şili'deki Ranco Gölü'nde klorofil-a konsantrasyonunu tahmin etmek üzere dört gelişmiş makine öğrenme modeli kullanmıştır. Üç numune alma istasyonundan temin edilen 1987-2020 yılları arasındaki ölçüm sonuçları veri seti olarak kullanılmıştır. TCN modeli $R^2 = 0,96$, RSME = 0,13, MSE = 0,33 ve MAE = 0,06 katsayıları ile klorofil-a tahmininde başarılı sonuçlar vermiştir.

Moon vd., (2024), Güney Kore'deki dört büyük nehir boyunca derin öğrenme teknikleri, Sentinel-2 uydu görüntüleri ve su kalitesi verilerini entegre ederek toplam askıda katı madde konsantrasyonundaki zamansal ve mekânsal değişimleri tahmin eden bir model geliştirmiştir. Evrişimli sinir ağı modeli ile hesaplanan 0,758'lik nash-sutcliffe katsayısı, modelin geleneksel regresyon ve diğer modellere kıyasla daha yüksek doğruluk sağladığını göstermiştir.

Zhao vd., (2024), Çin'in güneydoğu bölgesindeki Zhejiang Eyaleti'nde bulunan nehir sisteminde su kalitesi parametrelerini kestirmek üzere izleme istasyonundan alınan verileri ve Sentinel-2 uydu görüntülerini kullanmıştır. Aşırı eğim artırma ağacı algoritması kullanılarak elde edilen katsayılar ile modeller başarılı performans göstermiştir.

Bygate ve Ahmed, (2024), Teksas, Matagorda Körfezi'nde Landsat-8 yüzey yansıma değerlerini ve yerinde gözlem verilerini kullanarak deneysel ve makine öğrenimi metotlarıyla su kalitesini tahmin etmiştir. Dört makine öğrenme metodu kullanılarak elde edilen sonuçların performansı test edilmiştir. Derin sinir ağı tuzluluk parametresini tahmin etmek için kullanıldığında diğer tüm makine öğrenme metotlarından üstün performans göstermiştir.

Kaynak araştırması kapsamında incelenen çalışmalar, uzaktan algılama tabanlı verilerin su kalitesi parametrelerinin modellenmesinde giderek artan bir etkinliğe sahip olduğunu açıkça ortaya koymaktadır. Literatürde başlangıçta basit istatistiksel ve geleneksel ampirik yaklaşımlar ağırlık kazanırken zaman içerisinde makine ve derin öğrenme tabanlı yöntemlerin daha karmaşık ve doğrusal olmayan ilişkileri başarıyla temsil edebildiği görülmektedir. Özellikle son yıllarda geliştirilen kestirim modelleri yüksek doğruluklu tahminler üretebilme potansiyeli sunmaktadır. Bu doğrultuda, mekânsal ilişkileri çözümleme yeteneği sayesinde, derin öğrenme teknikleri su kalitesine yönelik uzaktan algılama araştırmalarında popüler bir yaklaşım olarak öne çıkmakta ve sıklıkla tercih edilmektedir. Literatürde elde edilen bulgular ve geliştirilen metodolojik yaklaşımlar, bu çalışmada tercih edilen yöntemlerin bilimsel dayanağını oluşturmakta ve kuramsal çerçevesini desteklemektedir.


Tez çalışmasının üçüncü bölümünde, uzaktan algılama sistemlerinin temel ilkeleri ayrıntılı biçimde açıklanarak, bu sistemlerin su kalitesi izleme çalışmalarındaki rolü teorik açıdan irdelenmiştir. Ayrıca çalışmada kullanılan kestirim modellerinin teorik altyapısı, model yapıları ve temel bileşenleri ayrıntılı olarak ele alınmıştır.

3. UZAKTAN ALGILAMA VE KESTİRİM MODELLERİ

Bu bölümde, uzaktan algılama tekniklerinin kuramsal altyapısı ile su kalitesi parametrelerinin kestirimine yönelik kullanılan modelleme yaklaşımları ayrıntılı biçimde ele alınmıştır. Bölüm kapsamında uzaktan algılama sisteminin temelini oluşturan fiziksel prensiplerin doğru anlaşılabilmesi amacıyla öncelikle elektromanyetik enerji, elektromanyetik spektrum ve suyun spektral yansıtma özellikleri açıklanmıştır. Ardından uzaktan algılama verilerinin su kalitesi parametreleri ile olan ilişkisi ayrıntılı olarak ele alınmış ve bu verilerin su kalitesinin kestirimine yönelik geliştirilen farklı modelleme yaklaşımlarında nasıl kullanıldığı açıklanmıştır.


3.1. Elektromanyetik Enerji

Elektromanyetik enerji, harmonik dalgalar şeklinde yayılan ve ışık hızında (c) hareket eden tüm enerji türlerini kapsamaktadır. Bu enerji ortamı uzaktan algılama sistemini oluşturan temel bileşenler arasındaki etkileşimi sağlamaktadır. Radyo dalgaları, görünür ışık, morötesi ışınım, kızılötesi ve X ışınları spektrumunda yer alan başlıca elektromanyetik enerji türleridir. Elektromanyetik enerjinin yayılımı, elektrik ve manyetik alan bileşenlerinin karşılıklı etkileşimi sonucunda gerçekleşmektedir. Bu alan bileşenleri zamana ve konuma bağlı olarak periyodik bir davranış sergileyerek dalga karakterini oluşturmaktadır. Şekil 3.1.'de elektromanyetik enerjinin dalga yayılımı gösterilmektedir.



Şekil 3.1. Elektromanyetik enerjinin dalga yayılımı

Elektromanyetik enerjinin uzaydaki hareketi birbirini dik kesen elektrik ve manyetik alan ile karakterize edilir. Her iki alanın da titreşimi dalganın hareket yönüne dik olmakla birlikte bu alanlarda enerji ışık hızı ile hareketini sürdürmektedir (Janssen vd., 2001). Bir dalganın tepe noktasından diğer dalganın tepe noktasına olan mesafe dalga boyu olarak tanımlanırken belirli bir zaman diliminde uzayda sabit bir noktadan geçen tepe sayısı ise frekans olarak nitelendirilmektedir. Işık hızının sabit olduğu göz önünde bulundurulduğunda dalga boyu ile frekans arasında ters orantı bulunduğu bilinmektedir. Enerji, frekans ile doğru, dalga boyu ile ters orantıya sahip olduğundan artan dalga boylarında enerjide azalma gözlenmektedir. Şekil 3.2.'de enerji ve dalga boyu arasındaki ilişkinin grafiksel gösterimi sunulmaktadır.



Şekil 3.2. Enerji ve dalga boyu arasındaki ilişkinin grafiksel gösterimi (Sunar, 2018)

Elektromanyetik enerji, temel dalga kuramına uygun bir şekilde yayılım gösterir. Bu kuramda, enerjinin harmonik sinüzoidal formda ve ışık hızında hareket ettiği kabul edilmektedir. Elektromanyetik enerji, dalga kuramı ile tanımlanabilse de madde ile olan etkileşimi parçacık kuramı ile ifade edilir (Sivakumar vd., 2003). Elektromanyetik bir dalganın hızı, frekansı ve dalga boyu arasındaki ilişki Eşitlik (3.1)'de verilmiştir.

$$c = \lambda \cdot V \quad (3.1)$$

Burada;

λ = Dalga Boyu (m),

V = Frekans (Hz),

c = Işık Hızı'nı ifade etmektedir (3×10^8 m/sn) (Lillesand vd., 2004).

Elektromanyetik enerjinin kuantum teorisine göre karakteristik durumu Planck tarafından tanımlanmıştır. Enerji aynı yönde ve hızda dalgalar halinde yayılım gösteren küçük parçacıklar (kuantum) şeklinde kabul edilir. Her bir ışımaya ait enerji ise foton olarak nitelendirilir. Enerji dalgasının tek bir foton için taşıdığı enerjiye yönelik matematiksel ifadeler Eşitlik (3.2), Eşitlik (3.3) ve Eşitlik (3.4)'de verilmiştir.

$$E = h \cdot V \quad (3.2)$$

$$V = \frac{c}{\lambda} \quad (3.3)$$

$$E = \frac{h \cdot c}{\lambda} \quad (3.4)$$

Burada;

h = Planck Sabiti ($6,3 \times 10^{-34}$ j/s),

E = Enerji (j),

V = Frekans (Hz),

λ = Dalga Boyu (m),

c = Işık Hızı'nı ifade etmektedir (3×10^8 m/sn) (Sunar, 2018).

3.2. Elektromanyetik Spektrum


Elektromanyetik spektrum, nanometrelerden kilometrelere kadar uzanan geniş bir aralıkta elektromanyetik enerjiye ait tüm formları kapsayan ve ışık hızında hareket eden sürekli enerji ortamıdır. Elektromanyetik spektrum farklı bölümlere ayrılmış olsa da spektrumun bölüm ayrımlarına yönelik kesin bir sınır bulunmamaktadır. Spektrumun her farklı dalga boyu aralığında yeryüzüne yönelik başka özellikler analiz edilebilmektedir.

Bu nedenle, araştırma yapılacak konuya ilişkin kullanılacak uydu görüntülerinin ya da bantların tespit edilmesi noktasında elektromanyetik spektrum kritik öneme sahiptir. Uzaktan algılama tabanlı araştırmalarda spektrumun farklı aralıkları yeryüzü nesnelere ilişkin özgün spektral imzalar üretmektedir. Bu spektral tepkiler, farklı hedeflerin ayırt edilmesinde temel veri kaynağını oluşturmaktadır. Bu sebeple, spektral bant seçimi sadece sensör özelliklerine dayalı değil aynı zamanda analiz edilecek yüzey türünün karakteristik özelliklerine bağlı olarak da gerçekleştirilmelidir. Uzaktan algılamada kullanılan spektrum bölgeleri Tablo 3.1.'de sunulmaktadır.

Tablo 3.1. Uzaktan algılamada kullanılan spektrum bölgeleri (Lillesand vd., 2004, 2018)

Spektrum Bölgesi	Dalga Boyu Aralığı	Frekans	Uzaktan Algılamada Temel Kullanım Alanları
Görünür Işık	0,4 – 0,7 μm	$4,3 \times 10^{14}$ – $7,5 \times 10^{14}$ Hz	- Bitki sağlığı, arazi örtüsünün modellenmesi, tarım vb. uygulamalarda etkin bir şekilde kullanılır. - Temel spektral indekslerin (NDVI, NDWI vb.) hesaplanmasında ve analizinde önemlidir.
Yakın Kızılötesi	0,7 – 1,3 μm	$2,3 \times 10^{14}$ – $4,3 \times 10^{14}$ Hz	- Bitki sağlığı, su stresi ve canlılık göstergelerinde kullanılır. - Su kütlelerinin çevrelerinden ayırt edilmesinde belirleyicidir.
Kısa Dalga Kızılötesi	1,3 – 3,0 μm	$1,0 \times 10^{14}$ – $2,3 \times 10^{14}$ Hz	- Mineral, nem, toprak tipi ve su stresi analizinde kullanılır. - Su maskesi oluşturmak için kullanılır.
Orta Dalga Kızılötesi	3 – 5 μm	$6,0 \times 10^{13}$ – $1,0 \times 10^{14}$ Hz	Volkanik faaliyet, yangın tespiti ve endüstriyel ısı ölçümlerinde kullanılır.
Uzun Dalga Kızılötesi	8 – 14 μm	$2,1 \times 10^{13}$ – $3,7 \times 10^{13}$ Hz	- Yüzey sıcaklığının modellenmesi ve termal analizlerde kullanılır. - Su sıcaklığındaki değişimlerin izlenmesinde kullanılır.
Mikrodalgalar	1 mm – 1 m	$3,0 \times 10^8$ – $3,0 \times 10^{11}$ Hz	Toprak nemi, su seviyesi, taşkın riski, deformasyon ya da buz analizlerinde kullanılır.
Radyo Dalgaları	> 1 m	$< 3,0 \times 10^8$ Hz	- Uzaktan algılamada sınırlı kullanıma sahip olsa da bazı radar sistemlerinde kullanılır. - GNNS sistemleri ile deformasyon ve su seviyesi ölçümlerinde kullanılır.

Uzaktan algılama sistemleri, spektrumun farklı dalga boyu aralıklarında dünya yüzeyinin görüntülerinin alınmasına imkân sunmaktadır. Bu sebeple, uzaktan algılamada bir görüntünün en önemli özelliklerinden biri spektrumda hangi dalga boyu aralığında temsil edildiğidir. Uzaktan algılama uygulamalarında enerjinin dalga boylarına göre kategorize edilmesi yüzey özelliklerinin başarılı şekilde analiz edilmesi noktasında yaygın ve gerekli bir yaklaşımdır. Dalga boylarının ifade edilmesinde en sık kullanılan ölçü birimi mikrometredir (μm). Elektromanyetik enerji, farklı dalga boyu ve frekans aralıklarında değişen fiziksel özelliklere sahip bantlar halinde sınıflandırılmaktadır. Bu bantlar, yeryüzü ile etkileşimler esnasında çeşitli davranışlar sergileyerek uzaktan algılama verilerinin temelini oluşturmaktadır. Şekil 3.3.'te elektromanyetik spektrumun bantları ve uzaktan algılamadaki işlevleri gösterilmektedir.




Şekil 3.3. Elektromanyetik spektrumun bantları ve uzaktan algılamadaki işlevleri (Örmeci, 1987)

Uzaktan algılama arařtırmalarında temel rol oynayan elektromanyetik spektrum, 10'un kuvvetleri ile ifade edilen olduka geniř bir dalga boyu aralıđını kapsamaktadır. Bu geniřlik nedeniyle, elektromanyetik spektrum genellikle logaritmik lekli grafikler zerinde gsterilmektedir. Bu tr grafiklerde, insan gz ile algılanabilen blm olan grnr ıřık spektrumun olduka kk bir kısmına karřılık gelmektedir. İnsan gznn spektral duyarlılıđı yaklaşık 0,4-0,7 μm dalga boyu aralıđında yer almakta olup bu aralık grnr ıřık olarak tanımlanmaktadır. Grnr spektrum ierisinde mavi ıřık 0,45-0,50 μm , yeřil ıřık 0,50-0,57 μm ve kırmızı ıřık 0,62-0,70 μm dalga boyu aralıklarında yer almaktadır. Uzaktan algılama sistemleri, spektrumun grnr, kızıltesi ya da mikrodalga aralıklarının birinde ya da birkaında etkin olarak kullanılmaktadır (Lillesand vd., 2004).

Grntlerin bir kısmı spektrumun grnr ve yakın kızıltesi dalga boyu aralıđında gneřten yansıyan radyasyon ile iliřkiliyken diđer kısmı termal kızıltesi dalga boyu aralıđında yeryznden yayılan enerji olarak tanımlanır. Mikrodalga blm ise bir platform tarafından iletilen enerjinin yeryznden geri yansıması ve sinyalin algılanarak llmesi esasına dayanmaktadır. Burada enerji kaynađı sensrn kendisi olduđu iin aktif uzaktan algılama olarak kabul grmektedir. Pasif uzaktan algılama sistemlerinde ise enerji kaynađı gneř gibi harici bir kaynak tarafından sađlanmaktadır (Sivakumar vd., 2003). Spektral yansıma yeteneđi, yeryzne ait eřitli detayların ve zelliklerin birbirinden ayrılması noktasında belirleyici rol oynamaktadır. Bařka bir deyiřle geniř bir yelpazede uzanan elektromanyetik spektrumun herhangi bir dalga boyu aralıđındaki mevcut bantlar algılanması istenen nesnenin spektral karakteristiđine gre tepkiler vermektedir. Bu durum, eřitli nesnelerin algılanması noktasında farklı uzaktan algılama sistemlerinin geliřtirilmesine ve tasarlanmasına imkn sunmaktadır. Yeryzndeki farklı hedeflerin enerji ile etkileřiminde ortaya koydukları spektral imzaları, zellikle ok bantlı ve hiperspektral algılama verilerinin analiz edilmesinde temel veri kaynađı niteliđi tařımaktadır. Sensrlerin yksek spektral znrlđ ile hedef nesnelerin ayırt edilebilirliđi st seviyelere ıkarak sınıflandırma, kestirim ya da deđiřim analizi gibi temel uygulamalarda daha hassas ve gvenilir sonular temin edilmesine olanak tanınmaktadır. Bu durum, farklı zelliklere sahip yzeylerin spektral tepkilerinin daha iyi bir řekilde yakalanmasını mmkn kılmaktadır. zellikle, karmařık yapıya sahip dođal sistemlerde kk lekteki deđiřimlerin analizinde nemli avantajlar sunmaktadır. Ayrıca uzaktan algılama tabanlı analizlerin performansını ve elde edilen sonuların kalitesini artırmaktadır.

3.3. Cisimlerin Spektral Yansıtma Özellikleri


Aktif ya da pasif bir enerji kaynağından iletilen elektromanyetik enerji yeryüzü nesneleri ile çeşitli etkileşimler kurmaktadır. Bu etkileşimler sonucunda nesnelerin temel özelliklerine dayalı olarak enerji yansıtılır, yutulur ya da geçirilir. Enerji korunumu yasasına göre yeryüzüne ulaşan ilk enerji miktarı nesnelerin karakteristik özelliklerine bağlı olarak ne tür etkileşim yaşarsa yaşasın yansıtılan, yutulan ya da geçirilen enerji miktarına eşittir. Nitekim, bu yasanın temeli evrendeki enerji miktarının sabit olduğu fikrine dayanmaktadır. Elektromanyetik enerjinin yeryüzündeki nesnelerle olan bu etkileşimi uzaktan algılama sistemlerinin temelini oluşturmaktadır. Bu doğrultuda, uzaktan algılama sensörleri ile kayıt altına alınan sinyaller, yeryüzü özelliklerine ilişkin dolaylı ancak güvenilir bilgiler sunmaktadır. Spektrumun farklı aralıklarında gerçekleşen bu etkileşimlerin doğru bir şekilde analiz edilmesi yüzey türünün tespiti, parametrelerin kestirimi ile çevresel süreçlerin analizi bakımından oldukça önemlidir. Şekil 3.4.'te yeryüzüne ulaşan enerjinin spektral etkileşimi gösterilmektedir.



Şekil 3.4. Yeryüzüne ulaşan enerjinin spektral etkileşimi

Şekil 3.4.'te görüldüğü üzere yeryüzü nesnelere ulaşan elektromanyetik enerji yansıtılmakta, geçirilmekte ya da yutulmaktadır. Yansıtılma, nesneye ulaşan enerjinin bir bölümünün nesneden yansması ve saçılması şeklinde gelişmektedir. Bu durum, yüzeyin fiziksel özellikleri ya da ışınımın geliş açısına bağlı olarak farklı şekillerde gerçekleşebilmektedir. Geçirilen enerji, ışınımın bir kısmının nesnelerin içerisine nüfus etmesi temeline dayanmaktadır. Burada, nesneye ulaşan enerjinin bir bölümü nesneden geçirilerek diğer ortama iletilmektedir. Yutulan enerji ise nesnelere ulaşan ışınımın büyük bir bölümünün absorbe edilmesidir.

Yeryüzündeki tüm nesnelerin elektromanyetik spektrumun farklı dalga boylarındaki tepkileri çeşitlilik göstermekte ve bu durum spektral yansıtma karakteristiği hakkında fikir vermektedir. Enerjinin izleyeceği güzergâh, dalga boyuna ve nesne özelliklerine bağlı olarak değişiklik göstermektedir. Nesnelerin farklılık gösteren spektral karakteristikleri ise uzaktan algılama teknikleriyle ayırt edilebilmelerine olanak sağlar. Uzaktan algılama tabanlı uygulamalarda analiz edilen nesnelerin spektral özelliklerine hâkim olunması gerekmektedir. Kullanılacak uydu görüntülerinin, bantların ya da spektral indekslerin seçimi noktasında spektral yansıtma özellikleri kritik öneme sahiptir. Yeryüzüne ulaşan enerjinin nesnelerle olan etkileşimi spektral yansıtım eğrisi ile grafiksel metotla temsil edilir. Spektral yansıtım eğrileri, farklı yüzeylerin dalga boyuna dayalı davranışlarını gözler önüne sermekte ve uzaktan algılama tabanlı araştırmalarda referans verisi olarak kullanılmaktadır. Uydu verilerinin analizinde bu eğrilerin göz önünde bulundurulması optimum analizlerin gerçekleştirilmesi noktasında oldukça değerli fikirler sunmaktadır. Şekil 3.5.'te başlıca yeryüzü nesnelerinin spektral yansıtım eğrileri gösterilmektedir. Tez kapsamında su kalitesi araştırıldığından sadece suyun spektral yansıtma özelliklerine değinilecektir.



Şekil 3.5. Yeryüzü nesnelerinin spektral yansıtım eğrileri

3.3.1. Suyun spektral yansıtma özellikleri

Su kütlelerine ulaşan ışınının büyük bir bölümü geri yansıma olmadan absorbe edilir ya da geçirilerek derin katmanlara iletilir. Özellikle ışınım, görünür ışık bölgesi ile yakın kızılötesi dalga boylarında kısa dalga boylarına kıyasla daha fazla oranda emilmektedir. Bu durum, kısa dalga boylarında (mavi, mavi-yeşil) daha fazla yansıma olduğundan su kütlelerinin mavi ya da mavi/yeşil olarak görünmesine sebebiyet vermektedir. Buna karşın, kırmızı ve yakın kızılötesi dalga boylarında emilimin baskın olmasının bir sonucu olarak su kütleleri daha koyu görünümündedir. Bir su kütlelerinin yansıtma özelliklerini belirleyen başlıca etkenler suyun derinliği, içerisindeki maddeler ya da yüzey pürüzlülüğüdür (Sivakumar vd., 2003). Suyun spektral yansıtım özellikleri incelendiğinde en dikkat çekici durum spektrumun yakın kızılötesi ve daha ötesindeki dalga boylarında absorpsiyon eğiliminin belirgenleşmesidir. Bu durum, serbest su kütlelerinde (göl, akarsu vb.) olduğu gibi toprak ya da bitki içerisindeki su miktarı için de geçerlidir. Su kütlelerine yönelik gerçekleştirilen uzaktan algılama tabanlı araştırmalarda yakın kızılötesi spektral aralığın kullanılma sebebi bu bölgede yansıma oranının azalmasından kaynaklı kolaylıkla tespit edilebilmesidir. Su kütlelerinin fiziksel, kimyasal ya da biyolojik özelliklerine ilişkin detaylı bilgiler ise görünür ışık dalga boyları kullanılarak sağlanmaktadır. Ancak, madde ile enerji arasındaki karmaşık etkileşimler sebebiyle bu bölgede çeşitli faktörler de göz önünde bulundurularak değerlendirme yapılması gerekmektedir. Örneğin, su kütlelerindeki askıda maddeler, su yüzeyinin pürüzsüzlüğü ya da suyun tabanı ile olan etkileşimi sebebiyle de spektral yansımalar gerçekleşebilmektedir. Dip etkilerinin ihmal edilebilir seviyede olduğu derin sularda bile su yüzeyinden ölçülen spektral yansıma sadece suyun optik özelliklerine bağlı gelişmemekte su içerisindeki yabancı maddelerden de kaynaklanabilmektedir. Temiz sularda, kısa dalga boylarında (dalga boyu $< 0,6 \mu\text{m}$) absorpsiyon seviyesi minimum düzeydedir. Bu sebeple, mavi-yeşil dalga boyu aralığında suyun geçirgenliğinin yüksek olması sebebiyle su rengi karakteristik görünüm kazanır. Ancak, suya nüfus eden organik ya da inorganik maddeler ve su bulanıklığının artması, hem bu geçirgenlik durumunda hem de yansıtma seviyelerinde belirgin farklara sebep olmaktadır. Benzer şekilde sudaki klorofil konsantrasyonu da yansıma özelliklerinde değişiklikler yaratmaktadır. Klorofil konsantrasyonunun artış göstermesiyle birlikte mavi dalga boyu aralığında yansıma azalmakta yeşil dalga boylarında ise artış göstermektedir (Lillesand vd., 2004).

3.4. Uzaktan Algılama ve Su Kalitesi

Geleneksel su kalitesi gözlem metotları laboratuvar analizleri ve yerinde ölçüm gerektirmesi yönüyle zaman alıcı ve yüksek maliyetlidir. Bu yöntemler doğru sonuçlar sağlasa da geniş bir mekânsal ölçekte kararlı bir bakış açısı sunmayabilir (Lim ve Choi, 2015). Ayrıca geleneksel metotların tek başına kullanılması ekolojik olayların gözlemsel ölçeklerini daraltarak zamansal açıdan süreksiz kılmaktadır (Estes vd., 2018). Aşağıda geleneksel metotlar ile karşılaşılan en önemli sınırlamalar listelenmiştir;

- Su numunelerinin toplanması ya da yerinde ölçülmesi yoğun iş gücü ve geniş zaman gerektiren maliyeti yüksek bir süreçtir.
- Geniş su kütlelerinde trend analizinin yapılması, zamana ve konuma bağlı değişimin izlenmesi neredeyse imkânsızdır.
- Topografya koşulları göz önünde bulundurulduğunda her su kütlesinin izlenmesi, yönetilmesi ya da tahmin edilmesi mümkün olmayabilir.
- Yerinde ölçüm ve laboratuvar analizlerindeki hatalar sebebiyle verilerin doğruluğu sorgulanabilir boyutta olabilir (Gholizadeh vd., 2016).

Uzaktan algılama teknikleri, sudan yansıyan spektral imzadaki değişimi analiz eden ve bu değişimi deneysel ya da analitik metotlar yardımıyla su kalitesi parametreleri ile ilişkilendiren yeteneğe sahiptir (Ritchie vd., 2003). Değişimin sebebi ise su kütlesindeki maddelerin suyun yansıma özelliklerini farklılaştırmasıdır. Uzaktan algılama ile aynı uydu sensöründen toplanan zaman serileri kullanılarak su kirliliği zamansal boyutta analiz edilerek su kalitesindeki değişiklikler izlenebilmektedir (Gholizadeh vd., 2016). Uzaktan algılama ve uydu teknolojilerindeki yenilikler ile özellikle hiper çözünürlükte uydu verilerinin kullanıma sunulmasıyla sinoptik ölçekli ve uzun vadeli su kalitesi izleme araştırmaları hızlı bir şekilde ilerlemiştir (Yang vd., 2022). Uzaktan algılama, su kalitesi değişimlerinin izlenmesi, su kaynaklarının etkin olarak yönetilmesi ve kirlilik risklerine yönelik erken uyarı sistemlerinin geliştirilebilmesi açısından başarılı çözümler sunan etkili bir teknolojidir. Ancak, bu tekniklerin tek başına kullanılmasında çeşitli sınırlamalarla karşılaşılması mümkün olup gerçek ölçü verileriyle entegrasyonu ile daha etkili yaklaşımlar sergilenebilmektedir. Uzaktan algılama teknolojisi, stratejik izleme ve yerinde ölçüm verileri ile entegre kullanıldığında gelecekteki su kalitesi sorunlarını kestirmeye, azaltmaya ve büyük oranda önlemeye

imkân sunan faydalı bir araçtır (Olmanson vd., 2011). Uzaktan algılama tekniklerinin su kalitesi konsantrasyonlarının tahmininde sağladığı avantajlar aşağıda sıralanmıştır;

- Su kütlesinin tamamını içeren sinoptik bir görünüm sağlayarak değişimin başarılı bir şekilde izlenmesini mümkün kılar.
- Geniş bir alandaki birden fazla gölün su kalitesinin senkronize şekilde elde edilmesine olanak sağlar.
- Bir alandaki su kalitesinin kapsamlı tarihsel kayıtlarının tutulması ve zamansal eğiliminin temsil edilmesini sağlar.
- Numune örnekleme için optimum lokasyonların belirlenmesi ve planlanmasına imkân sunar (Kallio, 2000).

Uzaktan algılama teknolojisi, su kütlelerinin fiziksel ve biyokimyasal özelliklerinin geniş alanlarda zamansal süreklilik içerisinde takip edilmesine olanak tanıyan kıymetli çözümler sağlamaktadır. Bu doğrultuda, su kütleleri içerisindeki optik etkileşim mekanizmalarına dayalı olarak su kalitesi konsantrasyonları algılanmakta ve değerlendirilmektedir. Su kalitesi parametreleri uzaktan algılama perspektifinde kategorize edildiğinde optik etkinliklerine göre iki gruba ayrılabilir. Su kalitesi parametrelerinin uzaktan algılama tabanlı optik etkinlikleri Tablo 3.2.'de sunulmaktadır.

Tablo 3.2. Su kalitesi parametrelerinin uzaktan algılama tabanlı optik etkinlikleri (Tesfaye, 2024)

Su Kalitesi Parametreleri	Kısaltma	Birim	Optik Etkinlik
Klorofil-a	CHL-A	µg/L	Aktif
Secchi Diski Derinliği	SDD	M	Aktif
Su Sıcaklığı	WT	°C	Aktif
Bulanıklık	TUR	NTU	Aktif
Toplam Askıda Katı Madde	TSM	mg/L	Aktif
Elektriksel İletkenlik	EC	µS/cm	Aktif
Deniz Yüzey Tuzluluğu	SSS	PSU	Aktif
Renkli Çözünmüş Organik Madde	CDOM	mg/L	Aktif
Toplam Organik Karbon	TOC	mg/L	Aktif
Çözünmüş Oksijen	DO	mg/L	İnaktif
Kimyasal Oksijen İhtiyacı	COD	mg/L	İnaktif
Biyokimyasal Oksijen İhtiyacı	BOD	mg/L	İnaktif
Toplam Azot	TN	mg/L	İnaktif
Amonyak	NH ₃ -N	mg/L	İnaktif
Toplam Fosfor	TP	mg/L	İnaktif
Çözünebilir Reaktif Fosfor	PO ₄	mg/L	İnaktif

Uzaktan algılama teknikleriyle su kalitesi parametrelerine uygulanan geri kazanım algoritmalarının temeli, örneklenen su kalitesi konsantrasyonlarının uydu görüntüleriyle eşleştirilerek modellenmesi prensibine dayanmaktadır. Geri kazanım algoritmaları, uydu sensörleri tarafından yakalanan su çıkış radyansı spektrumundan bir su kalitesi parametresinin konsantrasyonunu kestirmek için kullanılmaktadır. Su kalitesi parametreleri, çeşitli modelleme teknikleri ve algoritmaları geliştirilerek uzaktan algılama verilerinden elde edilir. Yaygın olarak kullanılan uzaktan algılama tabanlı su kalitesi modelleme yöntemleri ampirik, analitik ve makine öğrenmesi yöntemleri olarak gruplandırılabilir (Teskaye, 2024). Bu çalışmada, uzaktan algılama tabanlı su kalitesi modelleme yaklaşımları, Mogan Gölü'nün fiziksel durumu ve örnekleme yapısı dikkate alınarak ele alınmıştır. Uydu görüntülerinden türetilen spektral veriler saha ölçümleriyle ilişkilendirilerek su kalitesi parametrelerinin kestiriminde farklı modelleme stratejilerinin performansları karşılaştırılmalı olarak değerlendirilmiştir. Bu kapsamda, su kalitesi parametrelerinin kestirimi için RO, YSA ve ESA modelleri kullanılarak model performansları karşılaştırılmıştır.

3.5. Su Kalitesi Parametreleri

Su kalitesi, yüzey sularının kullanım potansiyeli, sürdürülebilir yönetimi ve ekolojik dengesi açısından temel bir gösterge niteliği taşımaktadır. Çeşitli kullanım amaçları doğrultusunda yüzey sularının fiziksel, kimyasal ve biyolojik özelliklerinin düzenli olarak izlenmesi gerekmektedir. Bu özelliklerde meydana gelen değişimler, su kaynakları üzerindeki etkileri yansıtırken çok sayıda parametrenin birlikte ele alınmasını zorunlu kılmaktadır. Su kalitesi parametreleri, su kütlelerinin mevcut durumunu ortaya koymanın yanı sıra çevresel risklerin analiz edilmesi ve yönetim stratejilerinin geliştirilmesi açısından da önemli bir rol üstlenmektedir. Yüzey sularının kalitesi, sahip olduğu mineral ya da organik maddeler, askıda maddeler, mikroorganizmalar ve çözünmüş gazların varlığına bağlı olarak şekillenir (Alcamo, 2019). Su kalitesinin analizi doğal oluşumlar ya da antropojenik faaliyetler sonucu gelişen fiziksel, kimyasal ve biyolojik değişimler aracılığıyla gerçekleştirilebilir (Britto vd., 2018). Su kütlelerinde çeşitli parametrelere yönelik kalite standartlarını tanımlayan “Kıtaıçi Yerüstü Su Kaynaklarının Genel Kimyasal ve Fizikokimyasal Parametreler Açısından Sınıflarına Göre Kalite Kriterleri” Yerüstü Su Kalitesi Yönetmeliği'nden temin edilerek Tablo 3.3.'te sunulmaktadır.

Tablo 3.3. Kıta içi yerüstü su kaynakları için kalite sınıfı kriterleri (YSKY, 2021)

Su Kalite Parametreleri	Su Kalite Sınıfları ^(a)		
	I (çok iyi)	II (iyi)	III (orta)
Renk (m ⁻¹)	RES 436 nm: ≤ 1,5 RES 525 nm: ≤ 1,2 RES 620 nm: ≤ 0,8	RES 436 nm: 3 RES 525 nm: 2,4 RES 620 nm: 1,7	RES 436 nm: > 4,3 RES 525 nm: > 3,7 RES 620 nm: 2,5
pH	6-9	6-9	6-9
İletkenlik (µS/cm)	< 400	1000	> 1000
Yağ ve Gres (mg/L)	< 0,2	0,3	> 0,3
Çözünmüş oksijen (mg/L)	> 8	6	< 6
Kimyasal oksijen ihtiyacı (KOİ) (mg/L)	< 25	50	> 50
Biyokimyasal oksijen ihtiyacı (BOİ ₅) (mg/L)	< 4	8	> 8
Amonyum azotu (mg NH ₄ ⁺ -N/L)	< 0,2	1	> 1
Nitrat azotu (mg NO ₃ ⁻ -N/L)	< 3	10	> 10
Toplam kjeldahl-azotu (mg N/L) ^(b)	< 0,5	1,5	> 1,5
Toplam azot (mg N/L) ^(c)	< 3,5	11,5	> 11,5
Orto fosfat fosforu (mg o-PO ₄ -P/L)	< 0,05	0,16	> 0,16
Toplam fosfor (mg P/L)	< 0,08	0,2	> 0,2
Florür (µg/L)	≤ 1000	1500	> 1500
Mangan (µg/L)	≤ 100	500	> 500
Selenyum (µg/L)	≤ 10	15	> 15
Sülfür (µg/L)	≤ 2	5	> 5

(a) Kalite sınıflarına göre suların kullanım maksatları:

- I. Sınıf - Yüksek kaliteli su (I. sınıf su kalitesinde olması “Çok İyi” su durumunu ifade etmektedir.);
 - 1) İçme suyu olma potansiyeli yüksek olan yerüstü suları,
 - 2) Yüzme gibi vücut teması gerektirenler dâhil rekreasyonel maksatlar için kullanılabilir su,
 - 3) Alabalık üretimi için kullanılabilir nitelikte su,
 - 4) Hayvan üretimi ve çiftlik ihtiyacı için kullanılabilir nitelikte su,
- II. Sınıf - Az kirlenmiş su (II. sınıf su kalitesinde olması “İyi” su durumunu ifade etmektedir.);
 - 1) İçme suyu olma potansiyeli olan yerüstü suları,
 - 2) Rekreasyonel maksatlar için kullanılabilir nitelikte su,
 - 3) Alabalık dışında balık üretimi için kullanılabilir nitelikte su,
 - 4) Mer’i mevzuat ile tespit edilmiş olan sulama suyu kalite kriterlerini sağlamak şartıyla sulama suyu,
- III. Sınıf - Kirlenmiş su (III. sınıf su kalitesinde olması “Orta” su durumunu ifade etmektedir.); Gıda, tekstil gibi nitelikli su gerektiren tesisler hariç olmak üzere,

uygun bir arıtmadan sonra su ürünleri yetiştiriciliği için kullanılabilir nitelikte su ve sanayi suyu, ifade etmektedir.

(b) TKN: $\text{NH}_3\text{-N} + \text{Organik Azot}$

(c) TN: $\text{TKN} + \text{NO}_3\text{-N} + \text{NO}_2\text{-N}$ (YSKY, 2021).


Bu çalışmada, uzaktan algılama verileriyle ilişkilendirilebilirliği yüksek olan su kalitesi parametreleri tercih edilmiştir. Bu kapsamda, klorofil-a, askıda katı madde ve secchi diski derinliği parametreleri ele alınmış ve bu parametrelerin mekânsal ve zamansal dağılımları uydu görüntülerine dayalı olarak analiz edilmiştir.

3.5.1. Klorofil-a

Klorofil-a (CHL-A) bitkilerin, alglerin ve siyanobakterilerin bünyesinde bulunan bir çeşit klorofil pigmentidir. Bu pigment sudaki su bitkilerinin ve alglerin fotosentez için gerekli ışık enerjisini yakalamalarına ve kullanmalarına imkân sunmaktadır (Kutser, 2009). Klorofil-a seviyesi, su kütlelerinde fitoplankton birikimini ve göl ötrofikasyon derecesini gösteren bir ölçüttür (Johnson ve Harriss, 1980). Sık periyotlarla ve kapsamlı bir şekilde gerçekleştirilen klorofil-a ölçümleri ile su kütlelerindeki alg varlığı ve ötrofikasyon seviyesi detaylı bir şekilde analiz edilebilmektedir (O'Reilly vd., 1998). Bu durum, su kütlelerindeki genel iç su kalitesinin anlaşılmasına ve gelecekteki koruma çalışmalarının stratejik bir şekilde yönetilmesine olanak sağlamaktadır.

Düşük fitoplankton birikimine sahip su kütlelerinde klorofil-a spektrumu 680 nm'de güneş kaynaklı bir floresan pik noktasıyla nitelendirilir. Bu pik noktası fotosentezde görev alan, bitkilere ve alglere yeşil rengini veren bir pigment olan klorofil-a barındıran fitoplanktonların varlığıyla ilişkilidir (Gower vd., 2005). Temelde artan klorofil-a konsantrasyonu ile yüzey yansıtım değerleri doğru orantılı bir ilişkiye sahiptir. 400-600 nm (Mavi-Yeşil) dalga boyu aralığında artan klorofil-a seviyesi ile yüzey yansıtımı doğru orantılı bir şekilde artarken, 675-685 nm (Yeşil-Kırmızı) dalga boyu aralığında yansıtım değerinin klorofil-a seviyesi ile doğru orantılı bir şekilde düştüğü (yutulduğu) gözlenmektedir (Ritchie, 2003). Klorofil pigmentlerinin ışıkla etkileşimi su kütlelerinden temin edilen yansıma değerlerinin analiz edilmesinde kritik bir rol oynamaktadır. Farklı dalga boyu aralıklarında meydana gelen değişimler klorofil yoğunluğundaki mekânsal ve zamansal farklılıkların tespit edilmesine imkân sağlamaktadır. Klorofil pigmentlerinin spektral davranışlarının anlaşılması, su kalitesi

parametrelerine yönelik gerçekleştirilen optik analizler ve modelleme yaklaşımları açısından oldukça önemlidir. Şekil 3.6.'da klorofil pigmentlerinin absorpsiyon spektrumu gösterilmektedir.



Şekil 3.6. Klorofil pigmentlerinin absorpsiyon spektrumu (Gholizadeh vd., 2016)

Klorofil-a kestirim metotları, her biri farklı avantajlara ve sınırlamalara sahip olan fiziksel tabanlı ve veri odaklı yaklaşımlar olarak genel anlamda iki kategoride sınıflandırılabilir. Fiziksel tabanlı metotlar, klorofil-a konsantrasyonunu zamansal ve mekânsal olarak modellemek için fiziksel, kimyasal ve biyolojik süreçleri kullanır. Veri odaklı yaklaşımlar ise, geçmişe yönelik veri setlerinden birtakım kalıplar öğrenerek gelecekteki konsantrasyon dağılımlarını çıkarır. Bu metotlar; istatistik, makine öğrenimi ve yapay zeka tekniklerinden yararlanarak daha az bilgi ile daha net sonuçlar verir (Ruan vd., 2025). Klorofil-a konsantrasyonu, uydu görüntülerinin yakın kızılötesi (NIR) bandındaki maksimum ve kırmızı bandındaki minimum yansıma değerleri arasındaki bant oranlaması, diferansiyel model, üç bantlı model ve deneysel sinir ağı kullanan yapay zekâ modelleri kullanılarak tahmin edilebilir (Tsfaye, 2024). Uzaktan algılama teknikleri ile makine ve derin öğrenme yaklaşımlarının entegre bir şekilde kullanılması klorofil-a konsantrasyonunun kestirilmesi ve modellenmesinde çift yönlü bir avantaj sağlamaktadır.


3.5.2. Askıda katı madde

Kıyı ve iç su kütlelerinde çevre kalitesinin en önemli parametrelerinden biri olan askıda katı madde (AKM) konsantrasyonunun incelenmesi su kalitesinin irdelenmesi noktasında büyük önem taşımaktadır. Askıda katı madde toprak erozyonunun doğru tahmininde kirlilik seviyelerinin temsil edilmesinde önemli rol oynar. Ayrıca su kütlesine ulaşan ışık miktarını azaltır, sucul bitkilerin gelişimini etkiler ve fitoplanktonun primer verimliliğini kontrol eder (Zhang vd., 2021). Askıda katı maddeler, fosfor ve azot gibi organik maddelerin su kütlelerindeki hareketi, taşınımı ve değişiminde önemli rol oynamaktadır (Bianchi vd., 2009). Uzaktan algılama teknikleri askıda katı madde konsantrasyonlarını ve bunların zamansal ve mekânsal değişimlerini haritalandırmak için yaygın olarak kullanılmaktadır (Torres-Vera, 2023). Askıda katı madde miktarının doğru şekilde belirlenmesi sediment çeşidi ve değişen ışık şartlarından etkilenen yansıma değerlerine bağlı olarak zorlaşmaktadır. Askıda katı madde konsantrasyonu açısından zengin olan su kütleleri temiz sulara kıyasla daha yüksek yansıma değerleri göstermektedir. Yüksek dalga boylarının suya nüfuz etme potansiyeli düşük dalga boylarına kıyasla daha sınırlıdır. Bu nedenle yüksek dalga boylarında su tabanının etkisi oldukça azdır (Mobasheri, 2008). Suyun yüzeyinden yansıyan güneş ışınımı, askıda katı madde miktarı ve dalga boyuna bağlı olarak değişkenlik gösterir. 450-900 nm aralığında sediment miktarı arttıkça yansıyan ışınım da artmaktadır. Düşük sediment seviyelerinde ise maksimum yansıma 550 nm’de olurken yüksek seviyelerde bu aralık 600 nm’nin üzerine çıkar. 700-800 nm aralığında ise yansıyan ışınım ve sediment miktarı arasındaki ilişki daha tutarlıdır (Ritchie, 1976). Askıda katı madde konsantrasyonlarının su kütlelerindeki mekânsal dağılımı, suyun optik özelliklerini doğrudan etkileyerek ışınımın saçılma ve soğurulma süreçlerinde kritik rol oynamaktadır. Optik duyarlılığı nedeniyle uzaktan algılama tabanlı su kalitesi izleme araştırmalarında sıklıkla tercih edilen temel göstergelerden biridir.

3.5.3. Secchi disk derinliği

Su berraklığını operasyonel olarak tahmin etmenin en bilinen yöntemi, Pietro Angelo Secchi tarafından 1865 yılında geliştirilen Secchi diskidir. Bu disk okyanus ve göllerde suyun berraklığını ölçmek amacıyla kullanılır. Dairesel şeklindeki disk bir ip yardımıyla suya bırakılır ve üzerindeki desen kayboluncaya kadar aşağı indirilir. Elde

edilen ölçüm değeri secchi diski derinliği (SDD) olarak adlandırılır ve bu değer suyun bulanıklık seviyesiyle de ilgilidir (Ggholizadeh vd., 2016). Şekil 3.7.'de secchi diski ve ölçüm prensibinin şematik gösterimi sunulmaktadır.



Şekil 3.7. Secchi diski ve ölçüm prensibinin şematik gösterimi

Secchi diski, su kirliliğinin minimum düzeyde olduğu derin göl ya da okyanuslarda en yüksek doğruluklu sonuçları vermektedir (Kirk, 2011). Su berraklığını ya da kalitesini ölçmek için günümüzde farklı tipte gelişmiş elektro-optik sistemler kullanılsa da secchi diskleri düşük maliyetleri ve pratik kullanımları sebebiyle limnoloji ve okyanus bilimi araştırmalarında düzenli olarak tercih edilmektedir (Alikas ve Kratzer, 2017). Secchi diski ile gerçekleştirilen saha çalışmaları her ne kadar pratik olsa da, sınırlı veri hacmi ve mekânsal kapsamı ile sürekli ölçüm eksikliği gibi sınırlamaları bulunmaktadır. Bu durum, gerçek zamanlı ve geniş çaplı izlemeyi imkânsız hale getirmektedir. Ayrıca su yüzeyindeki ışınımın yoğunluğu ve ölçüm yapan kişinin öznel algısı gibi etkenler, gözlemlerin performansını etkileyebilecek düzeyde belirsizlikler ortaya çıkarmaktadır (Huo vd., 2025). Uzaktan algılama teknikleri, bu tür sınırlamaların üstesinden gelmekte ve secchi diski derinliğinin geniş ölçekli bölgelerde mekânsal modellenmesi için etkin olarak kullanılmaktadır. Secchi diski derinliği ile askıda katı madde konsantrasyonu arasında ters bir korelasyon bulunmaktadır. Uzaktan algılama teknikleri ile secchi diski derinliği kestiriminde kırmızı spektrumu kapsayan dalga boyları ve bant oranları su berraklığının elde edilmesinde etkili çözüm sunmaktadır (Batina ve Krtalic, 2023). Son yıllarda uzaya konuşlandırılan çok sayıda uydunun başarılı bir şekilde işletilmesi ve veri sağlaması, uzaktan algılama araştırmacılarını su berraklığını analiz

etmek üzere çeşitli ters çevirme algoritmalarını geliştirmeye teşvik etmiştir. Bu algoritmalar temel olarak deneysel, yarı analitik ve makine öğrenmesine dayalı yöntemler olmak üzere üç kategoriye ayrılır (Huo vd., 2025). Bu çalışmada, uzaktan algılama tabanlı makine ve derin öğrenme teknikleri kullanılarak su kalitesi parametreleri kestirilmiştir.

3.6. Kestirim Modelleri

Kestirim modelleri, belirli dalga boyu aralığındaki saha ölçümleri ile yansıma değerleri arasındaki temel ampirik bağıntılardan, radyatif transfer odaklı ve spektral ilişkilere dayanan modellere kadar farklı yaklaşımlarda uygulanabilmektedir (Politi vd., 2015). Uzaktan algılama tekniklerine dayalı su kalitesi analizinin temel ilkesi, yerinde ölçüm verileri ile eşleştirilen uydu görüntülerinin model kurmak üzere bir araya getirilmesi esasına dayanmaktadır. Kestirim modelleri, bir sensör ile kaydedilen ışıma ile bir su kalitesi parametresinin konsantrasyonunu kestirmek için kullanılmaktadır (Tesfaye, 2024). Bu çalışmada, su kalitesi parametrelerinin kestirimi amacıyla sırasıyla RO, YSA ve ESA modelleri kullanılmıştır. Söz konusu modeller, spektral yansıma verileri ile su kalitesi değişkenleri arasındaki doğrusal ve doğrusal olmayan ilişkileri öğrenme kapasiteleri doğrultusunda seçilmiştir. Bu bölümde, her bir modelin teorik altyapısı ve modelleme sürecindeki işlevleri ayrıntılı olarak açıklanmaktadır.

3.6.1. Rastgele orman (RO)


RO, sınıflandırmada oldukça yüksek doğruluklu sonuçlar sağlaması sebebiyle makine öğrenme teknikleri arasında diğer yöntemlere kıyasla daha fazla kullanılan ve karar ağacı temeline dayanan bir yöntemdir. Bu metot, rastgele belirlenen örneklem kümesiyle bu kümeden elde edilen değişkenler alt kümesini kullanarak çok fazla karar ağacı oluşturur (Belgiu ve Drăgut, 2016). RO yöntemi ile istenen ağaç sayısı kadar sınıflandırma ve regresyon ağacı toplulukları oluşmaktadır. Yöntemin temeli çok fazla ağaç içinden rastgele belirlenen bir alt küme vasıtasıyla topluluklar üretmektir (Breiman, 2001). RO, her ne kadar karar ağaçları için tanımlanmışsa da algoritma her sınıflandırıcı için geçerlidir. Çok fazla girdi değişkenini ele alıyor olması yöntemin önemli avantajlarından (Skurichina ve Duin, 2002). RO algoritması hesaplama ve istatistiksel bakımdan ele alındığında çeşitli avantajlarıyla öne çıkmaktadır. Hesaplama açısından irdelendiğinde;

- Sınıflandırma ve regresyon metotlarının her ikisini de doğal olarak ele alması,
- Tahmin ve eğitim süreçlerinin hızlı olması,
- Bir ya da iki ayarlama parametresi kullanılarak geliştirilebilmesi,
- Genelleme hatası için yerleşik bir tahmin mekanizmasına sahip olması,
- Yüksek boyuta sahip problemlerin çözümünde doğrudan kullanılabilmesi,
- Paralel olarak kolay bir şekilde uygulanabilmesi yöntemin avantajlarından.

İstatistiksel açıdan değerlendirildiğinde ise;

- Değişken önem ölçüleri,
- Diferansiyel sınıf ağırlıklandırması,
- Kayıp değer imputasyonu,
- Görselleştirme,
- Aykırı değer tespiti,
- Denetimsiz öğrenme yöntemin avantaj sağlayan özellikleridir (Cutler vd., 2011).

Karar ağaçlarını çeşitlendirmek model performansını iyileştirebilmektedir. RO, bu amaca veri ve girdi setinin rastgele eğitilmesiyle ulaşmaktadır. RO, rastgele olarak değiştirme ve çıkarma yöntemiyle çeşitli yeni alt kümeler üretir. Bu eğitim alt kümelerinin boyutu ise en baştaki eğitim veri seti boyutuyla aynı olup tekrar eden alt kümeleri çıkarma ve değiştirme yöntemiyle üretilir (Wu vd., 2019). Bu yaklaşım sayesinde her bir karar ağacı farklı veri kümeleri üzerinde eğitilerek ağaç çıktılarının bir araya getirilmesi ile nihai kestirim sağlanmaktadır. Bu topluluk yapısı ile modelin genelleme kabiliyeti üst seviyeye çıkarılırken, tek bir karar ağacına dayalı aşırı öğrenme riskinin üstesinden gelinmektedir. Ayrıca eğitim veri setindeki olası uç değerlerin, gürültülerin ve ölçüm belirsizliklerin model performansı üzerindeki etkisi sınırlandırılarak daha kararlı, güvenilir ve tutarlı kestirim sonuçlarının elde edilmesini mümkün kılmaktadır. RO algoritmasının temel işleyişinin kavramsal açıdan ortaya konulması, modelin veri setiyle kurduğu ilişkiyi ve kestirim sürecini daha net ve sistematik biçimde değerlendirebilmek açısından önem arz etmektedir. Karar verme mekanizmasının şematik olarak gösterilmesi ise yöntemin daha anlaşılır sunulmasına olanak tanımaktadır. Şekil 3.8.'de RO algoritmasının temel mimarisi gösterilmektedir.



Şekil 3.8. RO algoritmasının temel mimarisi

Karar ağaçları temelde veri setini sınıflandırmak ve kategorize etmek maksadıyla kullanılmaktadır. Karar ağacı ile veriler daha sade veri setlerine ayrılır ve sonrasında çıktılar üretilir. Farklı karar ağaçlarından en yüksek oyu alan çıktı seçilir ve kullanılır. Karar ağacı üç temel bileşenden oluşmaktadır;

- Kök düğüm: Veri setini farklı karar düğümlerine ayırır.
- Karar düğümleri: Verileri çeşitli koşullarla dallara ayırır.
- Yaprak düğümler: Nihai veri noktasını içerir.

Karar ağaçlarının temel yapısında bulunan hiyerarşik ayırım mekanizması, veriler arasındaki karışık ilişkilerin test edilerek modellenmesine olanak tanımaktadır. Özellikle karar kurallarının açık ve izlenebilir olması model sonuçlarının analiz edilmesi ve değişken etkilerinin algılanabilmesini kolaylaştırmaktadır. Bununla birlikte tek bir karar ağacı kullanımı ile aşırı öğrenme riski ile karşı karşıya kalınabildiğinden topluluk tabanlı yaklaşımların kullanılması daha kararlı sonuçlara ulaşılmasını sağlamaktadır. Karar ağaçları koleksiyonu RO algoritmasını oluşturmaktadır. Bu ağaçların her birinde bir veriye ait sınıf tahmini gerçekleştirilir. Maksimum tekrar eden çıktı nihai çıktı verisi olarak seçilir (Tirth, 2018). RO, yaklaşımlarında birbirinden bağımsız θ_K vektörü k sayıda ağaç için rastgele üretilir. Aynı dağılımdaki eğitim verisi ve θ_K vasıtasıyla bir ağaç oluşturulur. Eğitimdeki örneklem sayısı N ve rastgele vektörler ise N adet kutuya yerleştirilir. θ , 1 ve K arasında split seçimi ile rastgele integer bir sayı belirlenir. Sonrasında ise en iyi K splitlerden rastgele seçilir. θ 'nın kullanıma bağlı olarak boyutu

ve yapısı belirlenir. Çok sayıda ağaç üretimi sonrası en popüler sınıf oylanır. RO' nun temel formülü Eşitlik (3.5)'te verilmiştir.

$$\{h(x, \theta_k) | k = 1, \dots\} \quad (3.5)$$

Burada;

θ_k = Rastgele vektör,

x = Girdi verisidir (Akar vd., 2010).

RO, hem topluluk stratejilerini hem de rastgele örnekleme kullanmasıyla daha uyumlu genelleme ve başarılı tahminler sağlamaktadır. Bu genelleme yeteneği, varyansı düşürerek genellemeyi iyileştiren torbalama metodundan gelirken, yükseltme gibi farklı metotlar önyargıyı düşürerek bunu başarmaktadır (Yang, 2010). RO tekniğinde en çok kullanılan ilk önem ölçüsü Gini önemi'dir. Ağaç, öğrenme sürecinde Gini indeksi olarak nitelendirilen metodu kullanarak hangi özneliliğin bölüneceğini tespit etmektedir. Gini indeksi, bir düğümdeki örneklerin ana düğümdeki bir bölünmeyi esas alarak safsızlık seviyesini belirler (Aydın, 2022). Gini indeksine ait formül Eşitlik (3.6)'da verilmiştir.

$$Gini_{(t)} = 1 - \sum_j [p(j/t)]^2 \quad (3.6)$$

Burada;

j = Sınıfı,

t = Düğümü,

$p(j|t)$ = Göreli olasılığı ifade etmektedir (Koyuncu ve Ekmekcioğlu, 2024).

3.6.2. Yapay sinir ağları (YSA)

YSA, insan beynindeki nörolojik işlem mekanizmalarını matematiksel algoritmalar ile simüle eden bir makine öğrenme tekniğidir. YSA, veri setindeki kuralların, desenlerin ve bağlantıların ortaya çıkarılması noktasında kullanılan etkili bir tekniktir. Bu teknik, doğrusal olmayan ilişkilerin enterpolasyonu ile birden çok parametrenin kestirimini gerektiren ve temel teorik yaklaşımlar ile uyumsuzluk gösteren problemlerin çözümünde başarılıdır. (Huiqun ve Ling, 2008). YSA mimarilerinin temelleri insanların nörobiyoloji bilimine duydukları ilgi ile atılırken öğrenilen bilgilerin


sayısal ortama aktarılması yönündeki uygulamalar ile başlamıştır. 1970 yılı YSA'nın dönüm noktası olarak nitelendirilmektedir. Bu dönemde, daha önce çözülmesi mümkün görülmeyen pek çok problem başarıyla ele alınmış ve önemli yeniliklerin temelleri atılmıştır. Bu gelişmeler doğrultusunda, YSA'nın tarihsel süreci genellikle 1970 yılı öncesi ve sonrası olmak üzere iki ana dönem altında incelenmektedir. Her iki dönemde öne çıkan kuramsal ve uygulamaya yönelik gelişmeler kronolojik olarak sınıflandırılarak Tablo 3.4.'te sunulmuştur.

Tablo 3.4. YSA mimarilerinin tarihsel özeti (Öztemel, 2003)

1970 YILI ÖNCESİ		1970 YILI SONRASI	
1949	Biyolojik açıdan gerçekleştirilebilen öğrenme sürecinin bilgisayarlar ile yapılabilecek şekilde geliştirilmesi	1969-1974	- Lineer ilişkilerin kurulması - Korelasyon matriks kapasitesinin geliştirilmesi - Geriye yayılım modeli
1956-1962	- Widrow mimarisinin geliştirilmesi - Adaline mimarisinin geliştirilmesi	1978-1982	- Öğretmensiz öğrenmenin geliştirilmesi - Çok katmanlı algılayıcının geliştirilmesi
1957-1952	Tek katmanlı algılayıcı	1984	Boltzman mimarisi
1965	İlk makine öğrenme kitabı	1985	Delta öğrenme kuramı
1967-1969	Çeşitli gelişmiş öğrenme mimarileri	1988	Rbf, Pnn modellerinin geliştirilmesi
1969	- Tek katmanlı algılayıcıların yetersizliğinin ortaya konması - Darpa desteğinin durdurulması	1991	- Grnn modelinin geliştirilmesi 1991 yılından günümüze kadar geçen süreçte sayısız uygulama geliştirilmiştir

YSA mimarilerinin tarihçesi ele alındığında 1970 yılından sonraki süreçte gelişmelerin hızla gerçekleştiği görülmektedir. 1991 yılından günümüze kadar geçen süreçte sinir ağlarına yönelik sayısız araştırma gerçekleştirilmiştir. Bu gelişmelerin tamamını tabloda aktarmak mümkün olmadığı için kritik öneme sahip gelişmeler kategorize edilerek sunulmuştur. YSA mimarileri temelde nöronlar olarak da nitelendirilmektedir. Burada her nöron bir sinapsı ifade etmekte olup her gizli birim kontrol sağlayan aktivasyon fonksiyonlarından meydana gelir. YSA mimarisinde birden fazla nöron devreye alındığında doğrusal olmayan ilişkiler test edilebilir (Maltarollo vd., 2013). YSA'lar biyolojik sinir sisteminin temel çalışma prensipleri esas alınarak

geliştirilen matematiksel modellerdir. Yapay nöronların yapısı ve işleyişi ile insan beynindeki biyolojik nöronlar arasında fonksiyonel benzerlikler bulunmaktadır. Bu benzerlik durumu, girdi sinyallerinin ağırlıklandırılması, toplam sinyalin işlenerek bir aktivasyon fonksiyonu ile çıktı üretilmesi gibi süreçlerde açıkça gözlenmektedir. YSA ve biyolojik sinir hücresi arasındaki karşılaştırma Şekil 3.9.'da gösterilmektedir.



Şekil 3.9. YSA ve biyolojik sinir hücresi (Maltarollo vd., 2013)

Burada; (A) insan nöronunu, (B) yapay nöron ya da gizli birliğini, (C) biyolojik sinapsı ve (D) YSA sinapslarını temsil etmektedir. Şekilde sunulan bu karşılaştırma, biyolojik sinir hücresi ile YSA arasındaki yapısal ve işlevsel benzerliklerin daha net bir şekilde anlaşılmasına imkân sunmaktadır. Özetlemek gerekirse, YSA'nın temel unsurlarının insan nöronu yapısı ile karşılaştırması Tablo 3.5.'te sunulmuştur.


Tablo 3.5. YSA ve insan nöronu yapısının karşılaştırılması (Çakır, 2018)

YSA	İnsan Nöronu
Sinir hesaplama sistemi	Sinir sistemi
Düğüm (sinir, işlem elemanı)	Sinaps
Sinirler arası bağlantılı ağırlıklar	Dentrit
Toplama işlevi	Hücre gövdesi
Sinir çıkışı	Akson

YSA, günümüzde birçok farklı probleme çözüm sunabilecek kapasiteye sahiptir. Literatürde farklı şekillerde tanımlanmaktadır. Bu tanımların ortak özelliklerinin başında sinir ağlarının birbirlerine hiyerarşik bir yapıda bağlı olması ve paralel şekilde çalışan yapay hücrelerden ibaret olması gelmektedir. Yapay hücrelerin birbirlerine bağlantılı bir yapıda olduğu ve bu bağlantıların bir değere sahip olduğu varsayılmaktadır. Bilginin öğrenme sayesinde elde edildiği ve bağlantı değerlerinde tutulduğu dolayısıyla dağınık bir belleğin mevcut olduğu da bu tanımların ortak noktalarını oluşturmaktadır (Öztemel, 2003). YSA mimarisinde basit bir kümelenmeye sahip yapay nöronlar bulunmaktadır. Bu kümelenme tabakalar halinde gerçekleştirilir ve bu tabakalar diğer tabakalar ile ilişkilendirilir. Temelde bütün YSA mimarileri benzer yapıdadır. Bu yapılarda nöronların bir bölümü girdileri almak bir bölümü ise çıktıları iletmek maksadıyla dışarı ile ilişki halindedir. Bunların dışındaki tüm nöronlar yalnızca ağ içi bağlantılara sahip olduğundan gizli tabakada yer almaktadır. Uygulamaların bir bölümünde tek tabaka kullanan ağlar ile başarı sağlanabilirken çoğu uygulamada minimum üç tabaka (girdi-gizli-çıkıtı) bulunan ağlara gereksinim duyulmaktadır. Girdi katmanı, içerisindeki nöronlara herhangi bir işlem uygulamamakta yalnızca bir sonraki tabakaya değerleri aktarmaktadır. Bu yönüyle bazı araştırmalarda tabaka sayısı olarak nitelendirilmezler. Çıkıtı katmanında ise değerleri dışarı aktaran nöronlar bulunmaktadır. Her iki tabaka temelde tek tabakadan meydana gelirken aralarında çok sayıda gizli tabaka olabilmektedir. Gizli tabakada çok fazla nöron bulunmakta ve bunlar ağ içindeki diğer nöronlarla ilişkilidirler. YSA mimarilerinin çoğunda gizli tabakadaki nöronlar önceki katmanda bulunan bütün nöronlardan sinyal almakta çıktı verisini ise sonraki tabakaya iletmektedir. Bu durum ağ çıktısı için ileri beslemenin temelini oluşturur ve nöronlar arası iletişim sinir ağlarında çok önemli bir bölümdür (Anderson ve McNeill, 1992).

Yapay sinir ağları, nöroloji sisteminden esinlenerek geliştirilen ve çok katmanlı bir oluşum içerisinde bilgiyi işleyen hesaplama modelleridir. Veri setindeki karmaşık ve doğrusal olmayan bağıntıları çözümleyebilme kabiliyetleriyle birçok tahmin probleminde sıklıkla tercih edilmektedir. YSA modellerinde bilgi, katmanlar arasındaki çeşitli kurallar dahilinde iletilmekte ve her aşamada yeniden şekillendirilmektedir. Bu kapsamda, girdi verileri ağı iç yapısında işlenerek anlamlı bir çıktı verisine dönüştürülür. Katmanlar arasındaki bu sistematik işleyiş, modelin hem çözümleme hem de öğrenme ihtimaline olumlu yönde katkı sunmaktadır. YSA algoritmalarının performansı nöronlar arasındaki ilişkilerin ağırlıkları ya da tercih edilen aktivasyon fonksiyonlarına bağlı olarak değişmektedir. Modelin eğitim sürecinde tanımlanan optimizasyon kriterleri ile model

performansı geliştirilebilmektedir. Bu durum, geliştirilen modelin mevcut verileri temsil etmesine benzer şekilde farklı veri setlerine de genelleme yapabilecek bir mekanizmaya dönüşmesine olanak tanımaktadır Şekil 3.10.'da YSA algoritmasının temel mimarisi gösterilmektedir.



Şekil 3.10. YSA algoritmasının temel mimarisi

YSA, uydu görüntülerine ait bantların gri değerlerini, piksel parlaklık değerlerini ve yansıma verilerini modele giriş verisi olarak alırken su kalitesi değerlerini modelin çıktı verisi olarak kullanmaktadır. Temelde bant değerleri ile su kalitesi verileri arasındaki ilişkiyi basit bir matematiksel formül ile ifade etmek zordur. Sinir ağı karmaşık yapıları algılayan yapısı ile su kalitesi parametre konsantrasyonları gibi doğrusal olmayan ilişkilerin test edilmesinde oldukça başarılıdır. Ancak, sinir ağı modeli ile konsantrasyon tahmini için model eğitiminde kullanılacak çok sayıda veri noktasına ihtiyaç duyulmaktadır. Veri sayısının az olması model doğruluğunu ve öğrenme yeteneğini olumsuz yönde etkileyebilmektedir (Yang vd., 2022). YSA, son yıllarda birçok bilimsel araştırmada etkin bir şekilde kullanılmaktadır. Bu araştırmalar, sinir ağlarının uzaktan algılama veri setlerinin sınıflandırılması çalışmalarında etkili bir yöntem olduğunu göstermektedir. Bu durum, sinir ağlarının çeşitli avantajlarından kaynaklanmakta olup bu avantajlar aşağıda sıralanmaktadır;

- Belirli bir parametre setine dayanmaması,
- Klasik sınıflandırma yöntemlerine alternatif sunan öğrenme yeteneği,
- Olasılık modeline ilişkin herhangi bir varsayımda bulunmaması,
- Özellik uzayında karmaşık ve doğrusal olmayan karar sınırları oluşturabilme kapasitesi,
- Çeşitli veri türleri ve giriş formatlarına uyum gösterebilme yeteneği (Vieira, 1998).

YSA'nın uzaktan algılamada bir diğer avantajı ise görüntü sınıflandırmasında farklı arazi verilerinin entegrasyonuna olanak sağlamasıdır. Nitekim klasik metotlar sadece uydu verilerine uygulanabilirken sinir ağları yardımcı arazi verilerini de (eğim, yükseklik vb.) kullanabilmekte hem doğrusal hem de doğrusal olmayan ilişkileri tespit edebilmektedir (Arslan, 2001). YSA eğitimi öncesinde girdi verilerine çeşitli ön işlem adımları uygulanarak verilerin modele ve eğitime olan uyumu olumlu yönde geliştirilebilmektedir. Normalizasyon yöntemi, verilerin eğitime hazırlanmasında oldukça büyük etkiye sahiptir. Bu yöntem ile veri uyumu sağlanırken eğitim süresi ciddi oranda kısaltılabilmektedir. Normalizasyon işlemi temelde giriş verilerinin belirli bir değer aralığında ölçeklendirilmesi şeklinde gerçekleştirilir. Farklı ölçeklere sahip girdi verilerinin bulunduğu araştırmalarda normalizasyon yöntemi uygulanarak başarılı sonuçlar sağlanmaktadır. Sigmoid, z-skor, medyan ve min-maks literatürde sıklıkla kullanılan normalizasyon yöntemlerinin başında gelmektedir (Jayalakshmi ve Santhakumaran, 2011). Bu araştırmada normalizasyon yöntemlerinden min-maks normalizasyonu kullanılmıştır. Bu yöntemde veri seti 0-1 aralığına ölçeklenmekte olup matematiksel gösterimi Eşitlik (3.7)'de verilmiştir.

$$X^I = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (3.7)$$

Burada;

X^I = Normalizasyon uygulanmış veri,


X_i = Girdi değeri,

$X_{\max}$ = Girdi verisindeki en büyük değer,

$X_{\min}$ = Girdi verisindeki en küçük değerdir.

3.6.3. Evrişimli sinir ağıları (ESA)

ESA, ilk olarak LeCun (1989) tarafından görüntü tanıma araştırmaları için geliştirilmiştir. Görüntü analizi, obje ya da kişi tanıma, ses tanıma, hastalık tespit etme, doğal dil işleme gibi çeşitli alanlarda kullanılmaktadır. ESA mimarilerinin özellikle sınıflandırma ve görüntü tanıma çalışmalarında çok başarılı olduğu kanıtlanmıştır (Şafak ve Barışçı, 2018). ESA ile çok boyutlu veriler kolaylıkla işlenebilmekte hiperspektral uzaktan algılamada kullanılmasıyla büyük avantajlar sağlanabilmektedir. ESA, tam bağlantılı katmanlar, evrişim katmanları ve havuzlama katmanları olmak üzere temelde üç katmandan oluşmaktadır (Gündüz ve Orman, 2024). Şekil 3.11.'de ESA'nın temel mimarisi gösterilmektedir.



Şekil 3.11. ESA algoritmasının temel mimarisi

ESA mimarisinde evrişim ve havuzlama ilk aşamaları oluştururken, tam bağlı katman ve sınıflandırma katmanı ise son aşamalarda yer almaktadır. ESA, fazla sayıda eğitilebilir bölümden meydana gelir ve akabinde eğitici sınıflandırıcı ile devam eder. Girdi verileri alınarak katman bazında işlemler uygulanarak eğitim süreci tamamlanır. Son aşamada ise doğru sonuçlar ile kıyaslamak adına bir final çıktısı üretir. Talep edilen ile elde edilen sonuç arasındaki fark kadar hata meydana gelir. Geriye yayılım tekniği ile bu hata tüm ağırlıklara dağıtılarak her bir ardışık işlemle de ağırlıklar revize edilerek hatanın düşürülmesi sağlanır (Gürbüz ve Yılmaz, 2023). ESA'nın temel fikri, bir kedinin görsel korteksine dayanmaktadır. Bu görsel kortekste çeşitli cisimler farklı hücre bölümlerinin harekete geçirilmesini sağlamakta ya da farklı bir deyişle hücreler cisimlerin

şekil ve yön durumuna yönelik aktif olmaktadır. Katmanlı bağlantıya sahip hücreler sayesinde çeşitli katmanların görüntüdeki farklı alanları işlemesi fikri, kedilerin görsel korteksinden esinlenerek ESA'ya uyarlanmıştır. Bu fikir zamanla gelişerek ağırlık paylaşımı gibi önemli kavramların ortaya çıkmasına zemin hazırlamıştır. Günümüzde sonuçların daha iyileşmesine sebep olan değişiklik ise çok fazla katman kullanılmasıdır. Bu durum, hesaplama gücünün artması ve hafızayı düzenlemek ile optimize etmek için çeşitli tekniklerin geliştirilmesi sayesinde mümkün olmuştur. Bu sebeple daha derin mimariler geliştirilmektedir. ESA'yı diğer modellerden ayıran başlıca özellikleri arasında evrimsel katmanlar, ReLU (Doğrultulmuş Doğrusal Birim) aktivasyon fonksiyonu ve havuzlama katmanları bulunmaktadır. Evrimsel katmanlar, ızgara benzeri veri setlerinin özel bir metotla işlenmesini gerçekleştirerek bu veri setinin daha etkin analiz edilmesini mümkün kılar (Quandel, 2018). ESA mimarisi ile geliştirilen derin modellerin sağladığı çok fazla sayıda avantaj bulunmaktadır. Bu avantajlar aşağıda maddeler halinde sıralanmıştır;

- Arka plandan objenin ayrılması ya da bölütleme gibi ön işlem adımına gerek duymadan ileri seviye görevleri başarılı bir şekilde gerçekleştirmektedir.
- Geleneksel görüntü tanıma metotlarına kıyasla daha yüksek doğruluk sağlamaktadır.
- Kurulan mimariler tek bir obje özelliğine bağlı kalmaksızın bütün objelerin sınıflandırılmasında kullanılabilmektedir.

Bu avantajların yanı sıra eğitim ya da test aşamalarında oldukça güçlü donanımsal kaynaklar ve bir o kadar da bellek gücüne ihtiyaç duyulmaktadır. Günümüzde üretilen güçlü donanımlar sayesinde bu tür ihtiyaçlar çözülmektedir. ESA mimarilerinde katmanlar arasındaki hiyerarşik yapı ile aşamalı bir öğrenme süreci sağlanmaktadır. Bu durum, özellikle karmaşık örüntülerin daha net bir şekilde algılanarak modellenmesini mümkün kılar. Katmanların işlevsel özelliklerinin ayrı ayrı ele alınması, modelin temel çalışma prensibinin anlaşılması ve optimum mimarinin tasarlanması bakımından kritik öneme sahiptir. ESA mimarisi; girdi katmanı ile başlayan ve sırasıyla evrim, aktivasyon, havuzlama ve sınıflandırma katmanlarından oluşan beş temel yapıdan meydana gelmektedir. Bu bölümde, ESA mimarisinin temel bileşenlerini oluşturan katmanlar ayrıntılı bir biçimde ele alınmaktadır.

3.6.3.1. Girdi katmanı

Girdi (giriş) katmanı adından da anlaşılacağı üzere ESA mimarilerinin ilk katmanıdır. Bu ilk katmanda veriler ham bir şekilde ağa iletilmektedir. Model tasarımının başarılı olması noktasında bu katmanda kullanılacak veri setinin boyutu oldukça önemlidir. Girdi görüntüsü olarak kullanılan verinin yüksek boyutlu olması bellek gereksinimini artırmakta, eğitim ve test süreçlerini uzatmaktadır. Düşük boyutlu görüntü seçimi ile hem bellek ihtiyacı azaltılabilmekte hem de test süreleri kısaltılabilmektedir. Ancak, bu şekilde ağıın derinliği ve performansı düşebilmektedir. Bu sebeple ESA mimarilerinde uygun boyutlu girdi görüntüsünün seçilmesi ağıın performansını yükseltmek açısından oldukça önemlidir (İnik ve Ülker, 2017).

3.6.3.2. Evrişim katmanı

Evrişim katmanı, görüntü verisi üzerinde yerel örüntülerin belirlenmesini sağlayan ve modelin özellik çıkarma sürecinde önemli rol oynayan bir katmandır. Bu katman sayesinde giriş verisi doğrudan işlenmek yerine belirli bölgeler üzerinden analiz edilerek daha anlamlı temsil biçimlerine dönüştürülür. Böylece görüntüdeki mekânsal yapı korunur ve elde edilen özellikler bir sonraki katmanlara aktarılacak üzere düzenli bir şekilde işlenir. Girdi katmanından alınan görüntü verisi evrişim katmanına sevk edilmektedir. Evrişim katmanında farklı filtrelemeler gerçekleştirilerek görüntüdeki nesnelere ait çeşitli öznitelikler tespit edilmeye çalışılmakta ve uygulanan filtreler ağı performansına doğrudan etki etmektedir (Pang, 2018). ESA algoritmasının temeli olan bu katmanda dönüşüm işlemi filtrenin görüntünün tamamına uygulanması şeklinde gerçekleştirilir. Bu nedenle filtreler modelin olmazsa olmaz bileşenidir. 2x2, 3x3 ya da 5x5 gibi çeşitli boyutlarda geliştirilen filtreler önceki katmandan aktarılan görüntülere evrişim metodunu gerçekleştirerek çıkış verisini üretirler. Bu adım sonrasında her filtreye ait özelliklerin bulunduğu aktivasyon haritası oluşmaktadır. Model eğitimi sırasında filtreler için katsayılar, eğitim bölümündeki her öğrenme tekrarıyla değişmektedir. Bu şekilde özelliklerin tayini için hangi bölgenin mühim olduğu tespit edilir (İnik ve Ülker, 2017). Evrişim, en temel anlamıyla birden fazla girdinin iki fonksiyon ile tek bir çıktıya dönüştürülmesi işlemidir. Matematiksel olarak ifade etmek gerekirse, t zaman noktasında, x girdisinin düzenlenmiş bir kestirimini veren s fonksiyonu Eşitlik (3.8)'de verilmiştir.

$$s(t) = (x * w)(t) \quad (3.8)$$

Burada;

x = Girdi verisi,

w = Çekirdek,

t = Zaman,

$s(t)$ = Fonksiyondur (Goodfellow vd., 2016).

Bir evrişimsel katmana q 'nuncu katman için girdi uzayının boyutu $n_q \times n_q \times d_q$ şeklinde tanımlanabilir. Filtre şeklinde de tanımlanan aynı katmandaki çekirdek (kernel) daima girdi uzayı ile aynı d_q derinliğine sahiptir. Giriş bölümünün genişliği ve yüksekliği genelde aynıdır. Bu sebeple uzamsal giriş bölümü olarak da nitelendirilen giriş alanı bir karedir. Bu durum, $F_q \times F_q \times d_q$ şeklinde tanımlanabildiği çekirdek için de geçerlidir (Aggarwal, 2018). Çekirdek, girdi uzayında olası tüm konumlara uygulanır. Dolayısıyla, olası konumların sayısı ile bir sonraki gizli katman olan çıktı alanının genişliği ve yüksekliği tanımlanmakta olup matematiksel ifadesi Eşitlik (3.9)'da verilmiştir.

$$n_{q+1} = n_q - F_q + 1 \quad (3.9)$$

Burada;


n_q = q 'nuncu evrişimsel katmana ait giriş uzayının uzamsal boyutu,

n_{q+1} = Bir sonraki evrişimsel katmanda oluşan çıktı uzayının uzamsal boyutu,

F_q = q 'nuncu evrişimsel katmanda kullanılan çekirdeğin uzamsal boyutudur.

3.6.3.3. Aktivasyon katmanı

ESA mimarilerinin önemli parçalarından bir tanesi aktivasyon fonksiyonudur. Bu katmanda doğrusal olmayan bir aktivasyon fonksiyonu ile eksik ifade sorununa çözüm üretilerek hesaplanan özellikler eşlenir (Lin ve Shen, 2018). Evrişim katmanından sonra gelen bu katmanda bulunan nöron çıktı verilerinin sonraki katmana aktarılıp aktarılmamasına karar verilmektedir. Evrişim işlemi sonrasında elde edilen özniteliklerin doğrusal olmayan dönüşümlerden geçirilmesi modelin özellikleri daha etkin bir şekilde temsil edebilmesi açısından kritik bir aşamadır. Şekil 3.12.'de yaygın olarak kullanılan aktivasyon fonksiyonları gösterilmektedir.



Şekil 3.12. Aktivasyon fonksiyonları (Seth vd., 2022)

Modele en uygun aktivasyon fonksiyonunun seçimi, ağın doğrusal olmayan ilişkileri temsil edebilmesi ve daha yüksek tahmin doğruluğu elde edilmesi açısından önemli bir rol oynamaktadır. Derin öğrenme tekniklerinde en çok kullanılan aktivasyon fonksiyonu ReLU'dur. ReLU, piksel bazında uygulanan öge bilge işlemidir. Özellik haritasında bulunan bütün negatif pikselleri sıfır ile değiştirir. Bu işlemin amacı ESA mimarisinde doğrusal olmayan verileri tanımlamaktır. ESA mimarisi ile işlenmesi istenen verilerin çoğunluğu doğrusal olmayan veriler olmasına karşın evrişim temelde doğrusal bir yöntemdir. Bu sebeple, doğrusal olmayan ReLU fonksiyonu gibi bir fonksiyon kullanılarak doğrusallık sağlanmaktadır (Srivastava vd., 2015). ReLU aktivasyon fonksiyonuna yönelik matematiksel ifade Eşitlik (3.10)'da verilmiştir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.10)$$


Burada;

$f(x)$ = Aktivasyon fonksiyonunun çıktısı,


x = Nörona giren net girdi değeridir.

3.6.3.4. Havuzlama katmanı

Bu katmanda evrişim katmanından gelen matrise yönelik gerçekleştirilen genişlik ve yükseklik azaltma gibi çeşitli işlemler ile matematiksel karmaşıklık giderilmektedir. Havuzlama katmanında seçilen bir bölümdeki değerler için ortalama alarak ya da maksimumu hesaplanarak bir değer üretilir. Girdi için havuzlama yöntemi kayan pencere tekniği ile gerçekleştirilmektedir. Bu pencere her defasında seçilen havuzlama metoduna göre isabet ettiği girdi bölümünden bir değer üretir ve bu değeri çıktı katmanına ilave eder (Dumolin ve Visin, 2016). Havuzlama işlemi ile evrişim katmanlarından elde edilen verilerin boyutu küçültülerek hesaplama maliyeti azaltılmakta ve modelin genelleme kabiliyeti artırılmaktadır. Ayrıca konumsal ölçekte küçük değişimlere karşı duyarsızlık sağlanarak öğrenilen özelliklerin daha tutarlı bir şekilde temsil edilmesi sağlanmaktadır. Bu durum, aşırı öğrenme eğilimini sınırlandırarak daha az sayıdaki parametre ile daha etkili bir öğrenme sürecinin gerçekleştirilebilmesine imkân tanımaktadır. Ortalama ve maksimum havuzlama teknikleri modelin öğrenme davranışı üzerinde doğrudan etkiye sahiptir. Şekil 3.13.'te ortalama havuzlama, Şekil 3.14.'te ise maksimum havuzlama tekniğinin çalışma prensibi gösterilmektedir.



Şekil 3.13. Ortalama havuzlama tekniği



Şekil 3.14. Maksimum havuzlama tekniği

Havuzlama teknikleri, öznitelik haritalarının boyutunu azaltarak hesaplama yükünü düşüren, modelin daha kararlı bir yapı kazanmasına katkı sağlayan ve aşırı öğrenme riskinin azaltılmasında etkin rol oynayan temel bir ağ bileşenidir. Her iki havuzlama tekniğinde de girdi verileri bölümlere ayrılmaktadır. Her bir bölümdeki verilerin ortalaması ile ortalama havuzlama tekniği gerçekleştirilebilirken en yüksek değer ataması ile maksimum havuzlama tekniği uygulanır. Tüm havuzlama teknikleri için kullanılan matematiksel ifade Eşitlik (3.11)'de verilmiştir.

$$o = \left(\frac{i-k}{s} \right) + 1 \quad (3.11)$$

Burada;

o = Çıktı boyutu,

i = Girdi boyutu,

k = Pencere boyutu,

s = Adım sayısıdır (Dumolin ve Visin, 2016).

Havuzlama işlemi, öznitelik boyutunu düşüren, modelin daha kararlı hale gelmesine katkıda bulunan ve aşırı öğrenme riskini azaltan önemli bir yapı taşıdır. Haritaların boyutunu azaltarak hesaplama maliyetinin düşürülmesine ve modelin daha kararlı hale gelmesine katkı sağlamaktadır. Bu aşamada uzamsal çözünürlüğün kontrollü bir şekilde azaltılması, ağın gürültüye karşı daha dayanıklı olması ve yerel değişimlerden daha az etkilenmesini mümkün kılmaktadır. Ayrıca havuzlama katmanları, ağın öğrenme sürecinde daha ayırt edici özniteliklere odaklanılmasını sağlayarak aşırı öğrenme riskinin azaltılmasına yardımcı olmaktadır. Bu yönüyle havuzlama mekanizması, modelin genelleme kabiliyetini artıran önemli bir yapı taşı olarak değerlendirilmektedir.

3.6.3.5. Sınıflandırma katmanı

ESA mimarilerinin son katmanında, model ile öğrenilen öznitelikler kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Bu katmanda, literatürde en yaygın kullanılan aktivasyon fonksiyonlarından biri Softmax fonksiyonudur. Bunun nedeni ise fonksiyonun veri sınıfları için olasılık değeri belirlemesidir. Softmax ile girdi değerleri 0-1 aralığına indirgenir ve değerlerin toplamı 1 olacak biçimde bölme gerçekleştirilir. Elde edilen değerlerle hangi sınıfa yakınlık bulunduğu ölçülür. Bu katmanda çıkış verisi, sınıflandırılacak nesne sayısına eşittir (Kırcalı, 2022).


Çalışmanın dördüncü bölümünde araştırma kapsamında kullanılan tüm materyal ve yöntemler ele alınmıştır. Bu kapsamda çalışma alanı, kullanılan veri setleri ve izlenen yöntemsel yaklaşım ayrıntılı biçimde aktararak saha ölçümleri ile uydu verileri birlikte değerlendirilmiş, su kalitesi parametrelerinin kestirimi için kullanılan analiz adımları sistematik bir yapı içerisinde sunulmuştur.

4. MATERYAL VE YÖNTEM

Bu bölümde, çalışmada kullanılan veri kaynakları, uygulanan yöntemler ve analiz süreçleri ayrıntılı olarak açıklanmaktadır. İlk olarak çalışma alanının genel özellikleri tanıtılarak modellemede kullanılan uydu görüntüleri ve su kalitesi ölçüm verilerine ilişkin bilgiler sunulmuştur. Akabinde, uydu verilerinden temin edilen spektral indeksler ele alınarak model çıktılarının analiz edilmesi amacıyla kullanılan doğruluk metrikleri açıklanmıştır. Ayrıca su kalitesi üzerindeki olası etkileri dikkate alınarak meteorolojik etkenlere değinilmiş ve çalışmada kullanılan yazılımlar tanıtılmıştır. Son olarak, uygulanan yöntemin genel işleyişi akış diyagramı aracılığıyla özetlenerek yöntemsel çerçeve sistematik bir şekilde sunulmuştur.


4.1. Çalışma Alanı

Bu çalışma, Ankara'nın güneyinde yer alan Gölbaşı ilçesi sınırları içerisinde bulunan Mogan Gölü'nde (39°47' N, 32°47' E) gerçekleştirilmiştir. Mogan Gölü, 3 m ortalama derinliği ve 4 m'ye ulaşan maksimum derinliği ile sığ karakterli bir tatlı su ekosistemi niteliği taşımaktadır. Deniz seviyesinden yaklaşık 973 metre yükseklikte konumlanan göl, jeomorfolojik ve hidrodinamik süreçlerin etkisiyle zaman içerisinde çeşitli morfolojik değişimlere uğramış ve günümüzdeki şeklini almıştır. (ÇŞİDB, 2015). Mogan Gölü, kapalı havza formu taşıması ve su yenileme kapasitesinin sınırlı olması sebebiyle çevresel tehditlere karşı oldukça hassas bir yapı sergilemektedir. Göl ortalama derinliğinin düşük olması, özellikle optik olarak aktif parametrelerin uzaktan algılama verileriyle analiz edilebilirliğini artırmaktadır. Ayrıca uydu tabanlı kestirim modellerinde yüzey yansıtım verilerinin göl genelini temsil edebilecek nitelikte olmasını sağlamaktadır. Bu özellikleriyle Mogan Gölü, uzaktan algılama ve derin öğrenme tabanlı yöntemlerin uygulanabilirliğini ve küçük, sığ göllerde su kalitesi parametrelerinin mekânsal dağılımını analiz etmek açısından temsil gücü yüksek bir çalışma alanı sunmaktadır. Uygulama alanının yapısal özellikleri uzaktan algılama tabanlı su kalitesi analiz sonuçlarını ve model performanslarını doğrudan etkilemektedir. Tüm bu hususlar bilikte değerlendirilerek sunduğu bilimsel ve yöntemsel avantajların yanı sıra çevresel açıdan taşıdığı yüksek önem de dikkate alınarak Mogan Gölü uygulama alanı olarak tercih edilmiştir. Şekil 4.1.'de çalışma alanı haritası gösterilmektedir.



Şekil 4.1. Çalışma alanı haritası

Mogan Gölü'nü besleyen akarsuların büyük bölümü güney ve batı yönlerinden göle ulaşmakta olup oluşturduğu vadi tabanları gölün ekolojik sürdürülebilirliği açısından kritik öneme sahiptir. Sınırlı su hacmi nedeniyle dere yataklarına yönelik olası olumsuz müdahaleler, su miktarında azalma ve su kalitesinde bozulma riskini artırmaktadır. Şekil 4.2.'de Gölbaşı bölgesine ait su toplama havza sınırları gösterilmektedir.




Şekil 4.2. Gölbaşı bölgesi su toplama havza sınırları (ÇŞİDB, 2015)

Mogan Gölü'nün güney bölümünde ortalama 750 hektar büyüklüğünde sazlık ve bataklıklardan oluşan Çökek Bataklığı bulunmaktadır. Çökek Bataklığı, bölgedeki çeşitli büyüklüklere sahip dereler tarafından beslenmekte olup, bu derelerin taşıdığı sular yaz aylarında yeraltı suyu, ilkbahar döneminde ise yüzey akışı şeklinde Mogan Gölü'ne ulaşmaktadır. Bataklığın gölle birleştiği alanda, yoğun sazlık ve kamış örtüsü yer almaktadır. Mogan, Eymir ve İncesu Deresi boyunca uzanan çukurluk vadisi, tektonik kökenli çökme olayları ile oluşmuş olup, başlangıçta bir akarsu vadisi niteliğindeki


zamanla derelerin taşıdığı alüvyol materyallerin Mogan çukurluğunun önünü doldurmasıyla birlikte Mogan Gölü oluşmuştur.

Mogan Gölü, 90/1117 sayılı Bakanlar Kurulu Kararı ile ilan edilen GÖÇKB içerisinde yer almaktadır. Ankara ili, Gölbaşı ilçesi sınırlarında yer alan, Mogan ve Eymir göllerini kapsayan 273.94 km²'lik bu alan yasal koruma statüsü kazanmıştır. Ayrıca Bakanlık tarafından GÖÇKB 1/25.000 ölçekli Çevre Düzeni Planına (ÇDP) hassas bölgeler olarak işlenmiştir. Şekil 4.3.'te GÖÇKB sınırları gösterilmektedir.




Şekil 4.3. GÖÇKB sınırları (ÇŞİDB, 2015)

GÖÇKB sınırları dahilinde iki farklı doğal sit alanı bulunmaktadır. Çökek Bataklığı, Türkiye'nin uluslararası çapta öneme sahip biyolojik çeşitliliği ile ön plana çıkan ve Mogan, Eymir göllerini besleyen su kaynaklarına sahip olması sebebiyle I. Derece Doğal Sit Alanı olarak tescil görmüştür. Diğer I. ve II. derecede sit alanları ise Eymir Gölü çevresinde bulunmaktadır. Şekil 4.4.'te GÖÇKB sınırları içerisinde bulunan doğal sit alanları gösterilmektedir.



Şekil 4.4. GÖÇKB sınırları içerisinde bulunan doğal sit alanları (ÇŞİDB, 2015)

Mogan Gölü ve yakın çevresi, kentsel yerleşim alanlarının, rekreasyon bölgelerinin ve sazlık alanların bir arada bulunduğu mekânsal çeşitliliği yüksek seviyede olan bir alandır. Bu özelliklerine bağlı olarak ekolojik yapı, arazi kullanımı ve insan faaliyetleri açısından bütüncül bir yaklaşımla değerlendirilmesi gereken dikkat çekici bir alan niteliği taşımaktadır. Şekil 4.5.'te Mogan Gölü ve çevresinin farklı dönemlere ait görüntüleri sunulmaktadır.



Şekil 4.5. Mogan Gölü ve çevresinin farklı dönemlere ait görüntüleri (URL-1)


Mogan ve Eymir Gölleri ile çevresindeki sulak alanlar, çok sayıda hayvan ve bitki çeşidi için vazgeçilmez yaşam alanları sunmaktadır. Türkiye'nin önemli kuş alanları arasında yer alan bölgenin günümüze kadar 227 kuş türü tarafından barınma, üreme ve göç dönemlerinde konaklama maksadıyla kullanıldığı rapor edilmiştir. Söz konusu alan, bu özellikleriyle Ramsar kriterlerine aday gösterilen nitelikli sulak alanlar arasında değerlendirilmektedir. Türkiye'nin taraf olduğu Bern Sözleşmesi kapsamında kesinlikle korunması gereken türler olarak nitelendirilen; alaca balıkçıl, küçük balaban, küçük kerkenez ve dikkuyruk gibi türler bölgede yaşamlarını devam ettiren ve kesin suretle korunması gereken kuş türleri arasında yer almaktadır. Ayrıca nesli tehlike altında olan türler arasında; macar ördeği, elmabaş patka, pasbaş patka ve balaban bulunmakta olup

bu türlerin varlığı alanın ulusal ve uluslararası ölçekte önemini artırmaktadır. Mogan Gölü ve çevresinin bitki örtüsü de benzer şekilde dikkat çekici çeşitliliğe sahiptir. Alanda yayılış gösteren önemli bitki türleri arasında dikmen alıcı, gelincik, ölmez otu, badem, düğün çiçeği ve oldukça sınırlı sayıda bulunan yanardöner/peygamber çiçeği yer almaktadır. Bu endemik türün yer aldığı alanlar, mutlak koruma zonu kapsamında değerlendirilmekte ve ekolojik açıdan oldukça kritik öneme sahiptir (URL-1).

Sulak alanlar, biyolojik çeşitliliğe ve iklimsel dengeye katkı sunması yönüyle doğal çevrenin en temel bileşenleri arasında yer almaktadır. Bu alanların doğal ve antropojenik etkenler sebebiyle tehdit altında olması doğal yaşam koşullarının sürdürülebilirliğine sekte vurmaktadır. Hızlı ve kontrolsüz kentleşme, artan nüfus baskısı ve arazi kullanımındaki değişimler su kütleleri üzerindeki çevresel tehditleri artırmaktadır. Bu durum, su kütlelerinin düzenli olarak izlenmesi ve korunmasına yönelik bilimsel araştırmaların yürütülmesini kaçınılmaz kılmaktadır. Su kaynaklarının gelişen teknolojiye entegre bir şekilde uygun maliyetli, güvenilir ve stratejik yönetimi çevresel politikaların başarısı açısından oldukça önemlidir. Koruma ve izleme gereksiniminin ön plana çıktığı ve çevresel baskılara maruz kalan alanlardan biri de Mogan Gölü'dür. Ekosistemin önemli bir parçası olması nedeniyle Türkiye için stratejik öneme sahip olan Mogan Gölü ve çevresinin korunması ve düzenli olarak izlenmesi çok önemlidir. Koruma altındaki bir sulak alan olan Mogan Gölü, ekolojik çeşitliliği, endemik türleri ve ekosistem hizmetleriyle dikkat çekmektedir. Turizm ve yerel ekonomi için stratejik öneme sahip olan göl ve çevresi, plansız gelişme nedeniyle çevresel tehditlerle karşı karşıyadır. Türkiye'nin başkentinde yer alan gölün korunması, düzenli olarak izlenmesi ve yönetilmesi, diğer tüm sulak alanlar için bir model teşkil etme potansiyeline sahiptir (Karakoç ve Buğdaycı, 2025).

4.2. Su Kalitesi Ölçüm Verileri

Çalışmada kullanılmak üzere 2018-2024 yılları arasındaki klorofil-a, askıda katı madde ve secchi diski derinliği ölçüm sonuçları Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Tabiat Varlıklarını Koruma Genel Müdürlüğü (TVKGM)'den temin edilmiştir. Kullanılan su numuneleri, Su Kirliliği Kontrolü Yönetmeliği ve Türkiye'de yürürlükte olan Numune Alma ve Analiz Metotları Tebliği hükümlerine uygun olarak Bakanlık koordinasyonunda toplanmış, depolanmış ve analiz edilmiştir. Şekil 4.6.'da numune alınan noktaların Mogan Gölü üzerindeki lokasyonları gösterilmektedir.



Şekil 4.6. Su örnekleme lokasyonları

Örnekleme lokasyonları, gölün hidrodinamik yapısını ve morfolojik özelliklerini temsil edecek şekilde kuzey ucu, güney ucu ve göl ortası olmak üzere üç farklı konumu kapsamaktadır. Ölçüm faaliyetleri, su kalitesindeki mevsimsel değişimlerin izlenebilmesi amacıyla aylık periyotlar esas alınarak planlanmaktadır. Elde edilen ölçüm verileri, su kalitesi analizlerinde girdi olarak kullanabilecek nitelikte sistematik ve süreklilik arz eden bir veri yapısı sunmaktadır. Ancak başta meteorolojik etkenler olmak üzere (şiddetli yağış, don olayları, ulaşım engelleri vb.) çeşitli dinamiklere bağlı olarak ölçüm takviminde zorunlu esneklik yaratan dönemler bulunmaktadır. Bu doğrultuda, örnekleme

alıřmaları saha kořullarının uygun olduėu dnemler esas alınarak yrtlmektedir. lm noktaları ve rnekleme sayıları, Bakanlık tarafından yrtlen rutin izleme programı erevesinde kayıt altına alınarak her bir noktaya iliřkin bilgiler dzenli olarak rapor edilmektedir. rnekleme srecine ynelik meknsal ve sayısal bilgiler, deėerlendirme srelerinin ve izleme faaliyetlerinin řeffaflıėını saėlamak amacıyla derlenmiřtir. Tablo 4.1.'de numune alınan noktaların genel zellikleri sunulmaktadır.

Tablo 4.1. Numune alınan noktaların genel zellikleri

Nokta No	Lokasyon	Numune Sayısı (2018-2024)	Enlem	Boylam
GA1	Kuzey Ucu	41	39° 47' 29,36	32° 48' 0,42
GA2	Gney Ucu	41	39° 44' 44,32	32° 46' 44,51
GA3	Ortası	41	39° 45' 59,2	32° 47' 51,8

rnekleme alıřmaları, gl suyunun fiziksel, kimyasal ve biyolojik zelliklerini temsil edecek řekilde, alanın hidrodinamik yapısı ve evresel etkenler gz nnde bulundurularak gerekleřtirilmektedir. Numune alma iřlemleri sırasında, temsiliyetin saėlanması ynelik derinlik, coėrafi konum ve meteorolojik kořullar dikkate alınmaktadır. Su rneklerinin muhafaza edilmesi ve laboratuvara tařınması srecinde mevzuata uygun uygulamalar esas alınarak gerekli kořullar altında su numuneleri tařınmakta ve saklanmaktadır. Numune kapları, dıř kaynaklı kirlenme riskini azaltacak nitelikte seilerek rneklerin yapısını bozabilecek etkileřimlerin nne geilmesi amalanmaktadır. Laboratuvar analizleri ncesinde geen sreler ise, lm gvenilirliėini olumsuz etkilemeyecek biimde planlanarak numune zelliklerine uygun řekilde ynetilmektedir. Temin edilen lm verileri her bir su kalitesi parametresi iin veri seti oluřturmak zere dzenlenmiřtir. 2018-2024 yılları arasında 41 farklı tarihte  farklı lokasyondan yapılan lm sayıları her su kalitesi parametresi iin 123'tr.

4.3. Uydu Görüntüleri

Uzaktan algılama teknolojileri, yeryüzüne ilişkin güvenilir ve süreklilik arz eden mekânsal bilgilerin temin edilmesinde önemli bir rol üstlenmektedir. Günümüzde, farklı kullanım amaçlarına yönelik tasarlanmış, çeşitli teknolojik özelliklere ve çözünürlüklere sahip çok sayıda uydu sistemi bulunmaktadır. Teknolojinin hızla gelişmesiyle birlikte, yeryüzü ve coğrafi nesnelere ilişkin mekânsal bilgi edinme gereksinimi de her geçen gün artmaktadır. Bu bağlamda, uzaktan algılama teknolojisinin temel bileşenlerinden biri olan uydu sistemleri, ihtiyaç duyulan verilerin elde edilmesinde güvenilir, ekonomik ve pratik çözümler sunmaktadır. Yeryüzüne ait görüntüleri toplayan ve çeşitli algılayıcı sensörlerle donatılmış olan yapay uydular ise uzaktan algılama uyduları olarak adlandırılmaktadır. Bu uydular, sahip oldukları sensör özelliklerine dayalı olarak farklı dalga boylarında veri toplayabilmekte ve nesnelerin fiziksel, kimyasal ya da biyolojik özelliklerine ilişkin kapsamlı analizlerin yapılmasına imkân sunmaktadır.

ERTS-1 (Dünya Kaynakları Teknoloji Uydusu) uydusu, 23 Temmuz 1972 tarihinde NASA (Ulusal Havacılık ve Uzay Dairesi) tarafından yeryüzünün sürekli olarak algılanması maksadıyla, çok bantlı tarayıcı donanımı ile uzaya gönderilmiştir. 01 Ocak 1975 tarihinde ise adının Landsat-1 olarak revize edilmesi ile birlikte Landsat uyduları literatürde kendi isimleriyle yer bulmuştur. Landsat uyduları yarım yüzyıla dayanan geçmişi ve yüksek spektral çözünürlüklü verileri ile kullanıcılara geniş kapsamlı bir görüntü arşivi sunmakta ve uzaktan algılama teknolojisinde sıklıkla tercih edilmektedir. Landsat uydu serisinin ilk uydusu olan Landsat-1 uydusunun yörüngeye yerleşmesi akabinde teknolojik gelişmelere paralel olarak belirli periyotlarla yeni Landsat uyduları uzaya gönderilmiştir. Landsat-1 ile başlayan ve 29 Eylül 2021 tarihinde Landsat-9'un uzaya fırlatılması ile devam eden süreçte yörüngeye oturtulma konusunda başarısızlığa uğrayan tek uydu Landsat-6 uydusu olmuştur.

Landsat filosunun sekizinci üyesi olan Landsat-8, NASA tarafından 11 Şubat 2013 tarihinde uzaya fırlatılmıştır. Landsat programının en temel konusu olan canlıların yaşamsal faaliyetleri için gerekli tarım arazileri, su kaynakları ve ormanlar gibi unsurların tespiti ve izlenmesi gibi amaçlar Landsat-8 uydusu ile devam ettirilmiştir. Landsat-8 uydusu 24 saatlik zaman diliminde 400 görüntü alımı yapabilmekte olup, önceki Landsat uydularının maksimum 250 görüntü olan performansına kıyasla gelişme göstermiştir. Görüntü alımında meydana gelen bu gelişme Landsat-8 uydusunun bir bölgeyi izlemede daha esnek olmasından kaynaklanmaktadır (Ali vd., 2017). Landsat-8 uydusu uzak

sensörü sayesinde önceki Landsat uydularındaki doğrudan uçuş yollarının altındaki sınırlı bir bölgeyi izleme kısıtlamasından etkilenmemesi bakımından oldukça avantajlıdır. Nitekim, uçuş yolundan belirli bir sapma açısının olduğu durumda diğer Landsat uyduları bu bölgeyi diğer turlarda algılayabilirken, Landsat-8 uzak sensörü sayesinde arazi hakkında bilgi alınabilmektedir. Bu avantajlı durum çok zamanlı karşılaştırma için gereken görüntülerin alınmasına imkân sağlar. Landsat-8 uydusunun genel özellikleri Tablo 4.2.'de verilmiştir.

Tablo 4.2. Landsat-8 uydusunun genel özellikleri

Landsat-8 Özellikleri	Tanımlama
Uzaya Fırlatılış Tarihi	11 Şubat 2013
Operasyonel Durum	Aktif
Taşıyıcı Sensörler	OLI (Operasyonel Arazi Görüntüleyici) TIRS (Termal Kızılötesi Sensör)
Mekânsal Çözünürlük	15 m (Pankromatik) 30 m (Çok bantlı) 100 m (Termal)
Radyometrik Çözünürlük	12 bit
Spektral Bant Sayısı	11 bant (9 OLI + 2 TIRS)
Yörünge	Güneş Senkronize
Yörünge Döngüsü	16 gün
Şerit Genişliği	185 km

Landsat-8 uydusu spektral aralığa dayalı olarak 15 m - 100 m aralığında bir orta uzaysal çözünürlüğe sahip olup, VNIR (Görünür ve Yakın Kızılötesi), SWIR (Kısa Dalga Kızılötesi) ve TIR (Termal Kızılötesi) aralıklarında görüntü almaktadır. Landsat-8 uydusu, OLI (Operasyonel Arazi Görüntüleyici) ve TIRS (Termal Kızılötesi Sensör) olmak üzere iki algılayıcı taşımaktadır. OLI/TIRS bantları içerdiği iki yeni bant kombinasyonu ile önceki Landsat uydularının yeteneklerine büyük ölçüde gelişme sunmuştur (Roy vd., 2014). Bu bantlardan birincisi optik kalınlık, yansıma ve yoğunlaşma gibi aerosol özelliklerin tahmini ve kıyı gözlemleri ile okyanus renginin tespiti için 0,433-0,453 μm spektral aralığındaki koyu mavi renkteki bant 1'dir. Diğer ise yüksek seviyede su soğurma niteliği bulunan ve OLI görüntülerinde Sırrüs (saçak) bulutlarının kolay tespitine imkân sunan 1,360-1,390 μm spektral aralığındaki kısa dalga

kızılötesi bant olarak bilinen bant 9'dur (Lillesand vd., 2018). OLI sensörü, NASA'nın EO-1 uydusundaki ALI (Gelişmiş Arazi Görüntüleyici) sensörünün teknik açıdan geliştirilmesiyle elde edilmiştir. Whiskbroom sensör yerine kullandığı pushbroom sensörü ile daha az hareketli parça ve daha yüksek hassasiyetli veriler ile içerik açısından daha zengin yeryüzü özelliklerinin tespitine olanak sağlamıştır. OLI sensörü dokuz banttandır veri elde etmekte olup bu bantların yedisi Landsat-5 (TM) ve Landsat-7 (ETM) sensörlerindeki aralıklarına sahiptir. Önceki Landsat verileri ile uyumun sağlanması bu şekilde gerçekleştirilmiştir. TIRS sensörü, 60 m çözünürlüğe sahip termal bant taşıyan ETM+ sensörüne kıyasla 100 m çözünürlüğe sahip termal bant taşımaktadır. Düşürülmüş TIRS çözünürlüğü en ideal olmasa da iki adet termal TIRS bandı yeryüzü sıcaklığının, atmosferik düzeltmenin ve emisyonun daha güvenilir vaziyette elde edilmesine imkân sunar (Roy vd., 2014). TIRS, sinyal/gürültü radyometrik özelliği ile 12 bitlik görüntüler verebilmekte olup, radyometrik ve geometrik veri üretmek maksadıyla OLI sensör verilerine uyumlu bir şekilde çalışmaktadır. Landsat-8 görüntüleri iki termal ve dokuz spektral banttandır oluşmakta olup Tablo 4.3.'te spektral bant özellikleri sunulmaktadır.

Tablo 4.3. Landsat-8 spektral bant özellikleri (Lillesand vd., 2018)

Bant	Tanımlı Spektral Konum	Bant Aralığı (µm)	Mekânsal Çözünürlük (m)	Sensör	ETM+ Bandı/ Bant Genişliği (µm)
1	Kıyasal/Aerosol	0,433 – 0,453	30	OLI	ETM+ yok
2	Mavi	0,450 – 0,515	30	OLI	1 / 0,450-0,515
3	Yeşil	0,525 – 0,600	30	OLI	2 / 0,525-0,605
4	Kırmızı	0,630 – 0,680	30	OLI	3 / 0,630-0,690
5	Yakın Kızılötesi	0,845 – 0,885	30	OLI	4 / 0,775-0,900
6	Kısa Dalga Kızılötesi 1	1,560 – 1,660	30	OLI	5 / 1,550-1,750
7	Kısa Dalga Kızılötesi 2	2,100 – 2,300	30	OLI	7 / 2,090-2,350
8	Pankromatik	0,500 – 0,680	15	OLI	8 / 0,520-0,900
9	Sirrus	1,360 – 1,390	30	OLI	ETM+ yok
10	Termal Kızılötesi 1	10,60 – 11,20	100	TIRS	6 / 10,4-12,5
11	Termal Kızılötesi 2	11,50 – 12,50	100	TIRS	ETM+ yok

Bu çalışmada, Landsat-8 uydu görüntüleri ve su kalitesi ölçüm verileri kullanılarak makine ve derin öğrenme teknikleri entegrasyonu ile Mogan Gölü'ndeki su kalitesi parametreleri modellenmiştir. Çalışma kapsamında farklı uydu görüntüleri test edilerek modeller için en uygun sonuçlara ulaşılan Landsat-8 uydu görüntüleri tercih edilmiştir. Bununla birlikte, uydu görüntülerinin seçiminde sensör kalitesi ve veri sürekliliği gibi kriterler de göz önünde bulundurulmuştur. Böylelikle modelleme sürecinde daha güvenilir ve istikrarlı tahminlerin elde edilmesine katkı sağlanmıştır. Bu kapsamda, uzaktan algılama verileri ile yerinde ölçüm verilerinin entegre bir şekilde kullanılması, su kalitesi parametrelerinin daha güvenilir biçimde değerlendirilmesine olanak sağlamıştır. USGS (Amerika Birleşik Devletleri Jeolojik Araştırmalar Merkezi) üzerinden çalışma alanına yönelik 2018-2024 tarihleri arasındaki uydu görüntüleri filtrelenmiştir. ÇŞİDB'den temin edilen su kalitesi parametreleri sekiz farklı tarihteki Landsat-8 uydu görüntüleri ile eşleştirilmiştir. Su kalitesi parametrelerinin atmosferik koşullardan doğrudan etkilenmesi sebebiyle çalışma alanını kapsayan uydu görüntülerinin bulutsuz olmasına dikkat edilmiştir. Çalışma kapsamında kullanılan uydu görüntüleri Tablo 4.4.'te verilmiştir.

Tablo 4.4. Kullanılan uydu görüntüleri

TARİH	YOL /SATIR	BULUT ÖRTÜSÜ (%)	ID
[18.04.2018]	177/32	0,13	[LC08_L2SP_177032_20180418_20201015_02_T1]
[23.07.2018]	177/32	8,8	[LC08_L2SP_177032_20180723_20200831_02_T1]
[27.10.2018]	177/32	0,34	[LC08_L2SP_177032_20181027_20200830_02_T1]
[31.07.2021]	177/32	1,08	[LC08_L2SP_177032_20210731_20210804_02_T1]
[16.08.2021]	177/32	0,3	[LC08_L2SP_177032_20210816_20210826_02_T1]
[17.09.2021]	177/32	11,75	[LC08_L2SP_177032_20210917_20210925_02_T1]
[05.07.2023]	177/32	0,18	[LC08_L2SP_177032_20230705_20230717_02_T1]
[08.08.2024]	177/32	1,71	[LC08_L2SP_177032_20240808_20240814_02_T1]

Bu çalışmada, Landsat-8 uydusuna ait Koleksiyon-2 düzeyindeki uydu görüntüleri kullanılmıştır. Görüntüler, USGS tarafından gerçekleştirilen ön işleme adımlarıyla geometrik ve atmosferik düzeltmelere tabi tutulmuştur. Atmosferik düzeltmeler, su buharı, aerosoller ve ozon gibi atmosferik bileşenlerin etkilerini gidermek amacıyla LaSRC (Kara Yüzeyi Yansımaya Kodu) algoritması kullanılarak gerçekleştirilmiştir. Geometrik düzeltmeler ise DEM (Sayısal Yükseklik Modelleri) yardımıyla, L1TP (Düzy-1 Hassas Arazi Düzeltmeli Ürün) ürünleri temel alınarak uygulanmıştır. DN (Dijital Numara) değerleri yansımaya değerlerine dönüştürülmüş ve veri setinde kullanılabilir hale getirilmiştir. Kullanılan uydu görüntülerinin Bant 2, Bant 3, Bant 4 ve Bant 5 bantları için spektral yansımaya değerleri çıkarılmıştır. Landsat-8 uydu görüntülerinin düzenlenmesinde Erdas Imagine yazılımı kullanılmıştır.

4.4. Spektral İndeksler

Spektral indeksler, uzaktan algılama tabanlı araştırmalarda yeryüzü ve çevresine ait nicel ve nitel analizlerin gerçekleştirilmesinde kritik öneme sahiptir. Bu indeksler, elektromanyetik spektrumun belirli dalga boyu aralıklarındaki yansıtım farklarından yola çıkarak ve bu farklara dayalı matematiksel bir model geliştirilerek yüzeye ilişkin özelliklerin daha ayrıntılı ve hassas bir şekilde tanımlanmasına olanak sağlar. Bitki örtüsü analizi, su kütlesi izleme ya da kentsel alanların irdelenmesi başta olmak üzere birçok konuda belirleyici rol oynayan spektral indeksler ile çevresel problemlerin takibi, su kalitesi izleme ya da arazi örtülerinin detaylandırılması gibi çeşitli konularda oldukça önemli avantajlar sağlanmaktadır. Ham uydu verilerinin doğrudan analiz edilmesi noktasında yorumlama durumunun sınırlı olması ve atmosferik etkilerin görüntüler üzerindeki olumsuz etkileri spektral indekslerin kullanılmasının temel nedenlerindendir. Spektral indeksler, istatistiksel araştırmalar ya da görüntü işleme teknolojisi ile entegre bir şekilde kullanılarak mevcut sınırlamaların giderilmesine ve daha yüksek doğruluklu sonuçlar elde edilmesine imkân sunar. Tarım, çevresel izleme, afet yönetimi, ormancılık ya da su kaynaklarının yönetimi gibi çok geniş kullanım yelpazesine sahip olan spektral indeksler ile erken uyarı sistemleri geliştirilebilmekte ve sürdürülebilir izleme çalışmaları yürütülebilmektedir. Bu çalışmada, su kalitesi izleme araştırmalarında başarılı çözümler ürettiği literatürde kanıtlanmış olan NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi), NDWI (Normalize Edilmiş Fark Su İndeksi) ve MNDWI (Modifiye Edilmiş

Normalize Fark Su İndeksi) indeksleri model performanslarına olumlu etkileri sebebiyle kullanılmıştır.

Bitki örtüsü sıklığına sahip alanlarda yaygın bir şekilde kullanılan NDVI, vejetasyon ölçütünü analiz etmek amacıyla sıkça tercih edilen önemli bir spektral indekstir (Yıldız vd., 2012). Literatürde, NDVI değerleri ile su kütlelerindeki klorofil miktarı arasında anlamlı ilişkiler olduğu ifade edilmektedir (Akgün, 2023). NDVI, klorofil pigmentinin özellikle kırmızı dalga boylarında yüksek emilim, yakın kızılötesi (NIR) bantta güçlü yansıma üretmesi prensibine dayalı olarak geliştirilmiştir (Datt, 1998). Bu sebeple, klorofil-a kestiriminde sık olarak kullanılan indekslerden biridir. NDVI indeksinin hesaplanma formülü Eşitlik (4.1)'de verilmiştir.

$$NDVI = \frac{NIR - Kırmızı}{NIR + Kırmızı} \quad (4.1)$$

NDVI analizi ile temin edilen veriler, yeşil bitki örtüsü varlığına yönelik bilgi sağlamakta ve bitki yoğunluğunun düşük seviyede olduğu ya da bitkisiz bölümlerin tespitine imkân sunmaktadır. NDVI değerleri, teorikte $[-1, +1]$ aralığında değişmektedir. Değerlerin $+1$ 'e yaklaşması sağlıklı ve yoğun bitki örtüsüne, 0 'a yakın değerler vejetasyona sahip olmayan ya da sınırlı sahip olan alanlara işaret ederken negatif değerler mevcut alanların büyük olasılıkla bitkisiz olduğunu göstermektedir. Göl, nehir ve benzeri su kütleleri ile endüstriyel faaliyet alanları, yerleşim yerleri ve karayolları gibi insan faaliyetlerinin yoğun olduğu yerlerde NDVI seviyeleri genellikle düşüktür. Bu sebeple, NDVI ile sadece sağlıklı bitki örtüsüne sahip alanlar değil aynı zamanda çeşitli sebeplere bağlı olarak bitkiden yoksun alanlar da ayırt edilebilmektedir (Duran, 2007). Su kütlelerinin izlenmesi ve kara parçalarından ayrılması noktasında kullanılmak üzere NDWI ve MNDWI gibi çeşitli su indeksleri geliştirilmiştir. McFeeters (1996) ve Gao (1996) araştırmalarında yeşil bant ile yakın kızılötesi (NIR) bandını kullanarak su yüzeylerinin tespitinde kullanılmak üzere NDWI indeksini geliştirmiştir. NDWI indeksinin hesaplama formülü Eşitlik (4.2)'de verilmiştir.

$$NDWI = \frac{Yeşil - NIR}{Yeşil + NIR} \quad (4.2)$$

Xu (2006) ise McFeeters (1996)'nın geliştirdiği NDWI indeksinden yola çıkarak MNDWI indeksini geliştirmiştir. Bu sebeple, MNDWI su kütlelerinin tespiti için tasarlanan ve NDWI indeksinin özel bir uyarlaması olan indekstir. Uzaktan algılama teknikleriyle su kütlelerinin analizinde oldukça verimli bilgiler sağlamaktadır (Atasever ve Abbas, 2024). MNDWI indeksinin geliştirilmesindeki temel amaç, NDWI indeksinin kentsel su kütlelerine yönelik yetersiz kaldığı yönlerin giderilmesi ve daha yüksek doğruluğa sahip sonuçların elde edilmesidir. Xu (2006) tarafından yapılan araştırmanın sonuçları kentsel alanlardaki su kütlelerinin tespitinde MNDWI indeksinin NDWI indeksine kıyasla daha iyi performans gösterdiğini doğrulamaktadır. MNDWI indeksinde, su yüzeylerinin kısa dalga kızılötesi (SWIR) bantta düşük yansıtma özelliği göstermesi nedeniyle, NIR bandı yerine SWIR bandı kullanılmaktadır. MNDWI, su kütleleri ile diğer alanların birbirinden ayrt edilmesini kolaylaştırarak daha hassas haritalandırılmasına imkân sunmaktadır. MNDWI indeksinin hesaplama formülü Eşitlik (4.3)'te verilmiştir.

$$\text{MNDWI} = \frac{\text{Yeşil} - \text{SWIR}}{\text{Yeşil} + \text{SWIR}} \quad (4.3)$$

Su kütlelerinde meydana gelen değişikliklerin izlenmesinde kullanılan MNDWI indeksi değerleri $[-1, +1]$ aralığında değişmektedir. MNDWI indeks değerleri temelde iki sınıf olarak tanımlanmakta olup -1 ile 0 aralığındaki değerler su varlığına işaret ederken, 0 ile $+1$ aralığındaki değerler ise su içermeyen alanları (toprak, bitki vb.) göstermektedir. Bu çalışmada kapsamında hesaplanan NDVI, NDWI ve MNDWI spektral indeksleri, Mogan Gölü'ndeki su kalitesi konsantrasyonlarının uzaktan algılama tabanlı kestirilmesinde yardımcı değişkenler olarak kullanılmıştır. Spektral indeksler, Landsat-8 uydu görüntülerinden türetilerek, su kalitesi parametrelerinin kestirim modellerinde giriş değişkenleri arasına dahil edilmiştir. İndekslerin seçiminde literatür odaklı yaklaşım sergilenirken su kalitesi parametreleri ile olan ilişkişisel durumu, model performanslarına sağlayacağı olumlu yöndeki katkıları göz önünde bulundurulmuştur.

4.5. Doğruluk Analizi

Bu çalışmada, R^2 (Belirleme Katsayısı), RMSE (Kök Ortalama Kare Hatası) ve MAE (Ortalama Mutlak Hata) metrikleri modellerin doğruluklarını değerlendirmek için

kullanılmıştır. Bu metrikler, makine ve derin öğrenme modellerinin performans analizlerinde kullanılan temel ölçütler arasında yer almaktadır. Uzaktan algılama tabanlı su kalitesi izleme araştırmalarında tahmin doğruluklarının analizinde sıklıkla tercih edilmektedir (Devi ve Mamatha, 2024; Zhang vd., 2022; Ali vd., 2024).

R^2 , modelin tahmin yapma kabiliyetini göstermektedir. Tahmin değerlerinin gerçek değerlere yaklaşması ile R^2 değeri 1'e yaklaşmakta ve bu durum modelin daha güçlü tahmin performansına sahip olduğunu göstermektedir. Bir başka deyişle, bağımlı değişkenlerdeki varyansın bağımsız değişkenler tarafından açıklanabilme oranıdır. R^2 , modelin uyum derecesini gösteren, tahmin ve gerçek değerlerin ne derece eşleştiğini yansıtan önemli bir parametredir.

RMSE, tahmin değerleri ile gerçek değerler arasındaki farkı yansıtmakta ve hataların standart sapması olarak tanımlanmaktadır. Daha düşük bir RMSE, modelin daha yüksek tahmin doğruluğuna sahip olduğunu işaret etmektedir. Ayrıca en iyi uyum çizgisine mevcut nokta kümesinin ne ölçüde yakın olduğunu göstermektedir.

MAE, bir tahmin serisindeki hataların ortalama seviyesini, yönlerine bakmaksızın değerlendiren bir ölçüttür. MAE, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını temsil eder ve hata büyüklüğünü gösterir (Peng vd., 2023). Çalışmadaki modellerin doğruluk değerlendirmesinde kullanılan bu metriklerin matematiksel formülleri Eşitlik (4.4), Eşitlik (4.5) ve Eşitlik (4.6)'da verilmiştir (Chicco vd., 2021).

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (4.4)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \quad (4.5)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (4.6)$$

Burada;

X_i = Tahmin değeri,

Y_i = Gerçek değer,

m = Örnek sayısı,


$\bar{Y}$ = Gerçek değerlerin ortalamasıdır.

Bu çalışmada model doğruluklarının değerlendirilmesi için R^2 , RMSE ve MAE metriklerinin birlikte tercih edilmesinin temel sebebi, su kalitesine yönelik uzaktan algılama araştırmalarında bu metriklerin hem istatistiksel hem de çevresel yorumlama yönüyle tamamlayıcı bir çerçeve sunmasıdır.


4.6. Meteorolojik Etkenler

Çalışma tarihleri için yapılacak değerlendirmelerde bölgesel ölçekli etkenlerin yanı sıra yağış, sıcaklık, rüzgâr ve taşınım yoluyla dahil olabilecek kaynaklar da ele alınmıştır. Ölçüm tarihlerindeki meteorolojik etkenlerin değerlendirilmesi Mogan Gölü'nde gözlenen anomalileri analiz etmek üzere önemli bir perspektif sunmaktadır. Bu kapsamda, çalışma tarihleri için meteorolojik veriler birlikte değerlendirilerek kısa süreli yağış durumları, rüzgâr yönü ve hızı ile sıcaklık değişimlerinin su kütlesi üzerindeki olası etkileri dikkate alınmıştır. Bu yaklaşım sayesinde gözlenen olası anomalilerin sadece uzaktan algılama veri setlerine ya da model sonuçlarına dayalı olarak değil aynı zamanda doğal çevresel kaynaklı süreçler kapsamında da bütüncül bir şekilde değerlendirilmesi amaçlanmıştır. Atmosferik parametreler iklim ve hidrolojik açıdan ileri düzey araştırmalar yürüten NOAA (ABD Ulusal Okyanus ve Atmosfer Dairesi) bünyesindeki PSL (Fizik Bilimleri Laboratuvarı) tarafından sunulan NCEP/NCAR Reanalysis I veri setinden temin edilmiştir. Söz konusu veri seti, küresel ölçekte uzun dönemli ve güvenilir atmosferik gözlemler sağlaması sebebiyle çevresel etkilerin zamansal açıdan analiz edilmesine imkân sunmaktadır.


Bu çalışma kapsamında, su kütlesi üzerinde olası etki potansiyeli bulunan sıcaklık, yağış, rüzgâr hızı ve yönü gibi temel atmosferik değişkenler çalışma tarihleriyle uyumlu olacak şekilde derlenmiş ve analiz edilmiştir. Elde edilen meteorolojik haritalar ile çalışma tarihlerinde hakim olan atmosferik koşulların Mogan Gölü su yüzeyi üzerindeki potansiyel etkilerinin yorumlanması hedeflenmiştir. Bu kapsamda, haritalar ile çalışma dönemlerinin birbirinden ayrılan atmosferik özellikleri görsel olarak sunulurken dönemler arası değişimlerin kolaylıkla analiz edilmesi ve çevresel etkenlerin yorumlanması amaçlanmaktadır. Böylece su kalitesi parametrelerindeki zamansal değişimlerin yalnızca uzaktan algılama verileriyle değil aynı zamanda atmosferik süreçlerle birlikte değerlendirilmesi mümkün hale gelmiştir. Çalışma tarihlerine yönelik hazırlanan yüzey sıcaklık, yağış ve rüzgâr haritaları sırasıyla Şekil 4.7., Şekil 4.8. ve Şekil 4.9.'da gösterilmektedir.



Şekil 4.7. Çalışma tarihlerine ait sıcaklık haritaları




Şekil 4.8. Çalışma tarihlerine ait yağış haritaları



Şekil 4.9. Çalışma tarihlerine ait rüzgâr haritaları

Sıcaklık, yağış ve rüzgâr dağılımı haritaları birlikte analiz edildiğinde, Mogan Gölü üzerinde doğrudan etkili herhangi bir meteorolojik anomali bulunmadığı tespit edilmiştir. İncelenen tarihlerde sıcaklık değerleri mevsim normallerine yakın ya da bir miktar yüksek seyretmekte olup ekstrem bir durum görülmemektedir. Göl ve çevresinde yağış miktarlarının düşük seviyelerde seyrettiği, kayda değer bir yağış anomalisi olmadığı anlaşılmıştır. Rüzgâr hızları uygulama alanına yakın bölgelerde genellikle düşük/orta şiddet ($\approx 2-6$ m/s) arasında seyretmekte olup kuvvetli bir dalga oluşumuna ya da taşınımına sebebiyet verecek seviyede değildir. Dolayısıyla, çalışma tarihlerinde su kalitesi parametrelerine etki eden belirgin bir meteorolojik ya da atmosferik etki bulunmadığı saptanmıştır.

Mogan Gölü, coğrafi konumu ve bölgesel atmosferik dolaşım koşulları nedeniyle özellikle Kuzey Afrika kaynaklı çöl tozu taşınımlarının etkisine açık bir alanda yer almaktadır. Sahra Çölü ve çevresindeki kurak bölgelerden atmosfere karışan mineral tozlar, uzun mesafeli taşınım süreçleriyle Akdeniz Havzası ve Anadolu'ya ulaşabilmekte yüzey suları üzerinde optik, kimyasal ve biyolojik etkiler oluşturabilmektedir. Bu bağlamda, çalışma alanını etkileyen atmosferik toz taşınımlarının belirlenmesi, uzaktan algılama temelli su kalitesi analizlerinin doğru yorumlanabilmesi açısından önem arz etmektedir. Bu çalışmada, söz konusu toz taşınım olaylarının tespiti ve zamansal olarak değerlendirilmesi amacıyla CAMS-IFS (Copernicus Atmosfer İzleme Hizmeti–Entegre Tahmin Sistemi) verileri esas alınmış ve analizler NASA-GEOS (Ulusal Havacılık ve Uzay Dairesi–Goddard Yer Gözlem Sistemi) küresel atmosfer modeli çıktıları ile desteklenmiştir. AB (Avrupa Birliği) Copernicus programı kapsamında faaliyet gösteren CAMS-IFS, aerosol ve atmosfer bileşenlerine ilişkin yüksek zamansal çözünürlüklü veriler sunan resmi bir atmosfer izleme servisi. Benzer şekilde, NASA tarafından geliştirilen GEOS modeli, küresel ölçekte atmosferik süreçleri, aerosol taşınımını ve iklim bileşenlerini temsil edebilen gelişmiş bir sayısal model altyapısına sahiptir. Her iki model aracılığıyla, herhangi bir bölge için belirli bir zaman aralığında saatlik ya da günlük ölçeklerde toz taşınım durumları, mekânsal dağılım haritaları şeklinde temin edilebilmektedir. Bu kapsamda, çalışma dönemlerine karşılık gelen tarihler için elde edilen toz taşınım haritaları incelenmiş ve Mogan Gölü'nü etkileyen olası toz taşınımları değerlendirilmiştir. Analiz sonucunda temin edilen toz taşınım haritaları çalışma dönemlerindeki toz yükünün göl havzası üzerindeki mekânsal ve zamansal dağılımını ortaya koymakta olup Şekil 4.10.'da gösterilmektedir.



Şekil 4.10. Çalışma tarihlerine ait toz taşınım haritaları

Her iki modelden elde edilen toz taşınım haritalarının incelenmesi sonucunda, çalışma tarihlerinde uygulama alanında toz yükünün düşük seviyelerde seyrettiği belirlenmiştir. Model lejantları dikkate alındığında, Mogan Gölü üzerinde toz değerlerinin yaklaşık 0,02–0,10 aralığında kaldığı anlaşılmaktadır.

4.7. Kullanılan Yazılım ve Platformlar

Bu çalışmada, uydu görüntülerinin işlenmesi, analiz edilmesi ve görselleştirilmesi ile makine ve derin öğrenme modellerinin geliştirilmesinde çeşitli yazılım ve platformlar kullanılmıştır. Çalışma kapsamında kullanılan yazılım ve platformlar Şekil 4.11.'de gösterilmektedir.




Şekil 4.11. Kullanılan yazılım ve platformlar

Öncelikle, Landsat-8 uydu görüntülerinin düzenlenmesi ve yüzey yansıtım değerlerinin hesaplanmasında Erdas Imagine yazılımı kullanılmıştır. Erdas Imagine, uzaktan algılama teknolojisinde oldukça başarılı çözümler sunan ve birçok işlevi bir arada sunan profesyonel görüntü işleme yazılımıdır. Ardından, farklı tarihlere ait uydu görüntülerinden türetilen spektral indekslerin (NDVI, NDWI, MNDWI) hesaplanması

sürecinde GEE (Google Earth Engine) platformu kullanılmıştır. GEE, Landsat gibi geniş uydu arşivlerine erişim sağlayan, bulut altyapısına sahip yüksek kapasiteli işlemlere izin veren bir platformdur. Makine ve derin öğrenme modellerinin geliştirilmesi ve uygulanması süreçlerinde ise Google Colab platformu etkin olarak kullanılmıştır. Bu süreçte, Python programlama dili ile gerekli olan çeşitli kütüphanelerden (pandas, numpy, matplotlib, scikit-learn, tensorflow ve keras) yararlanılmıştır. Google Colab'ın GPU desteği ile veri yönetimi ve modelleme süreci başarılı şekilde gerçekleştirilmiştir. Elde edilen model çıktılarının mekânsal tabanlı modellenmesi ve haritalandırılması amacıyla ArcGIS ve QGIS yazılımlarından yararlanılmıştır. ArcGIS yazılımı profesyonel düzeyde coğrafi veri analizleri gerçekleştirmek ve tematik harita üretimi için tercih edilirken, QGIS, spektral indekslerin raster format ile görselleştirilmesi, göl yüzeyine odaklanan tematik haritaların hazırlanması sürecinde kullanılmıştır. Çalışma kapsamında kullanılan veriler, farklı kaynaklardan temin edilerek analiz ve modelleme gibi aşamalardan geçirilmiştir. Böylece verilerin temin edilmesinden analizine, modellemeye kadar tüm aşamalar çeşitli yazılımların entegre bir şekilde kullanılmasıyla yürütülmüştür. Verilerin temini ile başlayan ve sonuç çıktılarının üretilmesine kadar uzanan çalışma sürecinin her aşamasında benimsenen bu bütüncül yaklaşım, elde edilen sonuçların hem sayısal hem de görsel açıdan tutarlı bir yapı içerisinde sunulmasına olanak tanımaktadır.

4.8. Yöntemin Akış Diyagramı

Bu çalışma kapsamında, uzaktan algılama ve derin öğrenme tabanlı modelleme yaklaşımlarına dayalı olarak gerçekleştirilen analiz süreci, veri temininden nihai çıktıların elde edilmesine kadar sistematik bir iş akışı çerçevesinde yürütülmüştür. Uydu görüntülerinin ve su kalitesi parametrelerinin temin edilmesi, uydu görüntülerinin düzenlenmesi, yüzey yansıtım hesabının yapılması, makine ve derin öğrenme modellerinin geliştirilmesi, doğrulukların değerlendirilmesi ve tematik haritaların üretilmesine kadar geçen tüm süreç iş akış diyagramı ile özetlenerek çalışmada izlenen yöntemsel adımların açık ve izlenebilir bir biçimde ortaya konulması amaçlanmıştır. Şekil 4.12.'de dört ana başlık (I, II, III, IV) altında gruplandırılarak hazırlanan yöntemin akış diyagramı sunulmaktadır.



Şekil 4.12. Yöntemin akış diyagramı

I. aşama, çalışma alanının belirlenmesinden uydu görüntülerinin düzenlenmesine kadar olan süreci kapsamaktadır. Bu aşamada, uygulama sahasının tespit edilmesi akabinde su kalitesi parametrelerinin temin edilmesi için çalışmalar yürütülmüştür. 2018-2024 yılları arasındaki su kalitesi parametrelerine yönelik ölçüm sonuçları ÇŞİDB'den temin edilmiştir. Çalışma alanına ait 2018-2024 yılları arasındaki Landsat-8 uydu

görüntüleri USGS üzerinden filtrelenmiştir. Kullanılan su kalitesi parametrelerinin ölçüm tarihleri esas alınarak çalışma alanını kapsayan sekiz farklı tarihe ait uydu görüntüleri temin edilmiştir. Atmosferik etkileri minimum düzeye indirmek için uydu görüntülerinin bulutsuz olmasına dikkat edilmiştir. Çalışmada Landsat-8 Koleksiyon-2 görüntüleri kullanılmış olup bu görüntülerin USGS tarafından geometrik ve atmosferik düzeltmeleri tamamlanmış şekilde servis edilmektedir. Erdas Imagine yazılımı ile uydu görüntülerine yönelik gerekli düzenlemeler tamamlanmıştır.

II. aşama, spektral indekslerin hesaplanmasından veri setinin oluşturulmasına kadar olan süreci kapsamaktadır. Bu aşamada, DN değerleri yansıma değerlerine dönüştürülerek veri setinde kullanılabilir hale getirilmiştir. Kullanılan uydu görüntülerinin Bant 2, Bant 3, Bant 4 ve Bant 5 bantları için spektral yansıma değerleri çıkarılmıştır. Akabinde çalışma kapsamında kullanılan NDVI, NDWI ve MNDWI spektral indeksleri hesaplanarak veri seti oluşturulmuştur. Spektral indekslerin hesaplanmasında ve spektral yansıma değerlerinin çıkarılmasında ArcGIS yazılımı ve GEE platformu kullanılmıştır.

III. aşama, modellerin geliştirilmesinden doğruluk analizinin yapılmasına kadar olan süreci kapsamaktadır. Bu aşamada, ilk olarak hazırlanan veri setinin kontrollü bir şekilde genişletilmesi amacıyla RO algoritması uygulanmıştır. RO modeli ile tüm göl alanını kapsayacak şekilde piksel bazında tahminler üretilerek veri seti kontrollü bir şekilde genişletilmiştir. Genişletilen veri seti, modele dahil edilmeyen gerçek ölçüm verileri ile karşılaştırılarak kontrol edilmiştir. Model verilerinin gerçek verilerle uyum içerisinde olması ve yüksek tahmin doğruluğu bulunduğundan genişletilmiş veri seti YSA ve ESA modellerinin eğitilmesinde kullanılmıştır. Akabinde optimizasyon kriterleri belirlenerek sırasıyla YSA ve ESA modelleri geliştirilerek eğitim ve test süreçleri tamamlanmıştır. Tüm bu süreçler, klorofil-a, askıda katı madde ve secchi diski derinliği parametreleri için ayrı ayrı yürütülmüş olup, geliştirilen tüm modellerin doğruluk analizleri başarıyla tamamlanmıştır. Makine ve derin öğrenme modellerinin geliştirilmesi, eğitim/test süreçlerinin tamamlanması, model performanslarının analiz edilmesi ve elde edilen sonuçların grafiksel bazda görselleştirilmesinde Python yazılım dili kullanılmıştır.

IV. aşama, istatistiksel analizden tematik haritaların üretilmesine kadar olan süreci kapsamaktadır. Bu aşamada, her üç su kalitesi parametresi için en yüksek tahmin doğruluğunu sağlayan ESA modeli kullanılarak tahminler üretilmiştir. Tahmin verileri Python yazılım dili kullanılarak raster formatında dışa aktararak sınıflandırılmıştır.

Mogan Gölü’ndeki 8 farklı tarih için klorofil-a, askıda katı madde ve secchi diski derinliği dağılımını gösteren tematik haritalar üretilmiştir. Çalışmada su kalitesi parametrelerinin mekânsal dağılımının gerçekleştirilmesi, göldeki yüzey yansıtım değerlerinin vektörel forma dönüştürülmesi ve tematik haritaların üretilmesinde ArcGIS ve QGIS yazılımları kullanılmıştır. Tematik haritalar üzerinden gerçekleştirilen piksel bazlı istatistiksel analizler ile kestirim sonuçlarının mekânsal tutarlılığı ve zamansal davranışı ayrıntılı olarak incelenmiştir. Piksel bazlı istatistiksel analizler Python yazılım dili kullanılarak gerçekleştirilmiştir. Ayrıca çalışma tarihlerine ait sıcaklık, yağış, rüzgâr ve toz taşınımına ilişkin veriler analiz edilerek göl ve çevresindeki meteorolojik koşullar değerlendirilmiştir.

Sonuç olarak, bu çalışmada su kalitesi parametrelerinin mekânsal modellenerek tematik haritaların üretilmesi için bir dizi yöntem kullanılmıştır. Uydu görüntüleri ile su kalitesi ölçüm verilerinin birlikte kullanılması sayesinde su kalitesi parametrelerinin kestirimi için güvenilir bir veri altyapısı oluşturulmuştur. Geliştirilen makine ve derin öğrenme modelleri su kalitesi parametrelerinin mekânsal ve zamansal değişimlerini yüksek doğrulukla temsil etmiştir. Üretilen tematik haritalar göl genelindeki su kalitesi dağılımının görsel olarak yorumlanmasına olanak sağlamış ve sonuçların daha anlaşılır bir biçimde sunulmasını mümkün kılmıştır. Bu yönüyle geliştirilen yöntem, su kaynaklarının izlenmesi ve sürdürülebilir yönetimine yönelik uygulanabilir bir model ortaya koymaktadır.

5. KESTİRİM MODELLERİ VE DOĞRULUK ANALİZİ

Bu bölümde, su kalitesi parametrelerinin kestirimine yönelik geliştirilen modelleme yaklaşımları ve elde edilen sonuçların doğruluğu ayrıntılı olarak ele alınmaktadır. Çalışma kapsamında, su kalitesi parametreleri için RO, YSA ve ESA modelleri geliştirilerek her bir modelin kestirim performansı belirlenen doğruluk ölçütleri perspektifinde değerlendirilmiştir. Model sonuçlarının mekânsal dağılımlarını ortaya koymak amacıyla tematik haritalar üretilmiş ve bu haritalar üzerinden su kalitesi parametrelerinin göl genelindeki dağılım özellikleri analiz edilmiştir. Son olarak, kestirilen su kalitesi parametrelerine ilişkin gerçekleştirilen istatistiksel analizlerden elde edilen bulgular, su kalitesinin zamansal ve mekânsal davranışını açıklamak amacıyla yorumlanmıştır.

5.1. Klorofil-a Kestirim Modelleri

Bu bölümde, CHL-A konsantrasyonlarının uzaktan algılama verileri kullanılarak kestirilmesine yönelik geliştirilen modelleme yaklaşımları ele alınmıştır. Bu kapsamda, Landsat-8 uydu görüntülerinden elde edilen spektral bantlar ve türetilmiş indeksler kullanılarak modeller geliştirilmiş ve performansları karşılaştırmalı olarak değerlendirilmiştir. İzleyen alt başlıklarda, her bir modelin kurulum aşamaları, kullanılan girdi değişkenleri ve elde edilen kestirim sonuçları ayrıntılı olarak sunulmaktadır.


5.1.1. Rastgele orman modeli

CHL-A parametresinin kestirimine yönelik ilk aşamada, hazırlanan veri setinin kontrollü ve tutarlı bir biçimde genişletilmesi amaçlanmış ve bu doğrultuda RO algoritması uygulanmıştır. RO algoritması, çoklu karar ağaçlarının bir araya getirilmesi esasına dayanan yapısı sayesinde, doğrusal olmayan ve karmaşık ilişkilerin modellenmesinde yüksek performans sergileyen güçlü bir makine öğrenmesi yöntemi olarak tercih edilmiştir. Bu yaklaşım, CHL-A gibi optik ve çevresel birçok parametreden etkilenen su kalitesi göstergelerinin kestiriminde önemli avantajlar sunmaktadır (Shen vd., 2022; Budakoti ve Pal, 2025).

Modelin eğitim sürecinde, CHL-A konsantrasyonları bağımlı değişken olarak tanımlanırken; NDVI, MNDWI, B4 ve B5 bantları CHL-A ile olan spektral ve istatistiksel ilişkileri dikkate alınarak bağımsız değişkenler olarak belirlenmiştir. Model, eğitim sürecinde bu değişkenler ile CHL-A ölçüm değerleri arasındaki ilişkileri öğrenerek kestirim yapacak şekilde yapılandırılmıştır. RO algoritmasının çoklu karar ağaçlarına dayalı yapısı sayesinde, bağımsız değişkenler arasındaki doğrusal olmayan ilişkiler ve etkileşimler modele dâhil edilebilmiş, böylece CHL-A değişkenliğinin daha gerçekçi bir biçimde temsil edilmesi amaçlanmıştır. Bununla birlikte, modelin yalnızca kestirim başarısının değil, aynı zamanda karar verme sürecinin de anlaşılabilir olması hedeflenmiştir. Veri seti, modelin genellenebilirliğini ve performansının nesnel olarak değerlendirilmesini sağlamak amacıyla %80 eğitim ve %20 test olacak şekilde iki alt kümeye ayrılmıştır. RO modelinin temel hiperparametrelerinden biri olan ağaç sayısı 100 olarak belirlenmiş, rastgelelik ve tekrarlanabilirliği sağlamak amacıyla rastgelelik kontrol parametresi 42 olarak atanmıştır.


Modelin eğitim sürecinde, girdi değişkenleri ile hedef değişken arasındaki ilişkilerin aşırı karmaşık bir biçimde öğrenilmesinin önüne geçilmesi ve genelleme yeteneğinin korunması temel öncelikler arasında yer almıştır. Bu doğrultuda, model performansını etkileyen temel hiperparametrelerin dikkatli bir şekilde ele alınması ve modelin karmaşıklık düzeyinin kontrol altında tutulması amaçlanmıştır. Modelin aşırı öğrenme (overfitting) eğilimini azaltmak ve farklı örnekler üzerinde dengeli bir performans sergilemesini sağlamak amacıyla, ağaç derinliği parametresi otomatik olarak belirlenmiştir. RO modelinde ağaç derinliği, giriş değişkenleri arasındaki karmaşık ve doğrusal olmayan ilişkilerin yakalanmasında kritik bir rol oynamaktadır. Uygun derinlik seçimi modelin doğruluğunu ve genelleme kabiliyetini doğrudan etkilemektedir. Bu bağlamda, 100 adet ağacın tercih edilmesi, model doğruluğu ile hesaplama maliyeti arasında optimum bir denge kurulmasına olanak tanımıştır.

Modelin yapısını ve kullanılan bağımsız değişkenlerin CHL-A kestirimi üzerindeki etkilerini daha ayrıntılı ve yorumlanabilir bir biçimde analiz edebilmek amacıyla kısmi bağımlılık grafikleri oluşturulmuştur. Bu grafikler, her bir bağımsız değişkenin diğer değişkenlerden bağımsız olarak CHL-A tahminine olan katkısını ortaya koymakta ve modelin karar mekanizmasının daha iyi anlaşılmasını sağlamaktadır. Elde edilen kısmi bağımlılık grafikleri Şekil 5.1.'de gösterilmektedir.



Şekil 5.1. RO modeli için CHL-A kısmi bağımlılık grafikleri

NDVI artışı ile CHL-A değerlerinde bir düşüş gözlenmekte olup bu durum CHL-A konsantrasyonunun artan bitki yoğunluğuyla birlikte baskılandığını göstermektedir. MNDWI artışı ile CHL-A değerleri önce artarken sonrasında sabit bir seviyeye ulaşma eğilimindedir. B4 değerinde kayda değer bir dalgalanma görülmezken, CHL-A konsantrasyonunun B5 değerinin artışıyla birlikte hızla azaldığı gözlenmektedir. Kısmi bağımlılık analizleri ile bağımsız değişkenlerin CHL-A kestirimi üzerindeki bireysel etkileri incelendikten sonra, modelin genel karar yapısında hangi değişkenlerin daha baskın rol oynadığını ortaya koymak amacıyla değişken önem dereceleri değerlendirilmiştir. RO modeli, her bir girdi değişkeninin ağaç yapılarındaki bölünmelere sağladığı katkıyı dikkate alarak, kestirim sürecinde kullanılan özniteliklerin göreceli önemlerini nicel olarak ifade edebilmektedir. Bu analiz, modelin yalnızca hangi değişkenlerle daha başarılı sonuçlar ürettiğini değil, aynı zamanda CHL-A değişkenliğini açıklamada hangi spektral bant ve indekslerin daha etkili olduğunu ortaya koyması açısından önem taşımaktadır. RO modeli ile CHL-A kestiriminde her bir özelliğin önem derecesini daha detaylı olarak analiz etmek üzere oluşturulan değişkenlerin önem derecesi grafiği Şekil 5.2.'de gösterilmektedir.



Şekil 5.2. RO modeli için CHL-A değişkenlerinin önem derecesi

RO modelinde kullanılan bağımsız değişkenler arasında model tahminlerinde en etkili olan özellik B5’ tir. Değişken önem sıralamasında B5’i sırasıyla MNDWI, NDVI ve B4 takip etmektedir. Bu sıralama ölçütü, modelin CHL-A parametresinin kestiriminde özellikle yakın kızılötesi bant bilgisine duyarlı olduğunu ortaya koymaktadır. B5 bandı, bitki örtüsü ve fitoplankton varlığı ile güçlü ilişkilere sahip olup sucul ortamlardaki biyolojik üretim durumunun detaylı analiz edilmesine imkân sunmaktadır. CHL-A konsantrasyonlarının artışı ile suyun optik özelliklerindeki değişimler, özellikle NIR bölgesinde belirgin hale gelmektedir. Bu durum, B5 bandının model üzerindeki etkisini ortaya koymaktadır. MNDWI ve NDVI indekslerinin model içerisinde belirleyici rolde yer alması ise vejetasyon etkilerinin CHL-A konsantrasyonları üzerinde tamamlayıcı bir rol oynadığını göstermektedir.

Veri seti, RO modeli ile tüm göl alanını kapsayacak şekilde piksel bazında tahminler üretilerek kontrollü bir şekilde genişletilmiştir. Bu yaklaşım ile sınırlı sayıdaki veri setinin uzaktan algılama tabanlı kestirimi için oluşturabileceği olası kısıtlar önemli ölçüde giderilmiştir. Piksel bazlı üretilen tahminler ile veri setinin genişletilmesi su kütlesindeki mekânsal değişimin daha iyi bir şekilde temsil edilmesine olanak tanımaktadır. Makine ve derin öğrenme modelleri için karmaşık ve doğrusal olmayan örüntüleri öğrenebilmeleri noktasında daha zengin bir veri kümesi elde edilmiştir. Genişletilen veri seti, modele dahil edilmeyen CHL-A ölçüm verileri ile karşılaştırılarak kontrol edilmiştir. Model kapsamında elde edilen tahmin değerlerinin gerçek ölçüm verileri ile uyumlu olduğu görülmüştür. Genişletilmiş veri seti, ileri aşamada daha

karmaşık ilişkileri çözömleme kapasitesine sahip olan YSA ve ESA modellerinin eğitilmesinde temel girdi verisi olarak kullanılmıştır.

5.1.2. Yapay sinir ağı modeli

RO modeli ile genişletilen veri seti kullanılarak YSA modeli geliştirilmiştir. RO modeli ile her bir piksel için tahmin edilen CHL-A değeri YSA modelinde bağımlı değişken olarak kullanılmıştır. Modelin bağımsız değişkenleri NDVI, MNDWI, B4 ve B5'tir. YSA modelinde veri setinin ölçeklendirilmesine gerek duyulduğundan min-max normalizasyon yöntemi ile bağımsız değişkenler 0-1 aralığına ölçeklenmiştir. YSA modelinde toplam 6344 veri noktası kullanılırken veri kümesi %80 eğitim ve %20 test olmak üzere ikiye ayrılmıştır. Eğitim verileri 5075 veri noktasından, test verileri ise 1269 veri noktasından oluşmaktadır. Adam optimizasyonu kullanılan modelin eğitiminde epok sayısı 100 olarak seçilmiştir. Model, gizli bir katmanda 64 nöron ve bir ReLU aktivasyon fonksiyonundan oluşan bir yapıya sahiptir. Doğrusal olmayan ilişkilerin modellenmesindeki yüksek başarısı sebebiyle ReLU aktivasyonu, hızlı ve kararlı optimizasyon özellikleri sebebiyle de Adam algoritması tercih edilmiştir. Bu hiperparametreler ile modelin genelleme kapasitesini ve doğruluğunu artırmak amaçlanmıştır. YSA modeli, CHL-A tahmininde yüksek doğruluk sağlarken modelin genelleme yeteneği göl genelinde tahmin edilen değeri doğruluğunu artırmıştır.

5.1.3. Evrişimli sinir ağı modeli

RO modeli ile genişletilen veri setindeki spektral özellikler arasındaki örtük mekânsal ilişkilerin daha etkin bir şekilde öğrenilmesi amacıyla ESA modeli geliştirilmiştir. ESA modeli, CHL-A kestiriminde mekânsal örüntüleri ve piksel tabanlı ilişkileri daha etkin biçimde öğrenebilmektedir. Özellikle uzaktan algılama verilerinde, komşu pikseller arasındaki mekânsal sürekliliğin göz ardı edilmesi model performansını sınırlayabilmektedir. Bu durumun üstesinden gelmek üzere ESA mimarileri, geleneksel makine öğrenmesi yaklaşımlarına kıyasla başarılı çözümler sunmaktadır. İki boyutlu ESA, özellikle uydu görüntüleri ile temin edilen veriler gibi mekânsal bağımlılığa sahip veri setlerindeki gizli ilişkilerin çözömlenmesinde oldukça başarılıdır. Model kurulumunda CHL-A konsantrasyonları bağımlı değişken olarak belirlenirken, NDVI, MNDWI, B4 ve B5 parametreleri modelin bağımsız değişkenleridir. ESA modelinde

özelliklerin ölçeklendirilmesine gerek duyulduğundan tüm bağımsız değişkenler 0-1 aralığına ayarlanmıştır. Veri seti %80 eğitim ve %20 test veri seti olmak üzere ikiye ayrılmıştır. Toplam 6344 veri noktasından 5075'i eğitim, 1269'u ise test veri seti olarak ayrılmıştır.

ESA modeli için kullanılan veri seti, 2B matrise dönüştürülerek modelle uyumlu hale getirilmiştir. Her veri örneği ESA giriş formatına uyum sağlaması için 5x5'lik uzamsal bloklara ayrılmıştır. İlk evrişim katmanında 32 filtre ve 3x3 çekirdek uygulanırken ikinci katmanda 64 filtre ve 3x3 çekirdek ile daha karmaşık özellikler öğrenilmiştir. Aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılırken karmaşık yapıları en etkili şekilde yakalamak üzere 3x3 ve 5x5 çekirdek yapılandırmaları tercih edilmiştir. 3x3 daha küçük ölçekli ayrıntıları yakalarken, 5x5 çekirdekler daha büyük ölçekteki desenlerin tespit edilmesine olanak tanımaktadır. ESA modeli kurulumunda farklı hiperparametre kombinasyonlarına yönelik yoğun testler gerçekleştirilerek en iyi performansı gösteren ayarlar ile model optimize edilmiştir. Model eğitiminde öğrenme oranı 0,001 olarak ayarlanırken maksimum dönem sınırı ise 100 olarak seçilmiştir. Modelin aşırı öğrenmesini önlemek amacıyla erken durdurma yöntemi uygulanarak herhangi bir performans iyileşmesi gözlenmediğinde modelin eğitimi otomatik olarak durdurması sağlanmıştır. Bu durum, modelin aşırı öğrenme ihtimalini minimize ederken eğitim aşamasının optimum zamanlama ile yönetilmesine ve güvenilir sonuçların elde edilmesine olanak tanınmıştır. Kayıp fonksiyonu olarak MSE kullanılırken aşırı uyumu önlemek için farklı katmanlara %50'lik bırakma katmanları eklenmiştir. Eğitim verilerinin çeşitliliğini artırmak için veri kümesine rastgele döndürme, gürültü ekleme ve yatay-dikey öteleme uygulanmıştır. Bu yöntemler ile veri kümesinin sınırlı boyutu hesaba katılarak modelin farklı veri dağılımlarını daha iyi genelleştirmesi sağlanmıştır.

ESA modeli, CHL-A kestiriminde diğer modellere kıyasla üstün performans göstermiştir. Bu sebeple, CHL-A parametresi için en yüksek tahmin doğruluğunu sağlayan ESA modeli kullanılarak tahminler yapılmıştır. Model ile elde edilen yüksek doğruluklu tahminler raster formatında dışa aktararak çalışma tarihlerine ait CHL-A ile ilişkili tematik haritalar üretilmiştir. RO, YSA ve ESA modellerinin tamamında veri işleme ve modelleme süreçlerini yönetmek üzere Python programlama dili ve gerekli kütüphaneler kullanılmıştır.


5.1.4. Doğrulukların değerlendirilmesi

Bu çalışmada, CHL-A parametresi için geliştirilen RO, YSA ve ESA modellerinin performans analizleri R^2 , RMSE ve MAE metrikleri ile değerlendirilmiştir. Tablo 5.1.'de CHL-A parametresinin model doğrulukları gösterilmektedir.

Tablo 5.1. CHL-A parametresinin model performansları

Metrik	Veri Seti	RO	YSA	ESA
R^2	Eğitim	0,88	0,89	0,96
R^2	Test	0,84	0,85	0,92
RMSE ($\mu\text{g/L}$)	Eğitim	0,15	0,25	0,16
RMSE ($\mu\text{g/L}$)	Test	0,18	0,29	0,20
MAE ($\mu\text{g/L}$)	Eğitim	0,14	0,21	0,10
MAE ($\mu\text{g/L}$)	Test	0,17	0,24	0,12

RO modeli ile $R^2 = 0,88$ (eğitim) ve $R^2 = 0,84$ (test), RMSE = 0,15 (eğitim) ve RMSE = 0,18 (test), MAE = 0,14 (eğitim) ve MAE = 0,17 (test) doğruluk metrikleri hesaplanmıştır. Model, sınırlı sayıda ölçüm verisi ile genelleme yapabilme kabiliyetiyle CHL-A kestirimi için güçlü bir başlangıç noktası olmuştur. YSA modeli ile $R^2 = 0,89$ (eğitim) ve $R^2 = 0,85$ (test), RMSE = 0,25 (eğitim) ve RMSE = 0,29 (test), MAE = 0,21 (eğitim) ve MAE = 0,24 (test) doğruluk metrikleri hesaplanmıştır. YSA modeli ile R^2 değerinde bir miktar doğruluk artışı görülse de RMSE ve MAE değerleri RO modelinden daha yüksek hesaplanmıştır. YSA modeli, doğrusal olmayan ilişkileri çözümüleme kabiliyeti sayesinde performansı bir miktar iyileştirmiş, ancak RO modeline kıyasla daha az etkili olmuştur. ESA modeli ile $R^2 = 0,96$ (eğitim) ve $R^2 = 0,92$ (test), RMSE = 0,16 (eğitim) ve RMSE = 0,20 (test), MAE = 0,10 (eğitim) ve MAE = 0,12 (test) doğruluk metrikleri hesaplanmıştır. ESA modeli, mekânsal ilişkileri öğrenme kapasitesi sayesinde tüm modeller arasında en yüksek performansı göstererek CHL-A kestiriminde en başarılı yöntem olmuştur. Şekil 5.3.'te CHL-A parametresinin model bazlı dağılımı ve çizgisel grafikleri gösterilmektedir.




Şekil 5.3. CHL-A parametresinin model bazlı dağılımı ve çizgisel grafikleri

Şekil 5.3.'te, CHL-A parametresine yönelik geliştirilen RO, YSA ve ESA modelleri tarafından üretilen sonuçlar birlikte sunulmaktadır. Modellerin bir arada değerlendirilmesine imkân tanıyan bu grafikler farklı modellere dayalı olarak CHL-A dağılımının nasıl gerçekleştiğinin analiz edilmesine imkân sunmaktadır. Böylece modeller arasındaki genel eğilimler ve benzerlikler görsel olarak değerlendirilerek elde edilen bulguların geniş ölçekte yorumlanması amaçlanmıştır.

5.1.5. Tematik haritaların üretilmesi

Çalışma alanına ait CHL-A, AKM ve SDD parametreleri tematik harita türlerinden izaritmik harita yöntemiyle görselleştirilmiştir. İzaritmik haritalar, mekânsal olarak sürekli değişim gösteren niceliksel verilerin, ölçüm noktaları arasındaki değerlerin enterpolasyon yoluyla tahmin edilmesi ve renk tonlu yüzeyler aracılığıyla temsil edilmesi esasına dayanan tematik harita türlerinden birisidir (Robinson vd., 1995; Dent vd., 2009; Slocum vd., 2009). Tematik haritaların sınıflandırma sürecinde manuel sınıflandırma yöntemi tercih edilmiş olup sınıf aralıkları veri dağılımı dikkate alınarak belirlenmiştir. CHL-A kestiriminde en yüksek tahmin doğruluğunu sağlayan ESA modeli kullanılarak uydu görüntüleriyle eş zamanlı tarihler için CHL-A tahminleri üretilmiştir. Python yazılım dili kullanılarak tahmin verileri raster formatında dışa aktarılmıştır. ArcGIS yazılımı ile raster görüntüler sınıflandırılarak Mogan Gölü'ndeki 8 farklı tarih için CHL-A konsantrasyonunu gösteren tematik haritalar üretilmiştir. Şekil 5.4.'te Mogan Gölü'ndeki CHL-A parametresinin mekânsal dağılımına ilişkin tematik haritalar gösterilmektedir.



Şekil 5.4. CHL-A parametresinin mekânsal dağılımına ilişkin tematik haritalar

Mogan Gölü’ndeki CHL-A değişiminin izlenmesi açısından, çalışma kapsamında üretilen tematik haritalar önemli bir değerlendirme aracı niteliği taşımaktadır. Tematik haritalar, CHL-A parametresinin gölün yüzey alanındaki dağılımını detaylı bir şekilde ortaya koyarken insan faaliyetlerinin ya da doğal unsurların kirlilik üzerindeki etkisini açıklamada son derece etkilidir. ESA modeli ile elde edilen tahmin verileri, ÇŞİDB’den temin edilen ölçüm değerleri ile karşılaştırılmıştır. Tematik haritaların gerçek ölçüm değerleriyle uyumlu olduğu görülmüştür. Mogan Gölü’ndeki CHL-A dağılımının mekânsal desenlerinin derinlemesine analiz edilmesi noktasında tematik haritaların kullanılması tercih edilmiştir. Çalışma sonuçları, ESA modelinin CHL-A parametresini tahmin etmedeki başarısını ortaya koymaktadır.


5.2. Askıda Katı Madde Kestirim Modelleri

Bu bölümde, AKM konsantrasyonlarının uzaktan algılama verileri kullanılarak kestirilmesine yönelik geliştirilen modelleme yaklaşımları ele alınmıştır. Bu kapsamda, Landsat-8 uydu görüntülerinden elde edilen spektral bantlar ve türetilmiş indeksler kullanılarak RO, YSA ve ESA modelleri oluşturulmuş ve performansları karşılaştırmalı olarak değerlendirilmiştir. İzleyen alt başlıklarda, her bir modelin kurulum aşamaları, kullanılan girdi değişkenleri ve elde edilen kestirim sonuçları ayrıntılı olarak sunulmaktadır.

5.2.1. Rastgele orman modeli


AKM parametresinin kestiriminde, sınırlı sayıdaki yerinde ölçüm verisinin modelleme sürecine daha etkin biçimde entegre edilebilmesi amacıyla, öncelikle oluşturulan veri setinin kontrollü bir şekilde genişletilmesi hedeflenmiştir. Bu kapsamda, güçlü genelleme yeteneği ve değişkenler arasındaki doğrusal olmayan ilişkileri başarıyla modelleyebilmesi nedeniyle RO algoritması tercih edilmiştir. Model eğitiminde AKM konsantrasyonları bağımlı değişken olarak tanımlanırken; NDWI, MNDWI indeksleri ile B2, B3 ve B4 bantları bağımsız değişkenler olarak modele dâhil edilmiştir. Oluşturulan veri seti, modelin hem öğrenme kapasitesinin hem de genellenebilirliğinin değerlendirilebilmesi amacıyla %80 eğitim ve %20 test olacak şekilde iki alt gruba ayrılmıştır. RO modelinde ağaç sayısı 100 olarak belirlenmiş, model çıktılarının tekrarlanabilirliğini sağlamak ve rastgeleliğin etkisini kontrol altında tutmak amacıyla

kontrol parametresi 42 olarak tanımlanmıştır. Aşırı öğrenme riskini en aza indirmek amacıyla, ağaç derinliği otomatik olarak belirlenmiş ve böylece modelin veri setine özgü gürültüye aşırı duyarlı hâle gelmesi engellenmiştir. Modelin karar mekanizmasının anlaşılması ve kullanılan bağımsız değişkenlerin AKM kestirimi üzerindeki etkilerinin değerlendirilmesi, model sonuçlarının güvenilir bir şekilde ele alınması noktasında kritik öneme sahiptir. Özellikle çok değişkene sahip ve doğrusal olmayan yapılarda model çıktılarının hangi girdiler eşliğinde etkilendiğinin ortaya konulması gerekmektedir. Bu kapsamda, modelin iç yapısını ayrıntılı ve yorumlanabilir bir biçimde analiz edebilmek amacıyla kısmi bağımlılık grafikleri oluşturulmuştur. Bu grafikler, diğer değişkenlerin sabit kaldığı durumda ilgili parametredeki değişimlerin model çıktısına olan etkisini ortaya koymakta ve modelin iç yapısının analiz edilmesine imkân sunmaktadır. Elde edilen kısmi bağımlılık grafikleri Şekil 5.5.'te gösterilmektedir.



Şekil 5.5. RO modeli için AKM kısmi bağımlılık grafikleri

NDWI ve MNDWI değerlerindeki artışa paralel olarak AKM değerlerinde belirgin değişimlerin meydana geldiği görülmektedir. Buna karşılık, diğer spektral bantların AKM konsantrasyonu üzerindeki etkisinin bu indekslere kıyasla daha sınırlı olduğu ve modele olan katkılarının ikincil düzeyde kaldığı gözlenmektedir. RO modeli ile AKM kestiriminde her bir özelliğin modele sağladığı katkının nicel olarak ortaya konulabilmesi amacıyla oluşturulan değişkenlerin önem derecesi grafiği Şekil 5.6.'da gösterilmektedir.



Şekil 5.6. RO modeli için AKM değişkenlerin önem derecesi

RO modelinde kullanılan bağımsız değişkenler arasında model tahminlerinde en etkili olan özellik NDWI indeksidir. Bu özelliği sırasıyla MNDWI, B2, B3 ve B4 takip etmektedir. Veri seti, RO modeli ile tüm göl alanını kapsayacak şekilde piksel bazında tahminler üretilerek kontrollü bir şekilde genişletilmiştir. Genişletilen veri seti, modele dahil edilmeyen AKM ölçüm verileri ile karşılaştırılarak kontrol edilmiştir. Model kapsamında elde edilen tahmin değerlerinin gerçek ölçüm verileri ile uyumlu olduğu görülmüştür. Bu genişletilmiş veri seti, ileri aşamada daha karmaşık ilişkileri çözümleme kapasitesine sahip olan YSA ve ESA modellerinin eğitilmesinde temel girdi verisi olarak kullanılmıştır.

5.2.2. Yapay sinir ağı modeli

RO modeli ile genişletilen veri seti kullanılarak YSA modeli geliştirilmiştir. RO modeli ile her bir piksel için tahmin edilen AKM değerleri YSA modelinde bağımlı

değişken olarak kullanılmıştır. Modelin bağımsız değişkenleri ise NDWI, MNDWI, B2, B3 ve B4'tür. YSA modelinde veri setinin ölçeklendirilmesi gerektiğinden min-max normalizasyon yöntemi ile bağımsız değişkenler 0-1 aralığına ölçeklenmiştir. YSA modelinde toplam 6344 veri noktası kullanılırken veri kümesi %80 eğitim ve %20 test olmak üzere ikiye ayrılmıştır. Eğitim verileri 5075 veri noktasından, test verileri ise 1269 veri noktasından oluşmaktadır. Adam optimizasyonu kullanılan modelin eğitiminde epok sayısı 200 olarak seçilmiştir. Model, gizli bir katmanda 64 nöron ve bir ReLU aktivasyon fonksiyonundan oluşan bir yapıya sahiptir. Doğrusal olmayan ilişkileri modellemedeki yüksek başarısı sebebiyle ReLU aktivasyonu, hızlı ve kararlı optimizasyon özellikleri sebebiyle de Adam algoritması tercih edilmiştir. Bu hiperparametreler ile modelin genelleme kapasitesini ve doğruluğunu artırmak amaçlanmıştır. YSA modeli, AKM tahmininde yüksek doğruluk sağlarken modelin genelleme yeteneği göl genelinde tahmin edilen değerlerin doğruluğunu artırmıştır.

5.2.3. Evrişimli sinir ağı modeli

RO modeli ile genişletilen veri setindeki spektral özellikler arasındaki örtük mekânsal ilişkilerin daha etkin bir şekilde öğrenilmesi ve tahmin performansının artırılması amacıyla ESA modeli kullanılmıştır. AKM değerleri modelin bağımlı değişkeniyken NDWI, MNDWI, B2, B3 ve B4 değerleri bağımsız değişkenlerdir. ESA modelinde özelliklerin ölçeklendirilmesine gerek duyulduğundan tüm bağımsız değişkenler 0-1 aralığına ayarlanmıştır. Veri seti %80 eğitim ve %20 test veri seti olmak üzere ikiye ayrılmıştır. Toplam 6344 veri noktasından 5075'i eğitim veri seti ve 1269'u test veri seti olarak ayrılmıştır. ESA modeli için kullanılan bu veri seti modelle uyumlu olması için 2B matrise dönüştürülmüştür. Her veri örneği ESA giriş formatına uyum sağlaması için 5x5'lik uzamsal bloklara ayrılmıştır. İlk evrişim katmanında 32 filtre ve 3x3 çekirdek uygulanırken ikinci katmanda 64 filtre ve 3x3 çekirdek ile daha karmaşık özellikler öğrenilmiştir. Aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılırken karmaşık yapıları en etkili şekilde yakalamak üzere 3x3 ve 5x5 çekirdek yapılandırmaları tercih edilmiştir. 3x3 daha küçük ölçekli ayrıntıları yakalarken, 5x5 çekirdekler daha büyük ölçekteki desenlerin tespit edilmesine olanak tanımaktadır. ESA modeli kurulumunda farklı hiperparametre kombinasyonlarına yönelik yoğun testler gerçekleştirilerek en iyi performansı gösteren ayarlar ile model optimize edilmiştir. Model eğitiminde öğrenme oranı 0,001 olarak ayarlanırken epok sayısı 200 olarak

seçilmiştir. Modelin aşırı öğrenmesini önlemek amacıyla erken durdurma yöntemi uygulanarak herhangi bir performans iyileşmesi gözlenmediğinde modelin eğitimi durdurması sağlanmıştır. Kayıp fonksiyonu olarak MSE kullanılırken aşırı uyumu önlemek için farklı katmanlara %50'lik bırakma katmanları eklenmiştir. Eğitim verilerinin çeşitliliğini artırmak için veri kümesine rastgele döndürme, gürültü ekleme ve yatay-dikey öteleme uygulanmıştır. Bu yöntemler ile veri kümesinin sınırlı boyutu hesaba katılarak modelin farklı veri dağılımlarını daha iyi genelleştirmesi sağlanmıştır. ESA modeli, AKM kestiriminde üstün performans göstermiştir. Model ile elde edilen yüksek doğruluklu tahminler raster formatında dışa aktararak tematik haritalar üretilmiştir. RO, YSA ve ESA modellerinin tamamında veri işleme ve modelleme süreçlerini yönetmek üzere Python programlama dili ve gerekli kütüphaneler kullanılmıştır.

5.2.4. Doğrulukların değerlendirilmesi


Bu çalışmada, AKM parametresi için geliştirilen RO, YSA ve ESA modellerinin performans analizleri R^2 , RMSE ve MAE metrikleri ile değerlendirilmiştir. Tablo 5.2.'de AKM parametresinin model performansları gösterilmektedir.

Tablo 5.2. AKM parametresinin model performansları

Metrik	Veri Seti	RO	YSA	ESA
R^2	Eğitim	0,84	0,91	0,98
R^2	Test	0,81	0,90	0,97
RMSE (mg/L)	Eğitim	0,36	0,35	0,15
RMSE (mg/L)	Test	0,39	0,36	0,17
MAE (mg/L)	Eğitim	0,33	0,27	0,12
MAE (mg/L)	Test	0,36	0,28	0,13

RO modeli ile $R^2 = 0,84$ (eğitim) ve $R^2 = 0,81$ (test), RMSE = 0,36 (eğitim) ve RMSE = 0,39 (test), MAE = 0,33 (eğitim) ve MAE = 0,36 (test) doğruluk metrikleri hesaplanmıştır. Model, sınırlı sayıda ölçüm verisi ile genelleme yapabilme kabiliyetiyle AKM kestirimi için güçlü bir başlangıç noktası olmuştur. YSA modeli ile $R^2 = 0,91$ (eğitim) ve $R^2 = 0,90$ (test), RMSE = 0,35 (eğitim) ve RMSE = 0,36 (test), MAE = 0,27 (eğitim) ve MAE = 0,28 (test) doğruluk metrikleri hesaplanmıştır. YSA modeli, doğrusal


olmayan ilişkileri çözümleme kabiliyeti sayesinde performansı bir miktar iyileştirerek RO modeline kıyasla daha çok etkili olmuştur. ESA modeli ile $R^2 = 0,98$ (eğitim) ve $R^2 = 0,97$ (test), RMSE = 0,15 (eğitim) ve RMSE = 0,17 (test), MAE = 0,12 (eğitim) ve MAE = 0,13 (test) doğruluk metrikleri hesaplanmıştır. ESA modeli, mekânsal ilişkileri öğrenme kapasitesi sayesinde tüm modeller arasında en yüksek performansı göstererek AKM kestiriminde en başarılı yöntem olmuştur. Şekil 5.7.'de AKM parametresinin model bazlı dağılımı ve çizgisel grafikleri gösterilmektedir.



Şekil 5.7. AKM parametresinin model bazlı dağılımı ve çizgisel grafikleri

5.2.5. Tematik haritaların üretilmesi

AKM kestiriminde en yüksek tahmin doğruluğunu sağlayan ESA modeli kullanılarak uydu görüntüleriyle eş zamanlı tarihler için AKM tahminleri üretilmiştir. Python yazılım dili kullanılarak tahmin verileri raster formatında dışa aktarılmıştır. ArcGIS yazılımı ile raster görüntüler sınıflandırılarak Mogan Gölü'ndeki 8 farklı tarih için AKM konsantrasyonunu gösteren tematik haritalar üretilmiştir. Şekil 5.8.'de Mogan Gölü'ndeki AKM parametresinin mekânsal dağılımına ilişkin tematik haritalar gösterilmektedir.



Şekil 5.8. AKM parametresinin mekânsal dağılımına ilişkin tematik haritalar

Mogan Gölü'ndeki AKM değişiminin izlenmesi noktasında çalışma kapsamında üretilen tematik haritalar oldukça önemlidir. Tematik haritalar, AKM parametresinin gölün yüzey alanındaki dağılımını detaylı bir şekilde ortaya koyarken insan faaliyetlerinin ya da doğal unsurların kirlilik üzerindeki etkisini açıklamada etkilidir. ESA modeli ile elde edilen tahmin verileri, ÇŞİDB'den temin edilen ölçüm değerleri ile karşılaştırılmıştır. Tematik haritaların gerçek ölçüm değerleriyle uyumlu olduğu

görülmüştür. Çalışma sonuçları, ESA modelinin AKM parametresini tahmin etmedeki başarısını ortaya koymaktadır.


5.3. Secchi Diski Derinliği Kestirim Modelleri

Bu bölümde, SDD parametresinin uzaktan algılama verileri kullanılarak kestirilmesine yönelik geliştirilen modelleme yaklaşımları ele alınmıştır. Bu kapsamda, Landsat-8 uydu görüntülerinden elde edilen spektral bantlar ve türetilmiş indeksler kullanılarak RO, YSA ve ESA modelleri oluşturulmuş ve performansları karşılaştırmalı olarak değerlendirilmiştir. İzleyen alt başlıklarda, her bir modelin kurulum aşamaları, kullanılan girdi değişkenleri ve elde edilen kestirim sonuçları ayrıntılı olarak sunulmaktadır.

5.3.1. Rastgele orman modeli


SDD parametresinin kestiriminde ilk olarak hazırlanan veri setinin kontrollü bir şekilde genişletilmesi amacıyla RO algoritması uygulanmıştır. Modelin eğitiminde SDD ölçüm sonuçları bağımlı değişken, NDWI, B2 ve B3 parametreleri ise bağımsız değişken olarak belirlenmiştir. Veri seti %80 eğitim ve %20 test olmak üzere ikiye ayrılırken ağaç sayısı 100 ve rastgelelik kontrolü 42 olarak belirlenmiştir. Modelin aşırı öğrenmesini engellemek amacıyla derinlik otomatikleştirilmiştir. RO modelinde ağaçların derinliği giriş değişkenleri arasındaki karmaşık ilişkilerin daha etkin bir şekilde yakalanmasına olanak tanımaktadır. 100 ağacın tercih edilmesinin sebebi model doğruluğu ile hesaplama verimliliği arasında optimum dengeyi sağlayabilmektir.

Modelin yapısını ve kullanılan bağımsız değişkenlerin SDD kestirimi üzerindeki etkilerini daha ayrıntılı ve yorumlanabilir bir biçimde analiz edebilmek amacıyla kısmi bağımlılık grafikleri oluşturulmuştur. Bu grafikler, her bir bağımsız değişkenin diğer değişkenlerden bağımsız olarak SDD tahminine olan katkısını ortaya koymakta ve modelin karar mekanizmasının daha iyi anlaşılmasını sağlamaktadır. Elde edilen kısmi bağımlılık grafikleri Şekil 5.9.'da gösterilmektedir.



Şekil 5.9. RO modeli için SDD kısmi bağımlılık grafikleri

NDWI değerlerindeki değişimlerin SDD tahminini güçlü bir şekilde etkilediği görülmektedir. Özellikle su yüzeyindeki optik karakteristiği doğrudan temsil etmesi sebebiyle NDWI indeksinin model üzerinde belirleyici rol üstlendiği anlaşılmaktadır. B2 ve B3 bantlarında da SDD kestirimi üzerinde anlamlı etkiler gözlenmiş olsa da bu değişkenlerin katkısı NDWI indeksine kıyasla daha sınırlı düzeyde kalmıştır. Görünür spektrum aralığında yer alan B2 ve B3 bantlarının su içerisindeki AKM ve ışık saçılımıyla ilişkili olması bu bantların SDD tahminine dolaylı katkı sunduğunu göstermektedir. RO modeli, her bir girdi değişkeninin ağaç yapılarındaki bölünmelere sağladığı katkıyı dikkate alarak, kestirim sürecinde kullanılan özneliliklerin göreceli önemlerini nicel olarak ifade edebilmektedir. Bu analiz, modelin yalnızca hangi değişkenlerle daha başarılı sonuçlar ürettiğini değil, aynı zamanda SDD değişkenliğini açıklamada hangi spektral bant ve indekslerin daha etkili olduğunu ortaya koyması açısından önem taşımaktadır. RO modeli ile SDD kestiriminde her bir özelliğin önem derecesini daha detaylı olarak analiz etmek üzere oluşturulan değişkenlerin önem derecesi grafiği Şekil 5.10.'da gösterilmektedir.



Şekil 5.10. RO modeli için SDD değişkenlerin önem derecesi

RO modelinde kullanılan bağımsız değişkenler arasında, model tahminlerinde en etkili olan özelliğin NDWI olduğu belirlenmiştir. Bu özelliği sırasıyla B2 ve B3 takip etmektedir. Çalışma kapsamında veri seti, RO modeli kullanılarak tüm göl alanını kapsayacak şekilde piksel bazında tahminler üretilmesi yoluyla kontrollü bir şekilde genişletilmiştir. Genişletilen veri seti, model eğitim sürecine dahil edilmeyen SDD ölçüm verileri ile karşılaştırılarak doğrulanmış ve bu sayede tahminlerin tutarlılığı kontrol edilmiştir. RO modeli kapsamında elde edilen tahmin değerlerinin gerçek ölçüm verileri ile yüksek düzeyde uyum gösterdiği tespit edilmiştir. Bu kapsamda hem veri çeşitliliği artırılmış hem de derin öğrenme modellerinin genelleme kabiliyetinin güçlendirilmesi ve SDD parametrelerinin tahmin doğruluğunun artırılması amaçlanmıştır. Elde edilen genişletilmiş veri seti, ileri aşamada daha karmaşık ilişkileri çözümleme kapasitesine sahip olan YSA ve ESA modellerinin eğitilmesinde temel girdi verisi olarak kullanılmıştır.

5.3.2. Yapay sinir ağı modeli

RO modeli ile genişletilen veri seti kullanılarak YSA modeli geliştirilmiştir. RO modeli ile her bir piksel için tahmin edilen SDD değerleri YSA modelinde bağımlı değişken olarak kullanılmıştır. Modelin bağımsız değişkenleri ise NDWI, B2 ve B3'tür. YSA modelinde veri setinin ölçeklendirilmesi gerektiğinden min-max normalizasyon yöntemi ile bağımsız değişkenler 0-1 aralığına ölçeklenmiştir. YSA modelinde toplam 6344 veri noktası kullanılırken veri kümesi %80 eğitim ve %20 test olmak üzere ikiye

ayrılmıştır. Eğitim verileri 5075 veri noktasından, test verileri ise 1269 veri noktasından oluşmaktadır. Adam optimizasyonu kullanılan modelin eğitiminde epok sayısı 100 olarak seçilmiştir. Model, gizli bir katmanda 64 nöron ve bir ReLU aktivasyon fonksiyonundan oluşan bir yapıya sahiptir. Doğrusal olmayan ilişkileri modellemedeki yüksek başarısı sebebiyle ReLU aktivasyonu, hızlı ve kararlı optimizasyon özellikleri sebebiyle de Adam algoritması tercih edilmiştir. Bu hiperparametreler ile modelin genelleme kapasitesini ve doğruluğunu artırmak amaçlanmıştır. YSA modeli, SDD tahmininde yüksek doğruluk sağlarken modelin genelleme yeteneği göl genelinde tahmin edilen değerlerin doğruluğunu artırmıştır.

5.3.3. Evrişimli sinir ağı modeli

RO modeli ile genişletilen veri setindeki spektral özellikler arasındaki örtük mekânsal ilişkilerin daha etkin bir şekilde öğrenilmesi ve tahmin performansının artırılması amacıyla ESA modeli kullanılmıştır. SDD değerleri modelin bağımlı değişkeniyken NDWI, B2 ve B3 değerleri bağımsız değişkenlerdir. ESA modelinde özelliklerin ölçeklendirilmesine gerek duyulduğundan tüm bağımsız değişkenler 0-1 aralığına ayarlanmıştır. Veri seti %80 eğitim ve %20 test veri seti olmak üzere ikiye ayrılmıştır. Toplam 6344 veri noktasından 5075'i eğitim veri seti ve 1269'u test veri seti olarak ayrılmıştır. ESA modeli için kullanılan bu veri seti modelle uyumlu olması için 2B matrise dönüştürülmüştür. Her veri örneği ESA giriş formatına uyum sağlaması için 5x5'lik uzamsal bloklara ayrılmıştır. İlk evrişim katmanında 32 filtre ve 3x3 çekirdek uygulanırken ikinci katmanda 64 filtre ve 3x3 çekirdek ile daha karmaşık özellikler öğrenilmiştir. Aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılırken karmaşık yapıları en etkili şekilde yakalamak üzere 3x3 ve 5x5 çekirdek yapılandırmaları tercih edilmiştir. 3x3 çekirdekler daha küçük ölçekli ayrıntıları yakalarken, 5x5 çekirdekler daha büyük ölçekteki desenlerin tespit edilmesine olanak tanımaktadır. ESA modeli kurulumunda farklı hiperparametre kombinasyonlarına yönelik yoğun testler gerçekleştirilerek en iyi performansı gösteren ayarlar ile model optimize edilmiştir. Model eğitiminde öğrenme oranı 0,001 olarak ayarlanırken maksimum dönem sınırı ise 100 olarak seçilmiştir. Modelin aşırı öğrenmesini önlemek amacıyla erken durdurma yöntemi uygulanarak herhangi bir performans iyileşmesi gözlenmediğinde modelin eğitimi durdurması sağlanmıştır. Kayıp fonksiyonu olarak MSE kullanılırken aşırı uyumu önlemek için farklı katmanlara %50'lik bırakma katmanları eklenmiştir. Eğitim

verilerinin çeşitliliğini artırmak için veri kümesine rastgele döndürme, gürültü ekleme ve yatay-dikey öteleme uygulanmıştır. Bu yöntemler ile veri kümesinin sınırlı boyutu hesaba katılarak modelin farklı veri dağılımlarını daha iyi genelleştirmesi sağlanmıştır. ESA modeli, SDD kestiriminde diğer modellere kıyasla üstün bir performans sergilemiştir. Özellikle mekânsal örüntüleri öğrenme konusundaki başarısı ile SDD tahminlerinde daha hassas sonuçlar üretilmesini sağlamıştır. ESA modeli ile elde edilen yüksek doğruluklu tahminler, göl alanının tamamını kapsayacak şekilde raster formatında dışa aktarılmış ve bu raster veriler kullanılarak SDD dağılımını ayrıntılı bir şekilde yansıtan tematik haritalar üretilmiştir. Çalışma kapsamında RO, YSA ve ESA modellerinin tümünde veri ön işleme, model eğitimi, doğruluk analizi ve tahmin üretim süreçlerini yönetmek üzere Python programlama dili ve gerekli kütüphaneler kullanılmıştır.

5.3.4. Doğrulukların değerlendirilmesi


Bu çalışmada, SDD parametresi için geliştirilen RO, YSA ve ESA modellerinin performans analizleri R^2 , RMSE ve MAE metrikleri ile değerlendirilmiştir. SDD parametresinin model performansları Tablo 5.3.'te gösterilmektedir.

Tablo 5.3. SDD parametresinin model performansları

Metrik	Veri Seti	RO	YSA	ESA
R^2	Eğitim	0,87	0,94	0,95
R^2	Test	0,85	0,91	0,92
RMSE (m)	Eğitim	0,07	0,05	0,04
RMSE (m)	Test	0,08	0,06	0,05
MAE (m)	Eğitim	0,07	0,03	0,03
MAE (m)	Test	0,09	0,04	0,04

RO modeli ile $R^2 = 0,87$ (eğitim) ve $R^2 = 0,85$ (test), RMSE = 0,07 (eğitim) ve RMSE = 0,08 (test), MAE = 0,07 (eğitim) ve MAE = 0,09 (test) doğruluk metrikleri hesaplanmıştır. Model, sınırlı sayıda ölçüm verisi ile genelleme yapabilme kabiliyetiyle SDD kestirimi için güçlü bir başlangıç noktası olmuştur. YSA modeli ile $R^2 = 0,94$ (eğitim) ve $R^2 = 0,91$ (test), RMSE = 0,05 (eğitim) ve RMSE = 0,06 (test), MAE = 0,03 (eğitim) ve MAE = 0,04 (test) doğruluk metrikleri hesaplanmıştır. YSA modeli, doğrusal


olmayan ilişkileri çözümleme kabiliyeti sayesinde performansı bir miktar iyileştirerek RO modeline kıyasla daha çok etkili olmuştur. ESA modeli ile $R^2 = 0,95$ (eğitim) ve $R^2 = 0,92$ (test), RMSE = 0,04 (eğitim) ve RMSE = 0,05 (test), MAE = 0,03 (eğitim) ve MAE = 0,04 (test) doğruluk metrikleri hesaplanmıştır. ESA modeli, mekânsal ilişkileri öğrenme kapasitesi sayesinde tüm modeller arasında en yüksek performansı göstererek SDD kestiriminde en başarılı yöntem olmuştur. Şekil 5.11.'de SDD parametresinin model bazlı dağılımı ve çizgisel grafikleri gösterilmektedir.



Şekil 5.11. SDD parametresinin model bazlı dağılımı ve çizgisel grafikleri

5.3.5. Tematik haritaların üretilmesi

SDD kestiriminde en yüksek tahmin doğruluğunu sağlayan ESA modeli kullanılarak uydu görüntüleriyle eş zamanlı tarihler için SDD tahminleri üretilmiştir. Python yazılım dili kullanılarak tahmin verileri raster formatında dışa aktarılmıştır. ArcGIS yazılımı ile raster görüntüler sınıflandırılarak Mogan Gölü'ndeki 8 farklı tarih için SDD dağılımını gösteren tematik haritalar üretilmiştir. Şekil 5.12.'de Mogan Gölü'ndeki SDD parametresinin mekânsal dağılımına ilişkin tematik haritalar gösterilmektedir.



Şekil 5.12. SDD parametresinin mekânsal dağılımına ilişkin tematik haritalar

Mogan Gölü'ndeki SDD değişiminin izlenmesi noktasında çalışma kapsamında üretilen tematik haritalar oldukça önemlidir. Tematik haritalar, SDD parametresinin gölün yüzey alanındaki dağılımını detaylı bir şekilde ortaya koymaktadır. ESA modeli ile elde edilen tahmin verileri, ÇŞİDB'den temin edilen ölçüm değerleri ile karşılaştırılmıştır. Tematik haritaların gerçek ölçüm değerleriyle uyumlu olduğu görülmüştür. Çalışma sonuçları, ESA modelinin SDD parametresini tahmin etmedeki başarısını ortaya koymaktadır.

Bu çalışmada Landsat-8 uydu görüntüleri kullanılarak geliştirilen ESA modelinin su kalitesi parametrelerinin kestiriminde yüksek doğruluk sağlaması, son yıllarda literatürde giderek artan biçimde vurgulanan uzaktan algılama tabanlı derin öğrenme algoritmalarının başarısı ile uyumlu sonuçlar ortaya koymaktadır. Özellikle su kalitesi izleme araştırmalarında sınırlı veri seti modellerin performansını doğrudan etkileyen temel bir kısıt olarak değerlendirilmektedir. Pu vd., (2019) tarafından Erhai ve Chaohu Gölleri'nde Landsat-8 görüntüleri kullanılarak geliştirilen hiyerarşik evrişimli sinir ağı modeli ve transfer öğrenme stratejisi, yerinde veri eksikliğinin giderilmesinde derin öğrenme yaklaşımlarının etkinliğini ortaya koymuştur. Bahse konu araştırmada modelin geleneksel makine öğrenme yöntemlerine kıyasla daha üstün performans göstermesi, çalışma kapsamında ESA modelleri ile elde edilen tahmin doğruluklarının literatürle tutarlı olduğunu göstermektedir. Benzer şekilde Yang vd., (2022) Baiyangdian Gölü'nde çoklu uydu verilerinin mekânsal-zamansal füzyonu ile yüksek çözünürlüklü görüntüler elde etmiş ve evrişimli sinir ağı tabanlı tersine çevirme modeli kullanarak klorofil-a tahmini gerçekleştirmiştir. Araştırmada ölçülen ve tahmin edilen klorofil-a değerleri arasında $R^2 = 0,80$ düzeyinde güçlü bir ilişki belirlenmesi, derin öğrenme modellerinin su kalitesi parametrelerinin uzaktan algılama verileri ile güvenilir biçimde tahmin edilebildiğini göstermektedir. Bu durum, uydu görüntülerine dayalı derin öğrenme modellerinin göl ekosistemlerinde mekânsal ve zamansal değişimlerin ortaya konulmasında etkin bir araç olduğunu desteklemektedir. Özellikle sınırlı örneklem büyüklüğüne rağmen yüksek doğruluk elde edilmesi, veri füzyonu ve derin öğrenme tabanlı model mimarilerinin sağladığı temsil gücü ile açıklanabilir. Literatürde hibrit derin öğrenme yaklaşımlarının da su kalitesi modellemesinde başarılı sonuçlar verdiği görülmektedir. Chellaiah vd., (2024) tarafından Kaveri Nehri boyunca geliştirilen evrişimli sinir ağı ve uzun kısa süreli bellek tabanlı hibrit modelin %98,40 doğruluk sağlaması, zamansal ve mekânsal dinamikleri birlikte değerlendiren derin öğrenme algoritmalarının klasik yöntemlere göre daha üstün performans gösterebildiğini ortaya koymaktadır. Bu bulgu, derin öğrenme mimarilerinin karmaşık ilişkileri öğrenebilme kapasitesinin yüksek olmasından kaynaklanmakta olup, su kalitesi parametrelerinin hidrolojik ve çevresel değişkenlerle olan çok boyutlu etkileşimini daha iyi temsil edebildiğini göstermektedir. Dolayısıyla, bu çalışma kapsamında kullanılan model yaklaşımı güncel literatürde önerilen metodolojik eğilimlerle örtüşmektedir. Genel olarak değerlendirildiğinde, literatürde ESA ve diğer derin öğrenme tabanlı modellerin su kalitesi parametrelerinin tahmininde geleneksel makine öğrenmesi ve istatistiksel

yöntemlere kıyasla daha yüksek doğruluk sağladığı görülmektedir. Bu çalışmada elde edilen model performansının söz konusu çalışmalarla paralellik göstermesi, uzaktan algılama tabanlı derin öğrenme yaklaşımlarının küçük ve orta ölçekli su kütlelerinde uygulanabilir ve güvenilir sonuçlar üretebildiğini ortaya koymaktadır.

5.4. Kestirilen Su Kalitesi Parametrelerinin İstatistiksel Analizi

Bu bölümde, modeller ile kestirilen su kalitesi parametrelerine yönelik geliştirilen istatistiksel analizlerle tematik haritalar ile sunulan mekânsal desenlerin piksel bazlı dağılımları, zamansal eğilimleri ve parametreler arası ilişkileri derinlemesine analiz edilmiştir. Bu kapsamda, her bir tarih için tematik haritaları oluşturan 6344 piksel üzerinden gerçekleştirilen analizler ile model çıktılarının korelasyonu ve tutarlılığı test edilmiştir.


5.4.1. Standart sapma ve ortalama değerler analizi

Kestirilen su kalitesi parametrelerine ait ortalama ve standart sapma değerleri hesaplanarak göl genelindeki mekânsal değişkenlikler ve temel büyüklük seviyeleri analiz edilmiştir. Ortalama değerler parametrelerin su kütlesindeki genel durumunu temsil ederken, standart sapmalar uygulama alanı içerisindeki dağılımlarını mekânsal ölçekte ortaya koymaktadır. Tablo 5.4.'te CHL-A, AKM ve SDD parametrelerine ait standart sapma ve ortalama değerler sunulmaktadır.

Tablo 5.4. Standart sapma ve ortalama değerler analizi

Tarih	CHL-A (Ortalama) (µg/L)	CHL-A (Standart Sapma)	AKM (Ortalama) (mg/L)	AKM (Standart Sapma)	SDD (Ortalama) (m)	SDD (Standart Sapma)
18.04.2018	0,63	0,10	12,54	1,11	0,73	0,14
23.07.2018	1,14	0,21	9,14	0,74	0,89	0,22
27.10.2018	1,53	0,60	12,37	1,80	0,62	0,22
31.07.2021	1,46	0,17	9,40	0,66	0,44	0,23
16.08.2021	2,05	0,60	11,41	2,02	0,54	0,21
17.09.2021	2,08	0,48	12,08	1,29	0,79	0,14
05.07.2023	1,75	0,40	11,19	0,94	0,58	0,18
08.08.2024	2,31	0,58	10,44	1,30	0,61	0,21

CHL-A parametresi için standart sapma değerleri 0,10-0,60 aralığında değişmektedir. Bazı tarihlerde yüksek standart sapma değerlerinin elde edilmesi, göl içerisindeki fitoplankton dağılımının mekânsal olarak homojen olmadığını göstermektedir. AKM parametresi için standart sapma değerleri 0,66-2,02 aralığında değişmektedir. Dönemsel olarak artış gösteren AKM konsantrasyonunun göl genelinde farklı kaynak ya da hidrodinamik süreçlerden etkilendiği düşünülmektedir. SDD parametresi için ise standart sapma değerleri 0,14-0,23 aralığında değişmektedir. Çoğu tarihte daha sınırlı standart sapma değerleri sergilemesiyle su berraklığının göl genelinde daha dengeli dağıldığını göstermektedir. Her bir su kalitesi parametresine yönelik hesaplanan ortalama değerler kullanılarak yıllar arasındaki eğilimleri karşılaştırmalı olarak değerlendirmek üzere zamansal değişim grafikleri üretilmiştir. Şekil 5.13.'te ortalama değerlerin zamansal analizi gösterilmektedir.



Şekil 5.13. Ortalama değerlerin zamansal analizi


Ortalama değerler hesabı ve zamansal analizi ile göl ekosisteminin uzun dönemli davranışını ortaya koymak amaçlanmıştır. 2018-2019 yılları arasındaki kırılımda CHL-A konsantrasyonları belirgin düzeyde artarken SDD azalma eğilimindedir. AKM konsantrasyonları ise önce azalma sonrasında ise artış göstermiştir. Bu dönemde göl suyu berraklığının azaldığı anlaşılmaktadır. 2021-2022 yılları arasındaki kırılımda üç parametre de birlikte artış göstermiştir. Bu dönem hem biyolojik hem de fiziksel parametrelerde belirgin değişimin yaşandığı bir kırılım noktasıdır. 2023-2024 yılları arasındaki kırılımda ise CHL-A yükselmiş, AKM azalmış ve SDD ise büyük ölçüde sabit kalmıştır. Bu dönemde sediment etkisinden ziyade biyolojik üretimin ön plana çıktığı anlaşılmaktadır. Zamansal analiz sonuçları, CHL-A değerlerinde yıllara göre belirgin bir artış eğiliminin olduğunu göstermektedir. Bu durum, gölde fitoplankton üretiminin zaman içerisinde güçlendiğini düşündürmektedir. AKM parametresinde ise bazı dönemlerde CHL-A ile paralel artışlar gözlenirken, bazı dönemlerde ise ters hareketler meydana gelmiştir. SDD değerleri ise zamansal açıdan daha durağan bir yapı sergilemekte ve yıllara göre büyük değişimler göstermemektedir.

5.4.2. Piksel bazlı dağılım ve korelasyon analizi

Parametreler arasındaki ilişkilerin ortaya konulması amacıyla her bir çalışma tarihi için Pearson Korelasyon Katsayıları (r) hesaplanmıştır. Parametreler arasındaki korelasyon durumu ile tematik haritalar ile elde edilen mekânsal desenlerin ve parametreler arası ilişkinin derinlemesine analiz edilmesi amaçlanmıştır. Piksel bazında gerçekleştirilen korelasyon analizi, noktasal ölçülerle sınırlı kalmayıp göl alanının tamamını kapsayan ayrıntılı bir değerlendirme imkânı sunmaktadır. Bu kapsamda, belirli bölümlerde öne çıkan yüksek ya da düşük korelasyon katsayıları, tematik haritalarda gözlenen mekânsal örüntülerle ne ölçüde örtüştüğünü analiz etmek üzere incelenmiştir. Elde edilen piksel bazlı korelasyon analizi sonuçları Tablo 5.5.'te sunulmakta olup, parametreler arasındaki ilişkileri görsel olarak yansıtan korelasyon ısı haritası Şekil 5.14'te verilmiştir.

Tablo 5.5. Piksel bazlı korelasyon analizi sonuçları


Tarih	r(CHL-A, AKM)	r(CHL-A, SDD)	r(AKM, SDD)	Piksel sayısı
18.04.2018	-0,42	0,24	-0,73	6344
23.07.2018	0,12	-0,17	-0,22	6344
27.10.2018	0,78	-0,65	-0,78	6344
31.07.2021	0,34	-0,77	-0,33	6344
16.08.2021	0,92	-0,24	-0,08	6344
17.09.2021	0,79	-0,63	-0,57	6344
05.07.2023	0,46	-0,63	-0,72	6344
08.08.2024	0,71	-0,55	-0,29	6344

**Şekil 5.14.** Parametrelere ait korelasyon ısı haritası

Korelasyon analizi sonuçlarına göre, genel anlamda CHL-A ile AKM arasında pozitif, CHL-A ile SDD arasında negatif ve AKM ile SDD arasında negatif korelasyonlar gözlenmektedir. Bu sonuçlar, gölde artan biyolojik üretim ve sediment yükünün ışık geçirgenliğini azaltarak su berraklığını düşürdüğünü göstermektedir. Korelasyon ısı haritası, parametreler arasındaki bu ilişkilerin farklı tarihlerde genel olarak tutarlı olduğunu göstermekte ve istatistiksel sonuçların mekânsal gözlemlerle uyumlu olduğunu doğrulamaktadır.

Su kalitesi parametreleri arasındaki ikili ilişkileri derinlemesine analiz etmek üzere tüm pikseller dikkate alınarak dağılım grafikleri üretilmiştir. Bu yaklaşım, parametreler arasındaki ilişkilerin özet istatistikler ya da ortalama değerler üzerinden

değerlendirilmesiyle sınırlı kalmayıp her bir pikselin temsil ettiği mekânsal bilgiyi de analiz sürecine dahil etmektedir. Şekil 5.15.'te piksel bazlı dağılım grafikleri gösterilmektedir.




Şekil 5.15. Piksel bazlı dağılım analizi

Dağılım analizleri sonucunda, CHL-A ve AKM parametreleri tüm tarihlerde benzer kümelenme sergileyerek belirgin bir pozitif ilişki göstermektedir. Bu durum, fitoplankton artışına paralel bir şekilde AKM miktarının da yükseldiğini göstermektedir. Buna karşılık, SDD ile diğer parametreler arasındaki ilişkilerde belirgin negatif eğilimler

gözlenmektedir. Yüksek biyolojik üretim ve partikül yükünün su berraklığının azalmasına neden olduğu anlaşılmaktadır. 3B dağılım grafikleri ise üç parametrenin dinamik olarak birbirine bağlı olduğunu ve yüksek CHL-A ve AKM değerlerinin çoğunlukla düşük SDD değerleri ile görüldüğünü göstermiştir.

5.4.3. Dağılım özellikleri ve değişkenlik analizi


Su kalitesi parametrelerinin her bir tarihteki dağılım aralıkları, medyan değerleri ve uç değerlerini analiz etmek üzere kutu grafikler üretilmiştir. Bu grafikler, göl genelindeki heterojenliğini görsel açıdan değerlendirmeye olanak tanımaktadır. Şekil 5.16.'da kutu grafiklerinin karşılaştırmalı analizi gösterilmektedir.




Şekil 5.16. Kutu grafiklerinin karşılaştırmalı analizi

Su kalitesi parametrelerine yönelik üretilen kutu grafikler analiz edildiğinde CHL-A ve AKM parametrelerinde bazı dönemlerde dağılım aralığının genişlediği ve uç değerlerin arttığı görülmektedir. Bu durum, bu dönemlerde göldeki CHL-A ve AKM konsantrasyonunun mekânsal ölçekte homojen olmayan bir yapıda dağılım gösterdiğine işaret etmektedir. Özellikle, belirli alanlarda lokal ölçekte yoğun bir biyolojik üretim ya da artan sediment birikiminin meydana geldiği anlaşılmaktadır. CHL-A parametresi için fitoplankton yoğunluğunun zamansal ve mekânsal ölçekte farklılık gösterdiğini, AKM parametresi için ise partikül miktarının değişkenlik gösterebildiğini düşündürmektedir. SDD parametresine ait kutu grafikleri analiz edildiğinde, diğer iki parametreye kıyasla daha dar bir dağılım aralığının hakim olduğu ve uç değerlerin sınırlı olduğu görülmektedir. Bu durum, SDD parametresinin göl genelinde daha dengeli ve istikrarlı bir şekilde dağılım gösterdiğini ortaya koymaktadır. Kutu grafikler ile tüm parametreler için elde edilen bulgular analiz edildiğinde tematik haritalar ile elde edilen sonuçların kutu grafikler ile desteklendiği ve uyumlu olduğu anlaşılmaktadır.


Parametrelerin su kütlesindeki dağılım karakteristiklerini derinlemesine analiz etmek üzere, ortalama ve dağılım ölçütlerini temsil eden grafiklere ek olarak histogram grafikleri de üretilmiştir. Histogramlar, su kalitesi parametrelerinin göl genelinde kapsadığı değer aralıklarını ve bu değerlere karşılık gelen piksel yoğunluklarını inceleme imkânı sunmaktadır. Bu yaklaşım ile parametrelerin belirli bir değer aralığında yoğunlaşıp yoğunlaşmadığı ya da göl genelinde heterojen ya da homojen bir dağılım gösterip göstermediği hususları daha açık bir şekilde değerlendirilebilmektedir. Özellikle piksel bazlı frekans dağılımlarının incelenmesi uzaktan algılama temelli tematik haritaların istatistiksel olarak desteklenmesine imkân tanımaktadır. Bu doğrultuda oluşturulan histogram grafikleri ile tematik haritalar ve çizgisel grafiklerden elde edilen bulguların daha kapsamlı bir şekilde ele alınması sağlanmıştır. Histogramlar ile elde edilen frekans temelli bakış açısı, ortalama değerlere dayalı değerlendirmelerin ötesine geçerek parametrelerin dağılımındaki asimetrik durumların, yoğunlaşma eğilimlerinin ya da yayılım durumunun daha net bir biçimde ortaya konulmasına olanak tanımaktadır. Mekânsal dağılımı görsel ölçekte yansıtan tematik haritalar ile istatistiksel eğilimleri yansıtan grafiklere ek olarak piksel bazlı frekans bilgileri sunan histogram grafikleri ile çok boyutlu bir bakış açısı ile dağılımın ele alınması amaçlanmıştır. CHL-A, AKM ve SDD parametrelerine ait histogram grafikleri sırasıyla Şekil 5.17, Şekil 5.18. ve Şekil 5.19'da sunulmaktadır.



Şekil 5.17. CHL-A parametresine ait histogram grafikleri



Şekil 5.18. AKM parametresine ait histogram grafikleri



Şekil 5.19. SDD parametresine ait histogram grafikleri

CHL-A histogramlarına göz atıldığında fitoplankton yoğunluğunun belirli aralıklarda yoğunlaştığı, ancak bazı dönemlerde dağılımın genişlediği anlaşılmaktadır. AKM histogramları çoğu tarihte tek tepe yapısı ile homojen bir dağılım sergilerken, bazı tarihlerde görülen iki tepe gölün belirli bölgelerinde sediment heterojenliğinin arttığını göstermektedir. SDD histogramları ise tüm tarihlerde genel olarak düşük seviyelerde yoğunlaşmakta, bu da gölün çoğunlukla düşük berraklığa sahip olduğunu göstermektedir.

6. SONUÇLAR VE ÖNERİLER

İklim değişikliğinin olumsuz etkileri, hızlı nüfus artışı ve buna bağlı hızla gelişen endüstriyel faaliyetler doğal su kaynaklarını hedef almakta ve su kalitesini çarpıcı bir şekilde düşürmektedir. Geleneksel su kalitesi izleme tekniklerinin mekânsal ve zamansal ölçekte sınırlı kalması ve yüksek maliyetleri ile yoğun iş gücü gerektirmesi su kalitesinin analizinde yeni çözüm arayışlarını kaçınılmaz kılmıştır. Nitekim, uzaktan algılama ve uydu teknolojilerindeki yenilikler su kalitesinin analizinde eşsiz bir fırsat sunmaktadır. Uzaktan algılama, su kalitesi konsantrasyonlarının düşük maliyetli ve yüksek doğruluklu bir şekilde izlenmesi, mekânsal olarak modellenmesi noktasında güvenilir ve etkili bir teknik olarak öne çıkmaktadır.

Bu çalışmada, Mogan Gölü'ndeki su kalitesini izlemek için Landsat-8 uydu görüntüleri ile makine ve derin öğrenme teknikleri entegre bir şekilde kullanılarak CHL-A, AKM ve SDD parametreleri kestirilmiştir. Araştırma kapsamında, uydu görüntüleri ile su kalitesi parametreleri arasındaki ilişkiyi test etmek üzere RO, YSA ve ESA modelleri geliştirilmiş ve saha ölçüm verileri kullanılarak uzaktan algılama teknikleriyle su kalitesi konsantrasyonları başarılı bir şekilde kestirilmiştir. Su kalitesi parametrelerine yönelik saha ölçüm verileri ÇŞİDB'den temin edilmiştir. Uydu görüntülerinin bant değerleri ve spektral indeksler hesaplanarak RO algoritması kullanılarak su kalitesi parametreleri ile olan ilişki test edilmiştir. Her üç su kalitesi parametresi için de RO modeli kullanılarak veri seti kontrollü bir şekilde genişletilmiştir. Genişletilen veri seti, YSA ve ESA modelleri için girdi verisi olarak kullanılarak su kalitesi parametrelerine yönelik daha derin modeller geliştirilmiştir.

RO modeli ile, CHL-A parametresi için $R^2 = 0,84$, AKM parametresi için $R^2 = 0,81$ ve SDD parametresi için ise $R^2 = 0,85$ hesaplanmıştır. Model, $0,81 \leq R^2 \leq 0,85$ aralığında sağladığı determinasyon katsayısı ile su kalitesi parametreleri için yüksek korelasyon göstermiş ve sınırlı sayıda ölçüm verisi ile genelleme yapabilme kabiliyeti sayesinde güçlü bir başlangıç noktası olmuştur.

YSA modeli ile, CHL-A parametresi için $R^2 = 0,85$, AKM parametresi için $R^2 = 0,90$ ve SDD parametresi için ise $R^2 = 0,91$ hesaplanmıştır. Model, $0,85 \leq R^2 \leq 0,91$ aralığında sağladığı determinasyon katsayısı ile su kalitesi parametreleri için yüksek korelasyon göstermiş ve doğrusal olmayan ilişkileri çözümleme kabiliyeti sayesinde performansı bir miktar iyileştirmiştir.

ESA modeli ile, CHL-A parametresi için $R^2 = 0,92$, AKM parametresi için $R^2 = 0,97$ ve SDD parametresi için ise $R^2 = 0,92$ hesaplanmıştır. Model, $0,92 \leq R^2 \leq 0,97$ aralığında sağladığı determinasyon katsayısı ile su kalitesi parametreleri için yüksek korelasyon göstermiş ve mekânsal ilişkileri öğrenme kapasitesi sayesinde su kalitesi parametrelerinin kestiriminde en yüksek performansı gösteren yöntem olmuştur. ESA modeli kullanılarak Mogan Gölü'nün su kalitesi parametreleri ile ilişkili tematik haritaları üretilmiştir.

Araştırma kapsamında hesaplanan determinasyon katsayıları (R^2), tüm modellerin yüksek düzeyde korelasyon sağladığını göstermektedir. Doğruluk analizleri incelendiğinde, su kalitesi parametrelerinin tamamında ESA modelinin, RO ve YSA modellerine kıyasla daha yüksek tahmin doğruluğu gösterdiği tespit edilmiştir. Landsat-8 uydu görüntülerinden temin edilen bant değerleri ve hesaplanan spektral indekslerin, ESA modeli ile birlikte kullanıldığında en başarılı sonuçları verdiği anlaşılmaktadır. Kestirim modellerinin performans ölçütü yalnızca doğruluk metrikleri ile değil aynı zamanda istatistiksel analizler ile gerçekleştirilmiştir. Üretilen tematik haritalar ile sunulan mekânsal desenlerin piksel bazlı dağılımları, zamansal eğilimleri ve parametreler arası korelasyon derinlemesine analiz edilmiştir. Elde edilen bulgular, su kalitesi parametrelerinin göl genelindeki mekânsal ve zamansal dağılımının tutarlılığını ve piksel bazlı gerçekleştirilen istatistiksel analizlerin tematik haritalar ile uyumunu göstermiştir.

Su kalitesi parametreleri, çalışma yapılan tarihlerdeki meteorolojik etkenler ve uygulama alanına taşınım yoluyla dahil olabilecek kaynaklardan etkilenebilmektedir. Bu sebeple, Mogan Gölü'nde gözlenen olası meteorolojik anomalileri analiz etmek üzere çalışma tarihleri için sıcaklık, yağış, rüzgâr ve toz taşınımı durumları ele alınmıştır. Meteorolojik değerlendirmeler neticesinde, çalışma tarihleri için Mogan Gölü üzerinde doğrudan etkili herhangi bir meteorolojik anomali bulunmadığı tespit edilmiştir. Mogan Gölü ve çevresi lokasyonu itibarıyla Kuzey Afrika üzerinden gelebilecek toz taşınımına maruz kalabilmektedir. Toz taşınım haritaları incelendiğinde, çalışma tarihlerinde Mogan Gölü ve çevresinde toz yoğunluğunun düşük seviyelerde olduğu dolayısıyla su kalitesi parametrelerine etki edebilecek seviyede kayda değer bir toz taşınımı bulunmadığı gözlenmiştir.

Bu çalışma kapsamında elde edilen bulgular, Landsat-8 uydu görüntüleri ve derin öğrenme tekniklerinin entegrasyonuna dayalı geliştirilen model yaklaşımının, su kalitesi parametrelerinin kestirimi ve mekânsal modellenmesi açısından güvenilir, tutarlı ve uygulanabilir sonuçlar sunduğunu göstermektedir. Model sonuçlarının yüksek doğruluk

düzeyi, önerilen yöntemin hızlı ve düşük maliyetli bir izleme alternatifi sağladığını ortaya koymaktadır. Bu bağlamda geliştirilen yöntem, göl ekosistemlerinin sürdürülebilir yönetimi, düzenli su kalitesi izleme çalışmaları ve karar destek süreçleri için bilimsel açıdan güçlü ve uygulanabilir bir modelleme çerçevesi sunmaktadır.

Mogan Gölü, 90/1117 sayılı Bakanlar Kurulu kararı ile ilan ve tespit edilen GÖÇKB içerisinde kalmaktadır. Türkiye için stratejik bir öneme sahip olan gölün korunması ve düzenli olarak izlenmesi oldukça önemlidir. Göl ve çevresi, ekolojik çeşitliliği, endemik türleri ve rekreasyon alanları ile dikkat çekmektedir. Göl ve çevresi için gerçekleştirilecek erken uyarı sistemleri ile göl suyu kalitesine yönelik daha kapsamlı izleme çalışmaları yürütülerek olumsuz gelişmelerin uyarılması ve zamanında önlem alınması sağlanabilir. Gelecekte yürütülecek izleme çalışmalarında, daha fazla sayıda düzenli ve eş zamanlı ölçüm verileri ile desteklenen uzaktan algılama verilerinin derin öğrenme teknikleri ile entegre edilmesi sayesinde, su kalitesine yönelik izleme süreçlerinin daha sistematik, sürekli ve yüksek doğrulukta gerçekleştirilebileceği değerlendirilmektedir.

KAYNAKLAR

- Adusei, Y. Y., Quaye-Ballard, J., Adjaottor, A. A., ve Mensah, A. A. (2021). Spatial prediction and mapping of water quality of Owabi Reservoir from satellite imageries and machine learning models. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 825–833. <https://doi.org/10.1016/j.ejrs.2021.06.006>
- Aggarwal, C. C. (2018). *Neural networks and deep learning: A textbook* (1st ed.). Springer International Publishing.
- Ahmed, M., Mumtaz, R., Anwar, Z., Shaukat, A., Arif, O., ve Shafait, F. (2022). A multi-step approach for optically active and inactive water quality parameter estimation using deep learning and remote sensing. *Water*, 14, 2112. <https://doi.org/10.3390/w14132112>
- Ahmed, W., Mohammed, S., El-Shazly, A., ve Morsy, S. (2023). Tigris River water surface quality monitoring using remote sensing data and GIS techniques. *The Egyptian Journal of Remote Sensing and Space Sciences*, 26(3), 816–825. <https://doi.org/10.1016/j.ejrs.2023.09.001>
- Akar, Ö., Güngör, O., ve Akar, A. (2010). Rastgele orman sınıflandırıcısı ile arazi kullanım alanlarının belirlenmesi. *III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu* (ss. 142–152). Kocaeli, Türkiye.
- Akgün, M. (2023). Uzaktan algılama ile klorofil-a izlenmesi üzerine bir çalışma. *JSAT*, 1, 41–47. <https://doi.org/10.5281/zenodo.8074879>
- Alcamo, J. (2019). Water quality and its interlinkages with the Sustainable Development Goals. *Current Opinion in Environmental Sustainability*, 36, 126–140. <https://doi.org/10.1016/j.cosust.2018.11.005>
- Ali, A. M., Darvishzadeh, R., ve Skidmore, A. K. (2017). Retrieval of specific leaf area from Landsat-8 surface reflectance data using statistical and physical models. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8), 3529–3536. <https://doi.org/10.1109/JSTARS.2017.2690623>
- Ali, A., Zhou, G., Antezana Lopez, F. P., Xu, C., Jing, G., ve Tan, Y. (2024). Deep learning for water quality multivariate assessment in inland water across China. *International Journal of Applied Earth Observation and Geoinformation*, 133, 104078. <https://doi.org/10.1016/j.jag.2024.104078>
- Alikas, K., ve Kratzer, S. (2017). Improved retrieval of Secchi depth for optically-complex waters using remote sensing data. *Ecological Indicators*, 77, 218–227.
- Amieva, J. F., Oxoli, D., ve Brovelli, M. A. (2023). Machine and deep learning regression of chlorophyll-a concentrations in lakes using PRISMA satellite hyperspectral imagery. *Remote Sensing*, 15(22), 5385. <https://doi.org/10.3390/rs15225385>
- Anderson, D., ve McNeill, G. (1992). *Artificial neural networks technology*. Rome Laboratory.

- Arias-Rodriguez, L. F., Duan, Z., Díaz-Torres, J. J., Basilio Hazas, M., Huang, J., Kumar, B. U., Tuo, Y., ve Disse, M. (2021). Integration of remote sensing and Mexican water quality monitoring system using an extreme learning machine. *Sensors*, 21(12), 4118. <https://doi.org/10.3390/s21124118>
- Arslan, O. (2001). *Görüntü sınıflandırması için yapay sinir ağlarının analiz ve optimizasyonu* [Doktora tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü].
- Atasever, Ü. H., ve Abbas, H. H. (2024). Drought monitoring in Burdur Lake using Sentinel-2 images. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(3), 882–891. <https://doi.org/10.28948/ngumuh.1411803>
- Aydın, M. (2022). *Sahte internet sitelerinin URL özellikleri temelinde tespit edilmesi amacıyla özellik seçme metotlarının ve öğrenme algoritmalarının analizi* [Doktora tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü].
- Batina, A., ve Krtalić, A. (2023). A review of remote sensing applications for determining lake water quality. *Preprints*. <https://doi.org/10.20944/preprints202309.0489.v1>
- Batur, E., ve Maktav, D. (2019). Assessment of surface water quality by using satellite images fusion based on PCA method in the Lake Gala, Turkey. *IEEE Transactions on Geoscience and Remote Sensing*, 57(5), 2983–2989. <https://doi.org/10.1109/TGRS.2018.2879024>
- Belgiu, M., ve Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31.
- Bertone, E., Ajmar, A., Tonolo, F. G., Dunn, R. J. K., Dorian, N. J. C., Bennett, W. W., ve Purandare, J. (2024). Satellite-based estimation of total suspended solids and chlorophyll-a concentrations for the Gold Coast Broadwater, Australia. *Marine Pollution Bulletin*, 201, 116217. <https://doi.org/10.1016/j.marpolbul.2024.116217>
- Bianchi, T. S., ve Allison, M. A. (2009). Large-river delta-front estuaries as natural “recorders” of global environmental change. *Proceedings of the National Academy of Sciences of the United States of America*, 106, 8085–8092.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Britto, F. B., do Vasco, A. N., Aguiar Netto, A. D. O., Garcia, C. A. B., Moraes, G. F. O., ve Silva, M. G. D. (2018). Surface water quality assessment of the main tributaries in the lower São Francisco River, Sergipe. *Revista Brasileira de Recursos Hídricos*, 23, 6–23. <https://doi.org/10.1590/2318-0331.231820170061>
- Budakoti, S., & Pal, M. (2025). Prediction of chlorophyll-a concentration and analysis of its relationship with environmental factors in Lake Vänern using the random forest algorithm. *Limnology*. <https://doi.org/10.1007/s10201-025-00822-8>

- Bygate, M., ve Ahmed, M. (2024). Monitoring water quality indicators over Matagorda Bay, Texas, using Landsat-8. *Remote Sensing*, 16(7), 1120. <https://doi.org/10.3390/rs16071120>
- Caballero, I., ve Navarro, G. (2021). Monitoring cyanoHABs and water quality in Laguna Lake (Philippines) with Sentinel-2 satellites during the 2020 Pacific typhoon season. *Science of the Total Environment*, 788, 147700. <https://doi.org/10.1016/j.scitotenv.2021.147700>
- Cen, H., Jiang, J., Han, G., Lin, X., Liu, Y., Jia, X., Ji, Q., ve Li, B. (2022). Applying deep learning in the prediction of chlorophyll-a in the East China Sea. *Remote Sensing*, 14(21), 5461. <https://doi.org/10.3390/rs14215461>
- Chellaiah, C., Anbalagan, S., Swaminathan, D., Chowdhury, S., Kadhila, T., Shopati, A. K., Shangdiar, S., Sharma, B., ve Amesho, K. T. T. (2024). Integrating deep learning techniques for effective river water quality monitoring and management. *Journal of Environmental Management*, 370, 122477. <https://doi.org/10.1016/j.jenvman.2024.122477>
- Chen, P., Wang, B., Wu, Y., Wang, Q., Huang, Z., ve Wang, C. (2023). Urban river water quality monitoring based on self-optimizing machine learning method using multi-source remote sensing data. *Ecological Indicators*, 146, 109750. <https://doi.org/10.1016/j.ecolind.2022.109750>
- Chicco, D., Warrens, M. J., ve Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Chu, H.-J., He, Y.-C., Chusnah, W. N., Jaelani, L. M., ve Chang, C.-H. (2021). Multi-reservoir water quality mapping from remote sensing using spatial regression. *Sustainability*, 13(11), 6416. <https://doi.org/10.3390/su13116416>
- Cutler, A., Cutler, D. R., ve Stevens, J. R. (2011). Random forests. In *Ensemble machine learning* (pp. 157–175). Springer. https://doi.org/10.1007/978-1-4419-9326-7_5
- Çakır, F. S. (2018). *Matlab kodları ve Matlab toolbox çözümleri*. Nobel Yayıncılık.
- Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (ÇŞİDB). (2015). *Gölbaşı özel çevre koruma bölgesi yönetim planı*. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Tabiat Varlıklarını Koruma Genel Müdürlüğü, Ankara.
- Çıtakoğlu, H., ve Özeren, Y. (2021). Sakarya Havzası su kalitesi parametrelerinin yapay sinir ağları ile modellenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 10–17. <https://doi.org/10.31590/ejosat.898046>
- Datt, B. (1998). Remote sensing of chlorophyll a, chlorophyll b, chlorophyll a + b, and total carotenoid content in eucalyptus leaves. *Remote Sensing of Environment*, 66(2), 111–121. [https://doi.org/10.1016/S0034-4257\(98\)00046-7](https://doi.org/10.1016/S0034-4257(98)00046-7)
- Dent, B. D., Torguson, J. S., & Hodler, T. W. (2009). *Cartography: Thematic map design*. McGraw-Hill.

- Devi, P. D., ve Mamatha, G. (2024). Machine learning approach to predict the turbidity of Saki Lake, Telangana, India, using remote sensing data. *Measurement: Sensors*, 33, 101139. <https://doi.org/10.1016/j.measen.2024.101139>
- Dumoulin, V., ve Visin, F. (2016). *A guide to convolution arithmetic for deep learning*. <https://doi.org/10.48550/arXiv.1603.07285>
- Duran, C. (2007). Uzaktan algılama teknikleri ile bitki örtüsü analizi. *Doğu Akdeniz Ormancılık Araştırma Müdürlüğü DOA Dergisi*, (3), 45–67.
- Ehteram, M., Ahmed, A. N., Sherif, M., ve El-Shafie, A. (2024). An advanced deep learning model for predicting water quality index. *Ecological Indicators*, 160, 111806. <https://doi.org/10.1016/j.ecolind.2024.111806>
- Ekercin, S. (2007). Water quality retrievals from high resolution IKONOS multispectral imagery: A case study in Istanbul, Turkey. *Water, Air, & Soil Pollution*, 183, 239–251. <https://doi.org/10.1007/s11270-007-9373-5>
- Elias, L. S., Zimale, F. A., Sultan, D., Enku, T., ve Tilahun, S. A. (2024). Advancing non-optical water quality monitoring in Lake Tana, Ethiopia: Insights from machine learning and remote sensing techniques. *Frontiers in Water*, 6, 1432280. <https://doi.org/10.3389/frwa.2024.1432280>
- Estes, L., Elsen, P. R., Treuer, T., Ahmed, L., Caylor, K., Chang, J., Choi, J. J., ve Ellis, E. C. (2018). The spatial and temporal domains of modern ecology. *Nature Ecology & Evolution*, 2, 819–826.
- Filazzola, A., Mahdiyan, O., Shuvo, A., Ewins, C., Moslenko, L., Sadid, T., Blaggrave, K., Imrit, M. A., Gray, D. K., Quinlan, R., O'Reilly, C. M., ve Sharma, S. (2020). A database of chlorophyll and water chemistry in freshwater lakes. *Scientific Data*, 7, 1–10. <https://doi.org/10.1038/s41597-020-00648-2>
- Flores-Anderson, A. I., Griffin, R., Dix, M., Romero-Oliva, C. S., Ochaeta, G., Skinner-Alvarado, J., Ramirez Moran, M. V., Hernandez, B., Cherrington, E., Page, B., ve Barreno, F. (2020). Hyperspectral satellite remote sensing of water quality in Lake Atitlán, Guatemala. *Frontiers in Environmental Science*, 8. <https://doi.org/10.3389/fenvs.2020.00007>
- Fu, Y., Xu, S., Zhang, C., ve Sun, Y. (2018). Spatial downscaling of MODIS chlorophyll-a using Landsat 8 images for complex coastal water monitoring. *Estuarine, Coastal and Shelf Science*, 209, 149–159. <https://doi.org/10.1016/j.ecss.2018.05.031>
- Gao, B.-C. (1996). Normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266.
- Gholizadeh, M. H., Melesse, A. M., ve Reddi, L. (2016). A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors (Switzerland)*, 16. <https://doi.org/10.3390/s16081298>
- Goodfellow, I., Bengio, Y., ve Courville, A. (2016). *Deep learning* (Vol. 1). MIT Press.

- Gower, J., King, S., Borstad, G., ve Brown, L. (2005). Detection of intense plankton blooms using the 709 nm band of the MERIS imaging spectrometer. *International Journal of Remote Sensing*, 26(9), 2005–2012. <https://doi.org/10.1080/01431160500075857>
- Guo, H., Tian, S., Huang, J. J., Zhu, X., Wang, B., ve Zhang, Z. (2022). Performance of deep learning in mapping water quality of Lake Simcoe with long-term Landsat archive. *ISPRS Journal of Photogrammetry and Remote Sensing*, 183, 451–469. <https://doi.org/10.1016/j.isprsjprs.2021.11.023>
- Gündüz, A., ve Orman, Z. (2024). Evrişimli sinir ağı ile uzaktan algılamada hiperspektral görüntülerin sınıflandırılması. *Türk Uzaktan Algılama ve CBS Dergisi*, 5(1), 28–40. <https://doi.org/10.48123/rsgis.1344194>
- Gürbüz, Ö., ve Yılmaz, T. (2023). Evrişimli sinir ağları kullanarak yüz belirleme ve tanıma uygulaması. *Journal of Investigations on Engineering and Technology*, 6(2), 45–60.
- Huiqun, M., ve Ling, L. (2008). Water quality assessment using artificial neural network. *2008 International Conference on Computer Science and Software Engineering* (ss. 13–15). Wuhan, Çin. <https://doi.org/10.1109/CSSE.2008.411>
- Huo, Y., Zhao, S., Yuan, Z., Wang, X., ve Wang, L. (2025). Hue angle-based remote sensing of Secchi disk depth using Sentinel-3 OLCI in the coastal waters of Qinhuangdao, China. *Journal of Marine Science and Engineering*, 13(6), 1149. <https://doi.org/10.3390/jmse13061149>
- İnik, Ö., ve Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104.
- Janssen, L. L. F., Huurneman, G. C., Bakker, W. H., Reeves, C. V., Gorte, B. G. H., Pohl, C., Weir, M. J. C., Horn, J. A., Prakash, A., ve Woldai, T. (2001). *Principles of remote sensing: An introductory textbook* (ITC Educational Textbook Series, Vol. 2). International Institute for Geo-Information Science and Earth Observation.
- Jayalakshmi, T., ve Santhakumaran, A. (2011). Statistical normalization and back propagation for classification. *International Journal of Computer Theory and Engineering*, 3(1), 89–93. <https://doi.org/10.7763/IJCTE.2011.V3.288>
- Johnson, R. W., ve Harriss, R. C. (1980). Remote sensing for water quality and biological measurements in coastal waters. *Photogrammetric Engineering and Remote Sensing*, 46(1), 77–85.
- Kallio, K. (2000). Remote sensing as a tool for monitoring lake water quality. In P. Heinonen, G. Ziglio, ve A. Van Der Beken (Ed.), *Water quality measurements series*. <https://doi.org/10.1002/9780470511121.ch20>
- Kang, X., Song, B., ve Sun, F. (2019). A deep similarity metric method based on incomplete data for traffic anomaly detection in IoT. *Applied Sciences*, 9, 135. <https://doi.org/10.3390/app9010135>

- Karakoç, O., ve Buğdaycı, İ. (2025). Spatial modeling of chlorophyll-a parameter by Landsat-8 satellite data and deep learning techniques: The case of Lake Mogan. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 14(2), 615–629. <https://doi.org/10.28948/ngumuh.1603421>
- Kavurmacı, M., Ekercin, S., ve Altaş, L. (2013). Use of EO-1 Advanced Land Imager (ALI) multispectral image data and real-time field sampling for water quality mapping in the Hirfanlı Dam Lake, Turkey. *Environmental Science and Pollution Research*, 20, 5416–5424. <https://doi.org/10.1007/s11356-013-1553-9>
- Kırcalı, K. (2022). *Element eksikliği olan bölgelerdeki ürünlerin derin öğrenme ve İHA ile sınıflandırılması* [Yüksek lisans tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü].
- Kırtıloğlu, E., ve Karabörk, H. (2022). Evaluating the performance of algorithms in estimating the Chl-a concentration of Lake Bafa. *Turkish Journal of Geosciences*, 3(1), 30–38. <https://doi.org/10.48053/turkgeo.1118373>
- Kirk, J. T. O. (2011). *Light and photosynthesis in aquatic ecosystems* (3rd ed.). Cambridge University Press.
- Kowe, P., Ncube, E., Magidi, J., Ndambuki, J. M., Rwasoka, D. T., Gumindoga, W., Maviza, A., Mavaringana, M. de J. P., ve Kakanda, E. T. (2023). Spatial-temporal variability analysis of water quality using remote sensing data: A case study of Lake Manyame. *Scientific African*, 21, <https://doi.org/10.1016/j.sciaf.2023.e01877>
- Koyuncu, Z., ve Ekmekcioğlu, Ö. (2024). İstanbul için CBS tabanlı makine öğrenmesi ile sel duyarlılık haritasının oluşturulması. *Doğal Afetler ve Çevre Dergisi*, 10(1), 1–15. <https://doi.org/10.21324/dacd.1254778>
- Kulkarni, A. (2011). Water quality retrieval from Landsat TM imagery. *Procedia Computer Science*, 6, 475–480. <https://doi.org/10.1016/j.procs.2011.08.088>
- Kutser, T. (2009). Passive optical remote sensing of cyanobacteria and other intense phytoplankton blooms in coastal and inland waters. *International Journal of Remote Sensing*, 30(17), 4401–4425. <https://doi.org/10.1080/01431160802562305>
- Li, H., Xie, X., Yang, X., Cao, B., ve Xia, X. (2022). An integrated model of summer and winter for chlorophyll-a retrieval in the Pearl River Estuary based on hyperspectral data. *Remote Sensing*, 14(9), 2270. <https://doi.org/10.3390/rs14092270>
- Li, N., Ning, Z., Chen, M., Wu, D., Hao, C., Zhang, D., Bai, R., Liu, H., Chen, X., Li, W., Zhang, W., Chen, Y., Li, Q., ve Zhang, L. (2022). Satellite and machine learning monitoring of optically inactive water quality variability in a tropical river. *Remote Sensing*, 14(21), 5466. <https://doi.org/10.3390/rs14215466>
- Lillesand, T. M., Kiefer, R. W., ve Chipman, J. (2004). *Remote sensing and image interpretation* (5th ed.). John Wiley & Sons.
- Lillesand, T. M., Kiefer, R. W., ve Chipman, J. W. (2018). *Uzaktan algılama ve görüntü yorumlama* (K. Ş. Kavak, Çev.). Palme Yayınevi. (Orijinal çalışma basım tarihi 2015)

- Lim, J., ve Choi, M. (2015). Assessment of water quality based on Landsat 8 operational land imager associated with human activities in Korea. *Environmental Monitoring and Assessment*, 187(6), 384. <https://doi.org/10.1007/s10661-015-4616-1>
- Lin, G., ve Shen, W. (2018). Research on convolutional neural network based on improved ReLU piecewise activation function. *Procedia Computer Science*, 131, 977–984. <https://doi.org/10.1016/j.procs.2018.04.239>
- Liu, J., Zhang, Y., Song, X., Kuang, Y., ve Yuan, D. (2013). Retrieving water quality from high resolution IKONOS multispectral imagery by multiple regression and artificial neural networks in Lake Cihu, Huangshi. *Proceedings of the 2013 IAHR World Congress*.
- Llodrà-Llabrés, J., Martínez-López, J., Postma, T., Pérez-Martínez, C., ve Alcaraz-Segura, D. (2023). Retrieving water chlorophyll-a concentration in inland waters from Sentinel-2 imagery: Review of operability, performance and ways forward. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103605. <https://doi.org/10.1016/j.jag.2023.103605>
- Loaiza, J. G., Rangel-Peraza, J. G., Monjardín-Armenta, S. A., Bustos-Terrones, Y. A., Bandala, E. R., Sanhouse-García, A. J., ve Rentería-Guevara, S. A. (2023). Surface water quality assessment through remote sensing based on the Box–Cox transformation and linear regression. *Water*, 15(14), 2606. <https://doi.org/10.3390/w15142606>
- Mahmoud, S. H., Ahmed, S. S., Zhu, D. Z., Gan, T. Y., Loewen, M. R., van Duin, B., ve Mahmood, K. (2023). Monitoring the spatial distribution of water quality of an urban stormwater pond using satellite images. *Ecological Informatics*, 77, 102205. <https://doi.org/10.1016/j.ecoinf.2023.102205>
- Maltarollo, V. G., Honório, K. M., ve Silva, A. B. (2013). Applications of artificial neural networks in chemical problems.
- Mamun, M., Ferdous, J., ve An, K.-G. (2021). Empirical estimation of nutrient, organic matter and algal chlorophyll in a drinking water reservoir using Landsat 5 TM data. *Remote Sensing*, 13(12), 2256. <https://doi.org/10.3390/rs13122256>
- Mancino, G., Nole, A., Urbano, V., Amato, M., ve Ferrara, A. (2009). Assessing water quality by remote sensing in small lakes: The case study of Monticchio lakes in southern Italy. *iForest: Biogeosciences and Forestry*, 2. <https://doi.org/10.3832/ifor0507-002>
- McFeeters, S. K. (1996). The use of the normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Mobasheri, M. (2008). Assessment of suspended sediments concentration in surface waters using MODIS images. *American Journal of Applied Sciences*, 5(7), 798–804. <https://doi.org/10.3844/ajassp.2008.798.804>

- Moon, J., Suh, S., Jung, S., Baek, S. S., Pyo, J. (2024). Deep learning-based mapping of total suspended solids in rivers across South Korea using high resolution satellite imagery. *GIScience & Remote Sensing*, 61(1). <https://doi.org/10.1080/15481603.2024.2393489>
- Najafzadeh, M., ve Basirian, S. (2023). Evaluation of river water quality index using remote sensing and artificial intelligence models. *Remote Sensing*, 15(9), 2359. <https://doi.org/10.3390/rs15092359>
- Nas, B., Karabörk, H., ve Ekerin, S. (2009). Mapping of chlorophyll-a using in situ measurements and Terra ASTER satellite data. *Environmental Monitoring and Assessment*, 157, 375–382. <https://doi.org/10.1007/s10661-008-0542-9>
- O'Reilly, J. E., Maritorena, S., Mitchell, B. G., Siegel, D. A., Carder, K., Garver, S., Kahru, M., ve McClain, C. (1998). Ocean color chlorophyll algorithms for SeaWiFS. *Journal of Geophysical Research: Atmospheres*, 103, 937–953.
- Olmanson, L. G., Brezonik, P. L., ve Bauer, M. E. (2011). Evaluation of medium to low resolution satellite imagery for regional lake water quality assessments. *Water Resources Research*, 47. <https://doi.org/10.1029/2011WR011005>
- Örmeci, C. (1987). *Uzaktan algılama (Temel esaslar ve algılama sistemleri)*. İTÜ İnşaat Fakültesi Matbaası.
- Öztemel, E. (2003). *Yapay sinir ağları*. Papatya Yayıncılık.
- Pang, Y., Sun, M., Jiang, X., ve Li, X. (2018). Convolution in convolution for network in network. *IEEE Transactions on Neural Networks and Learning Systems*, 29(5), 1587–1597.
- Peng, C., Biao, W., Yanlan, W., Qijun, W., Zuoji, H., ve Chunlin, W. (2023). Urban river water quality monitoring based on self-optimizing machine learning method using multi-source remote sensing data. *Ecological Indicators*, 146, 109750. <https://doi.org/10.1016/j.ecolind.2022.109750>
- Perivolioti, T., Mouratidis, A., Bobori, D., Doxani, G., ve Terzopoulos, D. (2017). Monitoring water quality parameters of Lake Koronia by means of long time-series multispectral satellite images. *Acta Universitatis Carolinae. Geographica*, 52. <https://doi.org/10.14712/23361980.2017.14>
- Perumal, B., Rajarethinam, N., Velusamy, A., ve Prabhu, S. V. (2023). Water quality prediction based on hybrid deep learning algorithm. *Advances in Civil Engineering*, 2023, 1–10. <https://doi.org/10.1155/2023/6644681>
- Peterson, K. T., Sagan, V., ve Sloan, J. J. (2020). Deep learning-based water quality estimation and anomaly detection using Landsat-8/Sentinel-2 virtual constellation and cloud computing. *GIScience & Remote Sensing*, 57(4), 510–525.
- Peterson, K., Sagan, V., Sidike, P., Cox, A., ve Martinez, M. (2018). Suspended sediment concentration estimation from Landsat imagery along the lower Missouri and middle Mississippi rivers using an extreme learning machine. *Remote Sensing*, 10(10), 1503.

- Politi, E., Cutler, M. E. J., ve Rowan, J. S. (2015). Evaluating the spatial transferability and temporal repeatability of remote-sensing-based lake water quality retrieval algorithms at the European scale: A meta-analysis approach. *International Journal of Remote Sensing*, 36, 2995–3023.
- Pu, F., Ding, C., Chao, Z., Yu, Y., ve Xu, X. (2019). Water-quality classification of inland lakes using Landsat 8 images by convolutional neural networks. *Remote Sensing*, 11(14), 1674. <https://doi.org/10.3390/rs11141674>
- Qi, C., Huang, S., ve Wang, X. (2020). Monitoring water quality parameters of Taihu Lake based on remote sensing images and LSTM-RNN. *IEEE Access*, 8, 188068–188081. <https://doi.org/10.1109/ACCESS.2020.3030878>
- Qian, J., Liu, H., Qian, L., Bauer, J., Xue, X., Yu, G., He, Q., Zhou, Q., Bi, Y., ve Norra, S. (2022). Water quality monitoring and assessment based on cruise monitoring, remote sensing, and deep learning: A case study of Qingcaosha Reservoir. *Frontiers in Environmental Science*, 10. <https://doi.org/10.3389/fenvs.2022.979133>
- Quandel, C. (2018). *Deep convolution neural networks for the analysis of a few medical images* [Master's thesis, Ludwig-Maximilians-Universität München, Institut für Statistik].
- Ritchie, J. C., Schiebe, F. R., ve McHenry, J. R. (1976). Remote sensing of suspended sediments in surface water. *Photogrammetric Engineering and Remote Sensing*, 42, 1539–1545.
- Ritchie, J. C., Zimba, P. V., ve Everitt, J. H. (2003). Remote sensing techniques to assess water quality. *Photogrammetric Engineering & Remote Sensing*, 69(6), 695–704. <https://doi.org/10.14358/PERS.69.6.695>
- Robinson, A. H., Morrison, J. L., Muehrcke, P. C., Kimerling, A. J., & Guptill, S. C. (1995). *Elements of cartography*. John Wiley & Sons.
- Rodríguez-López, L., Bravo Alvarez, L., Duran-Llacer, I., Ruíz-Guirola, D. E., Montejó-Sánchez, S., Martínez-Retureta, R., López-Morales, E., Bourrel, L., Frappart, F., ve Urrutia, R. (2024). Leveraging machine learning and remote sensing for water quality analysis in Lake Ranco, Southern Chile. *Remote Sensing*, 16(18), 3401. <https://doi.org/10.3390/rs16183401>
- Rodríguez-López, L., Duran-Llacer, I., Bravo Alvarez, L., Lami, A., ve Urrutia, R. (2023). Recovery of water quality and detection of algal blooms in Lake Villarrica through Landsat satellite images and monitoring data. *Remote Sensing*, 15(7), 1929. <https://doi.org/10.3390/rs15071929>
- Rodríguez-López, L., Usta, D. B., Duran-Llacer, I., Alvarez, L. B., Yépez, S., Bourrel, L., Frappart, F., ve Urrutia, R. (2023). Estimation of water quality parameters through a combination of deep learning and remote sensing techniques in a lake in southern Chile. *Remote Sensing*, 15(17), 4157. <https://doi.org/10.3390/rs15174157>


- Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154–172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Ruan, Q., Pan, D., Wang, D., He, X., Gong, F., ve Tian, Q. (2025). Prediction of sea surface chlorophyll-a concentrations by remote sensing and deep learning. *Remote Sensing*, 17(10), 1755.
- Seth, A., Nikou, A., ve Daoutis, M. (2022). A scalable species-based genetic algorithm for reinforcement learning problems. *The Knowledge Engineering Review*, 37, e9. <https://doi.org/10.1017/S0269888922000042>
- Shen, M., Luo, J., Cao, Z., Xue, K., Qi, T., Ma, J., Liu, D., Song, K., Feng, L., & Duan, H. (2022). Random forest: An optimal chlorophyll-a algorithm for optically complex inland water suffering atmospheric correction uncertainties. *Journal of Hydrology*, 615(Part A), 128685. <https://doi.org/10.1016/j.jhydrol.2022.128685>
- Slocum, T. A., McMaster, R. B., Kessler, F. C., & Howard, H. H. (2009). *Thematic cartography and geovisualization*. Pearson.
- Sivakumar, M. V. K., Roy, P. S., Harmsen, K., ve Saha, S. K. (2003). *Satellite remote sensing and GIS applications in agricultural meteorology*. Geneva.
- Skurichina, M., ve Duin, R. P. W. (2002). Bagging, boosting and the random subspace method for linear classifiers. *Pattern Analysis and Applications*, 5(2), 121–135. <https://doi.org/10.1007/s100.440.200011>
- Somvanshi, S., Kunwar, D., Singh, N. B., Shukla, S. P., ve Pathak, V. (2012). Integrated remote sensing and GIS approach for water quality analysis of Gomti River, Uttar Pradesh. *International Journal of Environmental Sciences*, 3, 62–74. <https://doi.org/10.6088/ijes.2012030131008>
- Srivastava, R., Greff, K., ve Schmidhuber, J. (2015). *Training very deep networks*. <https://doi.org/10.48550/arXiv.1507.06228>
- Su, Y.-F., Liou, J.-J., Hou, J.-C., Hung, W.-C., Hsu, S.-M., Lien, Y.-T., Su, M.-D., Cheng, K.-S., ve Wang, Y.-F. (2008). A multivariate model for coastal water quality mapping using satellite remote sensing images. *Sensors*, 8(10), 6321–6339. <https://doi.org/10.3390/s8106321>
- Sunar, A. F., Özkan, C., ve Osmanoğlu, B. (2018). *Uzaktan algılama*. T.C. Anadolu Üniversitesi, Açıköğretim Fakültesi Yayını.
- Şafak, E., ve Barışçı, N. (2018). Evrişimsel sinir ağlarını kullanarak yaş ve cinsiyet tahmini. *2nd International Symposium on Multidisciplinary Studies and Innovative Technologies*.

- Tesfaye, A. (2024). Remote sensing-based water quality parameters retrieval methods: A review. *East African Journal of Environment and Natural Resources*, 7(1), 80–97. <https://doi.org/10.37284/eajenr.7.1.1753>
- Tirth, G. (2018). *Autonomous vehicle guidance using neural network and random forest model* (Master's thesis). California State University, Long Beach, Department of Mechanical and Aerospace Engineering.
- Toksöz, O., ve Uysal, M. (2018). Muğla ili kıyı sularının uzaktan algılama tekniği ile su kalitesinin belirlenmesi ve haritalandırılması. <https://doi.org/10.15659/UzalCBS2018.7026>
- Toming, K., Kutser, T., Laas, A., Sepp, M., Paavel, B., ve Nöges, T. (2016). First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. *Remote Sensing*, 8(8), 640. <https://doi.org/10.3390/rs8080640>
- Torres-Vera, M. A. (2023). Mapping of total suspended solids using Landsat imagery and machine learning. *International Journal of Environmental Science and Technology*, 20, 11877–11890. <https://doi.org/10.1007/s13762-023-04787-y>
- Vieira, C. A. O. (1998). Using multitemporal, multispectral and multisource remotely sensed data to classify crops: An innovative approximation. *Proceedings of the Remote Sensing Society Conference* (ss. 47–52). Oxford.
- Villota-González, F. H., Sulbarán-Rangel, B., Zurita-Martínez, F., Gurubel-Tun, K. J., ve Zúñiga-Grajeda, V. (2023). Assessment of machine learning models for remote sensing of water quality in Lakes Cajitlán and Zapotlán, Jalisco—Mexico. *Remote Sensing*, 15(23), 5505. <https://doi.org/10.3390/rs15235505>
- Virdis, S. G., Xue, W., Winijkul, E., Nitivattananon, V., ve Punpukdee, P. (2022). Remote sensing of tropical riverine water quality using Sentinel-2 MSI and field observations. *Ecological Indicators*, 144, 109472. <https://doi.org/10.1016/j.ecolind.2022.109472>
- Wang, J., ve Chen, X. (2024). A new approach to quantify chlorophyll-a over inland water targets based on multi-source remote sensing data. *Science of the Total Environment*, 906, 167631. <https://doi.org/10.1016/j.scitotenv.2023.167631>
- Wei, Z., Wei, L., Yang, H., Wang, Z., Xiao, Z., Li, Z., Yang, Y., ve Xu, G. (2022). Water quality grade identification for lakes in middle reaches of Yangtze River using Landsat-8 data with deep neural networks (DNN) model. *Remote Sensing*, 14(24), 6238. <https://doi.org/10.3390/rs14246238>
- World Health Organization (WHO). (2023). Drinking-water fact sheet. Geneva: World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/drinking-water>
- Wu, X., Gao, Y., ve Jiao, D. (2019). Multi-label classification based on random forest algorithm for non-intrusive load monitoring system. *Processes*, 7(6), 337. <https://doi.org/10.3390/pr7060337>


- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Yang, H., Du, Y., Zhao, H., ve Chen, F. (2022). Water quality Chl-a inversion based on spatio-temporal fusion and convolutional neural network. *Remote Sensing*, 14(5), 1267. <https://doi.org/10.3390/rs14051267>
- Yang, H., Kong, J., Hu, H., Du, Y., Gao, M., ve Chen, F. (2022). A review of remote sensing for water quality retrieval: Progress and challenges. *Remote Sensing*, 14(8), 1770. <https://doi.org/10.3390/rs14081770>
- Yang, P., Yang, Y. H., Zhou, B. B., ve Zomaya, A. Y. (2010). A review of ensemble methods in bioinformatics. *Current Bioinformatics*, 5(4), 296–308. <https://doi.org/10.2174/157489310794072508>
- Yang, W., Fu, B., Li, S., Lao, Z., Deng, T., He, W., He, H., ve Chen, Z. (2023). Monitoring multi-water quality of internationally important karst wetland through deep learning, multi-sensor and multi-platform remote sensing images: A case study of Guilin, China. *Ecological Indicators*, 154, 110755. <https://doi.org/10.1016/j.ecolind.2023.110755>
- Yerüstü Su Kalitesi Yönetmeliği (2012), Değişik: RG-16/6/2021-31513
- Yıldız, H., Mermer, A., Ünal, E., ve Akbaş, F. (2012). Türkiye bitki örtüsünün NDVI verileri ile zamansal ve mekansal analizi. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 21(2), 50–56.
- Zhang, H., Xue, B., Wang, G., Zhang, X., ve Zhang, Q. (2022). Deep learning-based water quality retrieval in an impounded lake using Landsat 8 imagery: An application in Dongping Lake. *Remote Sensing*, 14(18), 4505. <https://doi.org/10.3390/rs14184505>
- Zhang, X., Song, Y., Chen, J., ve Huang, J. (2021). Landsat image-based retrieval and analysis of spatiotemporal variation of total suspended solid concentration in Jiaozhou Bay, China. *Remote Sensing*, 13(23), 4796. <https://doi.org/10.3390/rs13234796>
- Zhang, Y., He, X., Lian, G., Bai, Y., Yang, Y., Gong, F., Wang, D., Zhang, Z., Li, T., ve Jin, X. (2023). Monitoring and spatial traceability of river water quality using Sentinel-2 satellite images. *Science of the Total Environment*, 894, 164862. <https://doi.org/10.1016/j.scitotenv.2023.164862>
- Zhao, Y., He, X., Pan, S., Bai, Y., Wang, D., Li, T., Gong, F., ve Zhang, X. (2024). Satellite retrievals of water quality for diverse inland waters from Sentinel-2 images: An example from Zhejiang Province, China. *International Journal of Applied Earth Observation and Geoinformation*, 132, 104048. <https://doi.org/10.1016/j.jag.2024.104048>
- URL-1: (2025). <https://ockb.csb.gov.tr/golbasi-ozel-cevre-koruma-bolgesi-i-2750>, [Erişim tarihi: 14.12.2025].

EKLER


EK-1 18.04.2018 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-2 23.07.2018 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-3 27.10.2018 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-4 31.07.2021 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-5 16.08.2021 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-6 17.09.2021 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-7 05.07.2023 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-8 08.08.2024 tarihine ait CHL-A dağılımına ilişkin tematik harita.




EK-9 18.04.2018 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-10 23.07.2018 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-11 27.10.2018 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-12 31.07.2021 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-13 16.08.2021 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-14 17.09.2021 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-15 05.07.2023 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-16 08.08.2024 tarihine ait AKM dağılımına ilişkin tematik harita.




EK-17 18.04.2018 tarihine ait SDD dağılımına ilişkin tematik harita.




EK-18 23.07.2018 tarihine ait SDD dağılımına ilişkin tematik harita.




EK-19 27.10.2018 tarihine ait SDD dağılımına ilişkin tematik harita.




EK-20 31.07.2021 tarihine ait SDD dağılımına ilişkin tematik harita.




EK-21 16.08.2021 tarihine ait SDD dağılımına ilişkin tematik harita.



EK-22 17.09.2021 tarihine ait SDD dağılımına ilişkin tematik harita.



EK-23 05.07.2023 tarihine ait SDD dağılımına ilişkin tematik harita.



EK-24 08.08.2024 tarihine ait SDD dağılımına ilişkin tematik harita.

