



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

YÜKSEK LİSANS TEZİ

**UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ YAKLAŞIMI
İLE BATMAN ÇAYI'NIN YILLARA GÖRE SU AKIŞ REJİMİ
DEĞİŞİMİNİN İNCELENMESİ**

Mehmet TÜRK

**Ocak-2025
BATMAN**

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

YÜKSEK LİSANS TEZİ

**UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ YAKLAŞIMI
İLE BATMAN ÇAYI'NIN YILLARA GÖRE SU AKIŞ REJİMİ
DEĞİŞİMİNİN İNCELENMESİ**

Mehmet TÜRK

**Danışman
Doç. Dr. Emrullah ACAR**

Diğer Jüri Yeleri

Doç. Dr. Ömer TÜRK

Dr. Öğr. Üyesi M.Cengiz ARSLANOĞLU

**Ocak-2025
BATMAN**

TEZ KABUL VE ONAYI

Mehmet TRK tarafından hazırlanan ‘‘UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ YAKLAŞIMI İLE BATMAN ÇAYI’NIN YILLARA GÖRE SU AKIŞ REJİMİ DEĞİŞİMİNİN İNCELENMESİ’’ adlı tez çalışması 23/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı’nda YKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jri yeleri

İmza

Başkan

Doç. Dr. Ömer TRK

.....

Danışman

Doç. Dr. Emrullah ACAR

.....

ye

Dr. Öğr. yesi Mehmet Cengiz ARSLANOĞLU

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. yesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

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

ETHICAL DECLARATION

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

Mehmet TÜRK
Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ YAKLAŞIMI İLE BATMAN ÇAYI'NIN YILLARA GÖRE SU AKIŞ REJİMİ DEĞİŞİMİNİN İNCELENMESİ

Mehmet TÜRK

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Emrullah ACAR

2025, 64 Sayfa

Dünya üzerinde birçok akarsu bulunmaktadır. Doğal su kaynaklarından meydana gelen akarsular arazi eğimine de uyum sağlayacak bir biçimde kendi su yollarını oluşturmuşlardır. Arazi şartlarına ve insanların araziler üzerinde meydana getirdiği değişikliklere bağlı olarak bazı bölgelerde geniş su yatakları, bazı bölgelerde ise dar su yatakları meydana gelmiştir. Aynı zamanda yağış şartlarının ve çevresel koşulların da etkisiyle bu durum yıllara göre su yataklarının değişmesine sebep olmuştur.

Akarsuların su yolunun yıllara göre sabit olmaması metre-karelerce alanın ticari (tarım, sanayi, turizm vb.) anlamda değerlendirilememesine sebep olmaktadır. Bu durum devletler için de ekonomik anlamda negatif etki yaratmaktadır. Su yollarının yıllara göre değişmeyerek sabitlenmesi durumunda, tarım vb. amaçla bölgeye kazandırılacak olan alanlar, hem bölge halkının hem de devletin ekonomik anlamda kalkınmasına katkı sağlayacaktır.

Bu çalışmada Batman Çayı'nın yıllara göre su yolu değişimi uzaktan algılama verileri ve farklı makine öğrenmesi teknikleri yardımıyla tespit edilmiştir. Bu değişim sebebiyle tarım vb. amaçla kullanılmayarak su yatakları içinde kalan alanların kazandırılabilmesi adına su yolunun sabitlenmesi analiz edilmiştir. Sonuç olarak su yolunun sabitlenerek yıllara göre değişmeyeceği senaryoda kazandırılacak alanın hem ülke ekonomisine hem de Batman halkına fayda sağlayacağı değerlendirilmektedir.

Anahtar Kelimeler: Landsat, Makine Öğrenmesi, Spektral Bant Parametreleri, Uzaktan Algılama

ABSTRACT

MASTER THESIS

INVESTIGATION OF WATER FLOW REGIME CHANGES OF BATMAN STREAM OVER THE YEARS USING REMOTE SENSING AND MACHINE LEARNING APPROACH

Mehmet TRK

Batman University Graduate Education Institute

Electrical And Electronics Engineering Department of Science

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2025, 64 Pages

There are many rivers on Earth. Rivers formed from natural water sources have created their own waterways in a way that adapts to the terrain's slope. Depending on the land conditions and the changes made by humans on the land, wide water bodies have formed in some regions, while narrow water bodies have formed in others. At the same time, the influence of rainfall conditions and environmental factors has caused the water bodies to change over the years.

The fact that the waterway of rivers is not constant over the years causes square meters of land to be unusable for commercial purposes (agriculture, industry, tourism, etc.). This situation also has a negative economic impact on the states. If the waterways are stabilized and do not change over the years, the areas that will be allocated for purposes such as agriculture will contribute to the economic development of both the local population and the state.

In this study, the change in the watercourse of the Batman River over the years was identified using remote sensing data and various machine learning techniques. Due to this change, the stabilization of the waterway has been analyzed in order to reclaim areas that have been left within the water beds and cannot be used for purposes such as agriculture. As a result, it is evaluated that in the scenario where the waterway is stabilized and does not change over the years, the area to be reclaimed will benefit both the national economy and the people of Batman.

Keywords: Landsat, Machine Learning, Remote Sensing, Spectral Band Parameters

ÖN SÖZ

Yüksek Lisans hayatıma başladığım günden bu yana danışman hocam olarak tüm süreç boyunca verdiği destekler, tez hazırlama sürecinde bakış açımı değiştiren ve ufkumu açan farklı perspektifler, uzaktan algılamaya dair vermiş olduğu tüm değerli bilgiler için değerli sayın danışman hocam Doç.Dr. Emrullah ACAR'a ve tez hazırlama sürecinde her türlü desteği veren Dr. Öğr. Üyesi Mehmet Cengiz ARSLANOĞLU'na sonsuz teşekkürlerimi sunarım.

Bu tez çalışması boyunca yararlandığım GEE (Google Earth Engine) ve MATLAB platformlarının geliştiricilerine ve Landsat uydu serisinin sağlamış olduğu veriler için USGS/NASA (United States Geological Survey/ National Aeronautics and Space Administration)'ya teşekkürlerimi sunarım.

Son olarak hayatıma değer katan, maddi ve manevi anlamda desteklerini hiçbir zaman esirgemeyen ve hayatımın her anında olduğu gibi bu tez çalışması süresince de her zaman yanımda olan sevgili eşim Hilal TÜRK ve biricik kızım Almıla TÜRK'e vermiş oldukları manevi destekten dolayı teşekkür ederim.

Mehmet TÜRK
BATMAN-2025

İÇİNDEKİLER

ÖZET	1
ABSTRACT	2
ÖN SÖZ	3
İÇİNDEKİLER	4
ÇİZELGELER/TABLolar LİSTESİ.....	6
ŞEKİLLER LİSTESİ	7
SİMGELER VE KISALTMALAR.....	9
1. GİRİŞ.....	10
1.1. Çalışmanın Amacı ve Önemi	10
1.2. Çalışmanın Varsayımları ve Yaşanabilecek Aksaklıklar	11
2. KAYNAK ARAŞTIRMASI	12
2.1. Uzaktan Algılama	12
2.2. Makine Öğrenmesi.....	13
2.2.1. Denetimli öğrenme.....	14
2.2.2. Denetimsiz öğrenme	15
2.2.3. Takviyeli öğrenme	15
2.3. Literatür Taraması	15
3. YÖNTEM.....	20
3.1. Çalışma Alanı	20
3.2. Önerilen Sistem Mimarisi	22
3.3. Veri Seti Oluşturma	24
3.3.1. Landsat 1-9 Uydu Serisi.....	24
3.3.2. Google earth engine	28
3.4. Makine Öğrenmesi Algoritmaları.....	28
3.4.1. Karar ağacı modeli	28
3.4.2. Destek vektör makinesi	30
3.4.3. K-En yakın komşular	31
3.4.4. Topluluk öğrenimi	32
3.4.5. Kernel yaklaşım sınıflandırıcısı	32
3.4.6. Yapay sinir ağları.....	33
3.5. Karışıklık Matrisi.....	34
3.5.1. Doğruluk.....	35
3.5.2. Hata oranı	35
3.5.3. Hassasiyet	36
3.5.4. Duyarlılık.....	36
3.5.5. F1 skor.....	36
3.6. ROC Eğrisi	36

4. BULGULAR VE TARTIŞMA	38
4.1. Google Earth Engine Kullanılarak Elde Edilen Veriler	38
4.2. Makine Öğrenmesi Kullanılarak Elde Edilen Veriler	44
4.2.1. Karar ağaçları algoritmasına ait sonuçlar	46
4.2.2. Destek vektör makinesi algoritmasına ait sonuçlar	48
4.2.3. K-En yakın komşular algoritmasına ait sonuçlar	50
4.2.4. Topluluk sınıflandırıcısı algoritmasına ait sonuçlar	52
4.2.5. Yapay sinir ağları algoritmasına ait sonuçlar	54
4.2.6. Kernel yaklaşım sınıflandırıcısı algoritmasına ait sonuçlar	56
5. SONUÇLAR VE ÖNERİLER	59
5.1 Sonuçlar	59
5.1.1. GEE kullanılarak elde edilen yaklaşık sonuçların değerlendirilmesi	59
5.1.2. Makine öğrenmesi yaklaşımı ile elde edilen yaklaşık sonuçların değerlendirilmesi	64
5.2 Öneriler	64
KAYNAKLAR	66

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 3. 1. Landsat-7 Uydusu Yüzey Yansıması Bandları (GEE Platformu, 2024)...	27
Çizelge 3. 2. Landsat-8 Uydusu Yüzey Yansıması Bandları (GEE Platformu, 2024)...	27
Çizelge 4. 1. Makine Öğrenmesi Yaklaşımı ile Farklı Veri Setlerinden Elde Edilen Sonuçlar	45

ŞEKİLLER LİSTESİ

Şekil 2. 1. NASA MODIS Uydusu Okyanus ve Denizlerin Yüzey Sıcaklığı (TUBİTAK, 2019).....	13
Şekil 3. 1. Çalışma Alanı-1 (GEE Platformu, 2024).....	20
Şekil 3. 2. Batman Çayı, Dicle Nehri ve Ilısu Baraj Gölü (GEE Platformu, 2025).....	21
Şekil 3. 3. Çalışma Alanı-2 (GEE Platformu, 2024).....	22
Şekil 3. 4. Sistem Mimarisi.....	23
Şekil 3. 5. Çalışma Alanı İçerisinden Seçilen Su (Mavi) ve Atıl Alanları (Beyaz) Temsil Eden Noktalar (GEE Platformu, 2024)	24
Şekil 3. 6. Landsat Uydu Serisi (Wulder, 2019)	26
Şekil 3. 7. DVM Modeli (Cano, Research Gate, 2018).....	31
Şekil 3. 8. YSA Modeli (Cano, Research Gate, 2018).....	34
Şekil 3. 9. Karışıklık Matrisi (Room, 2019)	35
Şekil 4. 1. Batman Çayı Su Yolu Karşılaştırılması-1 (GEE Platformu, 2024).....	38
Şekil 4. 2. Batman Çayı Su Yolu Karşılaştırılması-2 (GEE Platformu, 2024).....	39
Şekil 4. 3. Batman Çayı Su Yolu Karşılaştırılması-3 (GEE Platformu, 2024).....	40
Şekil 4. 4. Batman Çayı Su Yolu Karşılaştırılması-4 (GEE Platformu, 2024).....	41
Şekil 4. 5. Batman Çayı Su Yolu Karşılaştırılması-5 (GEE Platformu, 2024).....	42
Şekil 4. 6. Batman Çayı Su Yolu Karşılaştırılması-6 (GEE Platformu, 2024).....	43
Şekil 4. 7. Karar Ağaçları Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	46
Şekil 4. 8. Karar Ağaçları Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi	47
Şekil 4. 9. Karar Ağaçları Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	47
Şekil 4. 10. Destek Vektör Makinesi Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	48
Şekil 4. 11. Destek Vektör Makinesi Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	49
Şekil 4. 12. Destek Vektör Makinesi Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi	49
Şekil 4. 13. KNN Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi	50
Şekil 4. 14. KNN Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	51
Şekil 4. 15. KNN Algoritması 2016 Sonrası Yıllardaki Düzeltilmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi	51
Şekil 4. 16. Topluluk Sınıflandırıcısı Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	52
Şekil 4. 17. Topluluk Sınıflandırıcısı Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	53
Şekil 4. 18. Topluluk Sınıflandırıcısı Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi	53
Şekil 4. 19. Yapay Sinir Ağları Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	54
Şekil 4. 20. Yapay Sinir Ağları Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi	55
Şekil 4. 21. Yapay Sinir Ağları Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	55

Şekil 4. 22. Kernel Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi	56
Şekil 4. 23. Kernel Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	57
Şekil 4. 24. Kernel Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi.....	57
Şekil 5. 1. Batman Çayı Üzerindeki Atıl Alan-1 (GEE Platformu, 2024)	59
Şekil 5. 2. Batman Çayı Üzerindeki Atıl Alan-2 (GEE Platformu, 2024)	60
Şekil 5. 3. Batman Çayı Üzerindeki Atıl Alan-3 (GEE Platformu, 2024)	61
Şekil 5. 4. Batman Çayı Üzerindeki Atıl Alan-4 (GEE Platformu, 2024)	62
Şekil 5. 5. Batman Çayı Üzerindeki Atıl Alan-5 (GEE Platformu, 2024)	63

SİMGELER VE KISALTMALAR

Kısaltmalar

ANN	: Yapay Sinir Ağları
AUC	: Eğrinin Altındaki Alan
CBS/GIS	: Coğrafi Bilgi Sistemi
DOD	: ABD Savunma Bakanlığı
EOSAT	: Dünya Gözlem Uydusu
ERTS	: Dünya Kaynakları Teknoloji Uydusu
ETM	: Geliştirilmiş Tematik Haritalayıcı
FN	: Yanlış Negatif
FNR	: Yanlış Negatif Oranı
FP	: Yanlış Pozitif
GEE	: Google Earth Engine
GP	: Gaus İşlemi
KNN	: K-En Yakın Komşular
LULC	: Arazi Kullanımı ve Arazi Örtüsü
ML	: Makine Öğrenmesi
MLP	: Çok Katmanlı Perceptron
MNDWI	: Modifiye Edilmiş Normalleştirilmiş Fark Su İndeksi
MODIS	: Orta Çözünürlüklü Görüntüleme Spektrometresi
NASA	: Ulusal Havacılık ve Uzay Dairesi
NDVI	: Normalleştirilmiş Fark Bitki Örtüsü İndeksi
NDWI	: Normalleştirilmiş Fark Su İndeksi
NOAA	: Ulusal Okyanus ve Atmosfer Dairesi
OLI	: Operasyonel Arazi Görüntüleyicisi
PCA	: Temel Bileşenler Analizi
RGB	: Kırmızı Yeşil Mavi
ROC	: Alıcı İşletim Karakteristiği
RS	: Uzaktan Algılama
SCG	: Ölçeklenmiş Konjuge Gradyen
SVM/DVM	: Destek Vektör Makinaları
SWI	: Basit Su İndeksi
TIRS	: Termal Kızılötesi Sensör
TM	: Tematik Haritalayıcı
TN	: Doğru Negatif
TP	: Doğru Pozitif
TPR	: Doğru Pozitif Oranı
USGS	: Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
WRI	: Su Oranı İndeksi

1. GİRİŞ

Doğa kaynakları insanlığa yüksek oranda (Enerji, tarım, turizm vb.) faydalar sağlamaktayken, her geçen yıl insanlığın doğaya olan etkileri artarak devam etmektedir. Bu etkilerin ne yazık ki büyük çoğunluğu doğaya zarar vermekte, hatta yok etmektedir. Bir yandan da doğanın daha sonraki nesillere de temiz ve daha saf olarak aktarılması için çeşitli kurum ve kuruluşlar ortaya çıkmıştır. Bu kuruluşların yaptığı çalışmalar ile insanlığın doğaya olan etkilerinin en aza indirilmesi amaçlanmaktadır. Öte yandan tüm bunlar düşünüldüğünde insanlığın çevreye olan etkilerinin kendilerine faydalı olacak bir şekilde yapılıyor olması, doğaya verilen tahribatın da en aza indirilmesinin, hatta doğaya da fayda sağlayacak şekilde yapılmasının, hem insanlığın geleceği hem de doğanın sürdürülebilirliği açısından büyük öneme sahip olacağı düşünülmektedir.

1.1. Çalışmanın Amacı ve Önemi

Bu tez çalışması, Türkiye'nin Batman ili sınırları içerisinde bulunan Batman Çayı'nın akış rejimiyle ilgilidir. Batman Çayı'nın yıllara göre akış rejimleri incelendiğinde düzenli bir su yolunu kullanmadığı, yıllara göre değişken bir rejim sergilediği görülmüştür (Arslanoğlu ve ark., 2003). Batman Çayı sadece çay yatağı için değil, çay yatağına komşu araziler için de tehditlerdir. Ayrıca yoğun yağış dönemlerinde veya Batman Barajı'na bakım yapılan zamanlarda kapakların açılmasıyla birlikte çay debisinin yükselmesine bağlı olarak, boğulma olaylarına da sebep olabilmektedir.

Halen Batman çayında, DSİ tarafından bir ıslah çalışması devam etmektedir ancak çalışmanın Batman çayının güneyinde çok küçük bir kısmı tamamlanabilmiştir. DSİ tarafından yürütülen bu çalışmanın önemine dikkat çekmek açısından Batman çay yatağında su yatağının değişiminin incelenmesi ile ilgili bir çalışma yapılması ihtiyacı ortaya çıkmıştır. Su akış rejiminin incelenme sebebi ise bölgede tarım, ticari vb. amaçla kullanılabilecek olan Batman Çay yatağı içinde ve yakınındaki bölgelerin atıl bir alan olmaktan çıkarak, ülke tarımına katkı sağlayacak ve doğaya da herhangi bir zarar vermeden kullanılabilmek olanağının bulunmasıdır.

Bu çalışmada, 2000-2024 yılları arasında Batman Çayı'nın akış rejimi incelenmiştir. Çalışma sonrasındaki hedef elde edilen veriler ile su yolunun sabitlenmesi durumunda kazanılabilecek alanların belirlenmesidir ve atıl alanların tarıma

kazandırılmasıdır. Sonuç olarak ıslah çalışmaları tamamlandığında bu alanların ülke tarımına kazandırılması ile hem bölge halkına hem de ülke ekonomisine katkı sağlayacağı değerlendirilmektedir. Aynı zamanda benzer nehir yatakları olan bölgeler üzerinde de bu şekilde bir çalışma yapılmasının önünü açacağı değerlendirilmektedir.

1.2. Çalışmanın Varsayımları ve Yaşanabilecek Aksaklıklar

Bu tez çalışması ile ilgili birçok varsayımda bulunulabilir. Örneğin çalışma sonucunda kazandırılacak bir atıl alanın olması ve bu alanın da tarım vb. amaçla kullanıma açılmasının faydalı bir sonuç olacağı düşünülmektedir. Ayrıca nehir yatağının sabitlenmesi durumunda, nehirde yaşayan balık türleri için de faydalı olacağı beklenmektedir. Yani çalışma sonrasında, hem doğa yönünden hem de insanlık için olumlu sonuçların ortaya çıkacağı değerlendirilmektedir.

Yukarıda belirtilen olumlu sonuçların yanı sıra çalışma sonucu her ne kadar faydalı olsa bile kazandırılacak atıl alanların tarım vb. koşullar için uygun olmayabileceği, nehir yatağının sabitlenmesi için yapılacak çalışmaların güçlükler içerebileceği gibi birçok sorunun da ortaya çıkabileceği düşünülebilir.

Çalışmada kullanılacak olan uzaktan algılama ve makine öğrenmesi yaklaşımı ile çalışma bölgesinin genel bir etüdü incelenmiştir. Bölgelerin analizi uydu görüntüleri üzerinden yapılmıştır. Bunun yanı sıra makine öğrenmesi yaklaşımıyla bölgeden yansıyan uydu verileri üzerinden, sayısal değerler ile de analizler yapılmıştır. Her iki yöntemin birbirini desteklediği görülmüştür.

Tüm bu koşullar düşünüldüğünde çalışma sonucunda ortaya çıkacak sonuçlar ve bu sonuçlara en faydalı olacağı düşünülen öneriler tez çalışmasının ilerleyen bölümlerinde değerlendirilecektir.

2. KAYNAK ARAŞTIRMASI

Uzaktan algılama tekniklerinin yıllar geçtikçe gelişmesiyle birlikte, farklı bir perspektif ve geniş bir açı ile yeryüzünün detaylı bir şekilde incelebilmesinin önü açılmıştır. Her geçen gün daha da gelişen kameralar sayesinde, uydular aracılığıyla yeryüzü üzerinden çok detaylı bir şekilde yüksek çözünürlükte görüntüler alınabilmektedir. Bu da yeryüzü alanlarının sınıflandırılmasında çok ciddi kolaylıklar sağlamaktadır. Örnek olarak yeryüzü alanları içerisinde nehirler, şehir merkezleri, tarım alanları, çorak bölgeler vb. birçok alanda sınıflandırma yapılarak bu alanların analizleri yapılabilmektedir.

Yeryüzü alanlarını birbirlerinden ayırt etmemizi sağlayan yüksek çözünürlüklü uydu görüntülerinin yanı sıra, yine uydular üzerinden elde edilen spektral bant parametreleri ile de yeryüzü alanlarının sınıflandırılmasının yapılması mümkündür. Uydu üzerinden alınan spektral bant parametreleri ile sulu alanlar, tarım alanları, şehirlerdeki yapılar, ormanlık alanlar vb. gibi farklı bölgeler için farklı değerler elde edilebilmektedir. Bu sayede, yeryüzü alanlarının spektral bant değerlerini kullanarak makine öğrenmesi yaklaşımı ile bu ayırım kolaylıkla yapılabilmektedir.


Bu tez çalışmasında, Batman Çayı'nın su akış rejimi uzaktan algılama ve farklı makine öğrenme yaklaşımları vasıtasıyla incelenmiştir.

2.1. Uzaktan Algılama

Uzaktan algılamaya bir başka ifade ile dünya gözlemi de denilebilir. Herhangi bir temas olmamasına rağmen, dünya yüzeyindeki objelerle ya da bölgelerle ilgili analiz yapılmasını sağlayacak bilgiler verir. İnsanlar bu görevi gözleri, burunları veya kulakları yardımıyla gerçekleştirir; bu nedenle uzaktan algılama insanların günlük hayatta fazlasıyla uyguladığı bir iştir. Gazete okumak, yoldan geçen arabaları izlemek vb. her şey uzaktan algılama faaliyetleridir. Birçok uzaktan algılama aygıtı, maddelerin elektromanyetik enerjisini geriye aktaran ve dağıtan yüzeylerden aldığı geri bildirim ile madde ile ilgili bilgiler verir (Aggarwal, 2004).

Uzaktan algılama yöntemleri, elektromanyetik spektrumun farklı türlerdeki dalga boylarında yeryüzünün görüntülerinin alınmasını sağlar. Uzaktan algılama teknikleri ile elde edilen bir görüntünün, elektromanyetik spektrumda içerisinde bulunduğu dalga boyu

bölgesi, o görüntünün en önemli niteliklerinden biridir. Görüntülerin bir kısmı, elektromanyetik spektrumun görünür ve yakın kızılötesi bölgelerindeki geriye aktarılan güneş radyasyonunu simgelerken, diğerleri ise yeryüzünün kendisinin yaydığı enerjinin ölçümleridir. Uzaktan algılama platformunun, kendi enerjisini sağlayarak yaptığı algılama sistemi aktif uzaktan algılama sistemleridir. Uzaktan algılama platformunun, kendi enerjisini sağlamadığı ve güneş vb. başka bir enerji kaynağına bağlı olarak yaptığı algılama sistemi ise pasif uzaktan algılama sistemleridir (Aggarwal, 2004).



Şekil 2. 1. NASA MODIS Uydu Okyanus ve Denizlerin Yüzey Sıcaklığı (TUBİTAK, 2019)

Yansıtılan ya da yayılan radyant enerjinin tespiti ve kaydedilmesi, maddelerin ya da yüzey özelliklerinin tespit edilmesi ve ayrılmasıdır. Farklı nesneler, elektromanyetik spektrumun farklı bantlarında, üzerine düşen farklı miktarda enerjiyi geri döndürür. Bu, malzemenin özelliğine (yapısal, kimyasal ve fiziksel), yüzey pürüzlülüğüne, geliş açısına, yoğunluğa ve radyant enerjinin dalga boyuna bağlıdır. Uzaktan Algılama, temelde optik, spektroskopi, fotoğrafçılık, bilgisayar, elektronik ve telekomünikasyon, uydu fırlatma vb. gibi çeşitli disiplinlerin bir kombinasyonunu içeren çok disiplinli bir bilimdir (Aggarwal, 2004).

2.2. Makine Öğrenmesi

Makine öğrenmesi, bilgisayarların verileri daha faydalı kullanmasını sağlar. Bazen verilerin insanlar tarafından okunabilmesi daha zor olabilirken, bilgisayarlar için daha kolay olabilmektedir. Makine öğrenmesinin amacı, bilgisayarlara yüklenen veri setleri üzerindeki bilgileri öğrenmektir. Bilgisayarların yüklenen veri setlerinden, gerekli bilgileri alarak kendi kendine öğrenmeyi sağlaması için yıllarca çalışılmıştır. Makine

öğrenmesi, farklı algoritmalar içermekte ve verilerle ilgili sorunları bu şekilde çözümleyebilmektedir. Bilim insanları, farklı algoritmalar ile problemlerin çözülmesinin daha faydalı olduğunu düşünmektedirler. Kullanmak istenilen algoritma, çözülecek probleme, değişkenlere ve en uygun modele bağlıdır (Mahesh, 2020).

İnsanlar, günlük hayat içerisinde çok basit bir şekilde bazı sorunları çözebilir, fakat nasıl yaptıklarını açıklayamazlar. Makine öğrenmesi algoritmalarında ise, bu durumlar daha net bir şekilde anlaşılmaktadır. Fikir çok basittir. Makinelerin öğrenmesini ve tahmin gibi görevleri gerçekleştirmelerini sağlayacak bilgisayar programları yazılmaktadır. Öğrenmenin amacı, girdiyi alıp istenen sonucu üreten bir model oluşturmaktır. Bazen model anlaşılabilir olsa da, bazı zamanlarda ise işleyişi tam olarak anlaşılamayan bir kara kutu gibi de olabilir. Bilgisayarların öğrenme süreçlerinde, bazen hatalar ortaya çıkabilir. Fakat genellikle öğrenme modeli doğru cevapları verebilecektir. Bu nedenle, bir makine öğrenmesi algoritmasının performansının en önemli ölçülerinden biri sonuçların doğruluğudur (Mohammed ve ark., 2016).

Makine öğrenmesi algoritmaları denetimli, denetimsiz ve takviyeli öğrenme olmak üzere 3 farklı başlık altında incelenebilir.

2.2.1. Denetimli öğrenme

Denetimli öğrenmenin amacı, eğitim veri setlerinden bir fonksiyon ya da bir senkronizasyon çıkarmaktır. Eğitim veri seti, giriş vektörlerinden (X) oluşurken, tahmin edilen sınıflar ise çıkış vektörlerinden (Y) oluşmaktadır. Çıkış vektöründen atanan bir etiket, giriş vektöründen gelen örnek bir girişin açıklamasıdır. Bu şekilde eğitim veri seti, eğitim örneklerini içermiş olur. Giriş vektörlerinde etiketleme kullanılmayabilir. Çıkış vektörlerinde ise, eğitim veri setlerinde bulunan tüm eğitim örnekler için etiketler kullanılmaktadır. Denetleyici, bu etiketleri çıkış vektörleri için denetler. Denetleyici rolünde insanlar olabileceği gibi, bilgisayarlar da kullanılabilir. Bu noktada insanların yer alması daha pahalıdır, fakat insan yargısının üstünlüğünden kaynaklı olarak, bilgisayarlar tarafından etiketlenen verilerdeki hata oranları daha yüksek olmaktadır. Manuel olarak etiketlenen veriler, denetimli öğrenme adına oldukça değerli ve güvenilir kaynak sağlar. Bunun yanı sıra, zaman zaman bilgisayarlar da güvenilir etiketleme sağlayabilmektedir (Mohammed ve ark., 2016).

2.2.2. Denetimsiz öğrenme

Eğitim veri setlerinin ve herhangi bir denetleyicinin kullanılmadığı öğrenme türüne, denetimsiz öğrenme denir. Başka bir deyişle, kullanılan tek şey etiketlenmemiş verilerdir. Kullanılan verilerin içerisinde gizli bir yapı bulmak hedeflenmektedir. Çok sayıda veri toplama cihazıyla, artık veriler benzeri görülmemiş bir oranda toplanabilmektedir. Bu yöntemin en önemli noktalarından biri, herhangi bir denetçi kullanılmadan veri setlerinden bir şeyler elde etmektir. Bu durum, günümüzün makine öğrenmesi uygulayıcıları için zorluklar oluşturmaktadır (Mohammed ve ark., 2016).

2.2.3. Takviyeli öğrenme

Bir takviyeli öğrenme sisteminde, girdi ve çıktı çiftleri sağlamak yerine, sistemin mevcut durumu tanımlanır, bir hedef belirlenir, izin verilen eylemlerin bir listesi ve sonuçları için çevresel kısıtlamalar sağlanır ve makine öğrenmesi modelinin, ödülü en üst düzeye çıkarmak için deneme yanılma ilkesini kullanarak hedefe ulaşma sürecini kendi başına deneyimlemesine izin verilir. Takviyeli öğrenme modelleri, bilgisayar oyunları vb. sanal ortamlarda büyük başarılarla uygulanmıştır (Silver vd. 2018), fakat çevrimiçi alışveriş gibi birden fazla yapay zekâ içeren çoklu ajan sistemleri için de başarıyla uygulanabilir (Peters vd. 2013).

2.3. Literatür Taraması

Uzaktan algılama ve makine öğrenmesi teknikleri ile yeryüzü alanlarının sınıflandırmasını yapmak, bir başka deyişle yeryüzü alanlarını birbirinden ayırarak analiz edebilmek mümkündür. Uzaktan algılama sistemlerinden olan uydulardan alınan görüntüler ile yeryüzü çok geniş bir açıdan gözlemlenebilmektedir. Yine buna bağlı olarak, yeryüzü şekillerinin spektral bant parametreleri alınarak, farklı alanların sayısal anlamda analizi de yapılabilmektedir. Bunun için de, makine öğrenmesi ve derin öğrenme yaklaşımlarını kullanmak uygun olacaktır. Spektral bant parametrelerinin, makine öğrenmesi veya derin öğrenme yaklaşımları ile kullanılması sonucunda yeryüzü alanlarının sayısal anlamda sınıflandırılması mümkündür. Bu bölümde, uzaktan algılama verileri yardımıyla, sulu alanların tespiti ile ilgili yapılan bazı çalışmalar aşağıda verilmiştir.

Hui ve ark. (2008), Poyang Gölü su kütlesinin, mekansal-zamansal değişimini ve bataklık alanlardaki su baskınının zamansal sürecini haritalamak için, çok zamanlı Landsat görüntülerinin kullanımının fizibilitesini değerlendirmişlerdir. Sonuç olarak, uyduların bu alandaki su kaplamasının anlık görüntülerini yakalamak için kullanılabilmesine karşın, doğrusal enterpolasyon yoluyla bataklık alanlar üzerindeki su baskınının, mekansal-zamansal sürecini doğru tahmin edemediği tespit edilmiştir.

Du ve ark. (2012), 1973 ile 2010 yılları arasında Qingjiang Nehri Havzası yüzey suyu alanındaki değişiklikleri izlenmişlerdir. Sonuç olarak, Qingjiang Nehri Havzası'nın yüzey suyu alanının, 1980'lerden 21. yüzyılın ilk on yılına kadar, hidroelektrik kademeli gelişimiyle birlikte büyüme eğilimi gösterdiği tespit edilmiştir. Çalışma sonucunda, insan faaliyetlerinin yüzey suyunun mekansal-zamansal dağılımı üzerindeki etkisinin önemi ortaya konulmuştur.

Asmar ve ark. (2013), Nil Deltası'ndaki Burullus Lagünü'nün, 1973-2011 yılları arasındaki uydu görüntülerinden oluşturulan bir veri setini, su endeksleri yaklaşımları ile inceleyerek, yüzey alanındaki değişimi haritalandırmışlardır. Sonuç olarak, lagünün güney kenarlarında yapılan bilinçsiz tarım ve bunun sebep olduğu tarımsal atıkların etkisiyle, açık su alanının %42,8'ini kaybettiği tespit edilmiştir.

Asmar ve ark. (2014), 1973 ile 2011 yılları arasında, Damietta Nil kolu ile Port-Said arasındaki bölgeyi uydu görüntüleri ile incelemişlerdir. Damietta burnu yakınlarında kıyı erozyonunun şiddetli olduğu ve doğuya doğru azaldığı, ancak Port-Said yakınlarında, yığılmanın gözlemlendiği tespit edilmiştir. Kıyı şeridinin, yaklaşık %50'sinin erozyon, %13'ünün ise birikim altında olduğu ve ayrıca Manzala lagününün yüzey alanında, dikkate değer bir azalma (%34,5) olduğu tahmin edilmiştir.

Rokni ve ark. (2014), Urmia Gölü'nün çok zamanlı Landsat 5-TM, 7-ETM+ ve 8-OLI görüntülerini kullanarak, 2000-2013 dönemindeki uzay-zamansal değişimleri modellemişlerdir. Sonuç olarak, Urmia Gölü'nün 2000 yılına göre, yüzey alanının yaklaşık üçte birini kaybettiği görülmüş, 2010-2013 yılları arasında ise, yüzey alanında yoğun bir azalma eğilimi olduğu tespit edilmiştir. Bununla birlikte, yüzey suyu değişiminin tespiti için NDWI-PC yaklaşımının, özellikle iki ve üç farklı zaman arasındaki değişikliklerin, aynı anda tespit edilmesindeki etkinliği ortaya konulmuştur.

Cheng ve ark. (2015), Dongting Gölü'nün su yoğunluğundaki, yıllara göre son değişiklikleri anlamak ve değişiklikleri etkileyen faktörleri araştırmak için, 1996-2014 yıllarına ait Eylül ayı Landsat verilerini, MNDWI tarafından işlenmiş ve Dongting Gölü'nün su bilgileri çıkarmışlardır. Sonuç olarak, su miktarının yıllar geçtikçe azaldığı

tespit edilmiştir. Sürekli çökelti birikimi, arazilerin ıslah edilmesi ve iklimdeki değişikliklerin, su miktarının azalmasına sebep olduğunu değerlendirmişlerdir.

Acharya ve ark. (2016), 1988–2013 arasındaki 25 yıllık Landsat verilerini kullanarak, Pokhara şehrindeki göllerdeki değişimin tespit edilmesi için, Landsat endekslerini kullanmışlardır. Sonuç olarak, Phewa alanının küçüldüğü, Rupa'nın ise yüzey suyu alanının arttığı gözlemlenmiştir. Began'da çok az değişiklik olduğu ve Dipang Gölü dışındak, diğer küçük göller tespit edilememiştir. Dipang Gölü için 25 yıllık boşluğun ardından, yüzey su alanında artış olduğu görülmüştür.

Yang ve Du (2017), Çin'in Taiyuan bölgesi için, PCA gerçekleştirmek ve MNDWI'yi çıkarmak amacıyla 23 Eylül 2011'e ait bir Landsat TM görüntüsünü kullanmışlardır. Sonuç olarak, Taiyuan'ın hem kentsel alanları hem de çevresindeki dağlık alanları için, Landsat TM görüntülerinden su kütleleri çıkarılmış ve %95 genel doğruluğa ulaşılmıştır. Ayrıca, önerilen yöntemin en yüksek doğruluğa sahip olduğu ve etrafı dağlarla çevrili kentsel alanlar için, multispektral uydu görüntüleri kullanılarak su kütlelerinin çıkarılmasında önerilebileceği ortaya konulmuştur.

Naik ve ark. (2018), Andhra Pradesh'teki Nagarjuna Sagar Rezervuarında, 1989'dan 2017'ye kadar olan yüzey suyu kütlesi değişikliklerinin tespit edilmesi için, Landsat-5 TM ve Landsat-8 OLI verilerini kullanmıştır. Sonuç olarak, son yıllarda yüzey sularının değişmesi, çamur ve kumun artması nedeniyle, Gölet kritik bir konuma gelmiş olup, bu azalma eğiliminin sürekli devam etmesi durumunda rezervuarın, maksimum su yüzey alanını kaybedeceği tespit edilmiştir.

Acharya ve ark. (2019), Nepal bölgesindeki su kütlelerinin çıkarımı için, Landsat uydu görüntüleri üzerinde NDVI, NDWI, MNDWI, WRI, SWI endekslerini kullanmışlardır. Sonuç olarak, kullanılan endekslerin bitki örtüsü, buz, çayır, ıslak çorak kum vb. bölgeleri, düzgün bir şekilde ayırt edemediği tespit edilmiştir.

Çağlayan ve ark. (2020), 1985-2020 yılları arasında, Akşehir Gölü'ndeki alansal değişimi izlemişler ve elde ettikleri sonuca göre 35 yıl içinde göl alanının %90 oranında küçüldüğünü tespit etmişlerdir.

Hung ve ark. (2020), Ninh Binh ve Nam Dinh kıyı şeridini, 1988'den 2018'e kadar Landsat 5 TM ve Landsat 8 OLI/TIRS uydu görüntülerini kullanarak incelemişlerdir. Sonuç olarak, Nam Dinh bölgesinin kıyı şeridinin, 1988-2018 döneminde aşınma eğiliminde olduğu ve en fazla aşınan uzunluğun 987 m olduğu ortaya çıkmıştır.

Özelkan (2020), 2013-2017 yılları arasında Çanakkale Merkez ilçesinin tek su kaynağı olan Atıkhisar Baraj Gölü için, Landsat 8 uydu görüntülerini kullanarak oluşturulan, 3 NDWI modelinin su kütlelerini tespit yeteneği analiz etmiştir.

Yan ve ark. (2020), Tibet Platosu'nda Landsat serisi uydu görüntülerini kullanarak, hem yeni su hem de kar endekslerini test etmişlerdir. Sonuç olarak, SCG'den göl suyunun ve SCG'nin haritalandırılmasında, NDWI ve NDSI indexlerinin genel doğruluğunun %94,6–97,0 ve %94,9–97,0 aralığında olduğu tespit edilmiştir.

Bhattacharjee ve ark. (2021), 1989 ve 2019 yılları arasında Lakshmibaur-Nalair Haor bölgesindeki arazi kullanımı ve arazi örtüsü (LULC) değişikliklerini, uzaktan algılama ve coğrafi bilgi sistemi teknikleri ile Landsat multispektral görüntüleri üzerinden incelemişlerdir. Sonuç olarak, bölgenin son 30 yılda yaklaşık 2208,6 hektar (%37,54) derin su külesini ve 489,6 hektar (%8,34) bitki örtüsünü kaybettiği gözlemlenmiştir. Bununla birlikte, yaklaşık 1729 hektar (%29,39) ekili alan, 2673 hektar (%45,44) sığ su ve 1124 hektar (%28) çıplak toprak kazandığı tespit edilmiştir.

Deoli ve ark. (2021), Nainital Bölgesi'nde yer alan Bhimtal, Sattal ve Naukuchiatıl göllerinin, 2001-2018 yılları arasında Landsat-8 OLI ve Landsat-7 ETM uydu görüntülerini kullanarak, su yayılım alanlarının haritalanmasını yapmışlardır. Sonuç olarak, Sattal Gölü'nün su yüzeyi alanında Kasım'dan Şubat'a (-0,00087 km²/yıl) ve Naukuchiatıl Gölü'nün Mart'tan Haziran'a kadar (-0,00056 km²/yıl) önemli bir azalma eğilimi olduğu ortaya konulmuştur.

Chang ve ark. (2022) tarafından, Pekin, Şangay, Suzu, Hangzu ve Tokyo bölgeleri için, Landsat uydu görüntüleri kullanılarak su kütlelerinin analizi yapılmıştır. Yapılan çalışma sonucunda, MNDWI'da %3'ün üzerinde hata ile oldukça başarılı bir sonuç elde edilmiştir.

Alkan (2023) tarafından, yanmış alanlar, U-net derin öğrenme mimarisi kullanılarak uydu görüntülerinden tespit edilmiştir. Sonuç olarak, farklı eşik değerlerinde en yüksek %97'lik bir doğruluğa ulaşılmıştır.

Bu ve benzer alanlarda birçok çalışma yapılmış olup, başarılı sonuçlar elde edilmiştir. Bu tez çalışmasında, Landsat uydu görüntüleri kullanılarak bir veri seti oluşturulmuş ve farklı makine öğrenmesi yaklaşımları ile bu veriler analiz edilmiştir. Aynı zamanda “Google Earth Engine Code Editor” vasıtasıyla, Batman Çayı su yolunun yıllara göre değişimi incelenmiştir. Bununla birlikte ise su yolunun sabitlenmesi durumunda, tarım vb. alanlar için kazandırılacak bölgeler analiz edilmiştir. Bu analiz, çalışmaya özgünlük katmıştır. Ayrıca bu çalışma, geçmişte yapılan çalışmaların çoğunu

destekler niteliktedir. Sonuç olarak, kazandırılacak alanların hem ülke ekonomisine hem de bölge halkına yarar sağlayacağı düşünülmektedir.

3. YÖNTEM

Bu aşamada, GEE kullanılarak yıllara göre uzaktan algılama teknikleri yardımıyla, Landsat-7 ve Landsat-8 uydu görüntüleri incelenmiştir. İncelenen uydu görüntüleri ile Batman Çayı'nın akış rejiminin değişimi gözlemlenmiştir. Ek olarak ilgili yıllardaki yeryüzü yansımaları değerleri GEE üzerinden Landsat-7 uydu görüntülerinden alınmış ve farklı makine öğrenmesi teknikleri (Karar Ağaçları, Destek Vektör Makinesi, K-En Yakın Komşular Topluluk Öğrenimi, Yapay Sinir Ağları ve Kernel Yaklaşım Algoritmaları) kullanılarak incelenmiştir.


3.1. Çalışma Alanı

Bu kısımda, Batman Çayı nehir yatağını içeren bir çalışma alanı belirlenmiştir. Batman çayı, Diyarbakır ile Batman İl sınırı boyunca güneye doğru akmakta ve Oymataş köyü sınırlarında Dicle nehri ile birleşmektedir (Şekil 3.1).




Şekil 3. 1. Çalışma Alanı-1 (GEE Platformu, 2024)

Şekil 3.2’de Batman Çayı, Dicle Nehri ve Ilısu Baraj gölü bağlantısı görülmektedir. Ilısu Barajı’nın faaliyete geçmesinin ardından Batman Çayı ile Dicle Nehrinin birleştiği bölgede su yüzey genişliğinin arttığı görülmektedir.



Şekil 3. 2. Batman Çayı, Dicle Nehri ve Ilisu Baraj Gölü (GEE Platformu, 2025)

Çalışma alanı olarak belirlenen, Batman Barajının da bulunduğu Çatakköprü Bucağı ile Oymataş bölgeleri arasında kalan bu alan, yaklaşık 4370.8 hektarlık (43.7 km²) alana tekabül etmektedir. Şekil 3.3’de görüldüğü gibi, Batman Çay Yatağı içerisinde kalan Batman Çayı’nın kapsadığı alanın çay yatağına göre oldukça küçük olduğu değerlendirilebilir. Buradan da anlaşılabileceği üzere Batman Çayı’nın yıllarca değişime uğraması sonucunda ortaya çıkan atıl bölgelerin oldukça fazla bir alanı kapsadığı görülmektedir.



Şekil 3. 3. Çalışma Alanı-2 (GEE Platformu, 2024)

Çalışma alanının kuzeyinde yer alan Malabadi köprüsünden güneyde Diyarbakır köprüsüne kadar Batman Çayına katılan 20 yan derenin bulunduğu bildirilmektedir (Efe, 2015).


3.2. Önerilen Sistem Mimarisi

Önerilen sistem mimarisi sırasıyla;

1. Uzaktan algılama yöntemi için, çalışma alanı içerisinde su ve atıl alanları temsil eden örnek noktaların seçilmesi,
2. Seçilen noktaların çalışma için belirlenen zaman aralığında, Landsat 7 uyduları üzerinden spektral bant parametrelerinin elde edilmesi,
3. Elde edilen bant parametrelerinin sınıflara ayrılması,
4. Sınıflara ayrılan veri setlerine, makine öğrenmesi yaklaşımının uygulanması,

5. Uygulama sonucunda elde edilen sulu alan ve atıl alanların tespiti.

Bu tez çalışmasında uygulanacak olan önerilen sistem mimarisi Şekil-3.4'te görüldüğü gibidir.



Şekil 3. 4. Sistem Mimarisi

3.3. Veri Seti Oluřturma

Çalışmanın bu bölümünde, GEE üzerinden belirlemiş olduğumuz çalışma alanı içerisinde, Batman Çayı su yolu değışiminin daha net anlaşılabilmesi adına, 2000 yılındaki uydu görüntüsü üzerinden, Şekil 3.5'te görüldüğü gibi referans olabilecek 80 adet nokta seçilmiştir. Bu noktaların, mavi renkte olan 40 tanesi Batman Çayı yüzey alanından seçilmiş olup su alanlarını temsil etmekteyken, diğery beyaz renkte olan 40 nokta ise, Batman Çayı su yolu kenarında bulunan atıl alanların içerisinde seçilmiştir.

Landsat 7 uydusu üzerinden, bu noktaların 2000-2024 yılları arasındaki spektral bant parametreleri, 3 bant üzerinden (RGB) alınmıştır. Sulu bölge ve atıl alanlar için alınan veriler, iki ayrı sınıf olacak şekilde veri setine dönüřtürülmüştür.




Şekil 3. 5. Çalışma Alanı İçerisinden Seçilen Su (Mavi) ve Atıl Alanları (Beyaz) Temsil Eden Noktalar (GEE Platformu, 2024)

3.3.1. Landsat 1-9 Uydu Serisi

Planlama ve operasyon sürecinin 50 yılın üzerinde olduğu, Landsat uydu programı çok yönlü olmasının yanında, oldukça karmaşıktır. Her bir Landsat görevi, görev edinme (yani planlama, finansman, inşa, fırlatma öncesi aktivite) ve verileri ve ilgili yönetim aktivitelerini (örneğin görüntü planlama, uydu-yer bağlantısı, arşivleme, yayma) içeren görev operasyonları tarafından değerlendirilebilir. Görev edinme, büyük ölçüde NASA'nın görev alanı olmuştur ve sorumluluklar şu anda NASA (uzay bölümü) ve USGS (yer bölümü) arasında bölünmüştür. Landsat 4 ve 5 görevleri, NOAA (Ulusal Okyanus

ve Atmosfer İdaresi) ile yapılan sözleşmelere göre ticari bir sorumluluk olmuştur. Aynı zamanda, bu sorumluluğa veri dağıtımı ve arşivleme de dâhildir. Veri dağıtımı ve arşivleme, 2001 yılından beri USGS tarafından yapılmaktadır. Landsat 1 uydusu için görev süreci, 1967'de NASA tarafından başlatılmış ve yaklaşık 5 yıl sonra 23 Temmuz 1972'de uzaya fırlatılmıştır (Goward ve ark., 2017). Landsat 1 uydusunun fırlatıldığı tarihten bu yana, sürekli olarak yörüngede bulunan ve çalışmaya devam eden en az bir adet Landsat uydusu olmuştur (Wulder ve ark., 2008). Landsat 5'in dikkate değer 29 yıllık ömrü (3 yıllık tasarım ömrüyle birlikte), Landsat 6'nın yörüngeye ulaşamama sorununu hafifletmiştir. Şekil-3.5'te Landsat görev serisi ve yönetim geçmişi ile altmış yıllık program yönetimi sorumlulukları görülmektedir. Kırık çubuklar, beklenen gelecekteki yönetim planlarını belirtmektedir (Wulder, 2019).



Şekil 3. 6. Landsat Uydu Serisi (Wulder, 2019)

Çalışmada kullanılan Landsat 7 ve 8 uydu görüntülerinin ön işlem aşamasından sonra yüzey yansımalarını temsil eden görüntülere ait band ve band özelliklerine ilişkin bilgiler, Çizelge 3.1 ve 3.2’de gösterilmiştir.

Çizelge 3. 1. Landsat-7 Uydusu Yüzey Yansımaları Bandları (GEE Platformu, 2024)

Landsat-7 Uydusu Yeryüzü Yansıma Bantları	Açıklama
SR_B1	Mavi Yeryüzü Yansıma Bandı
SR_B2	Yeşil Yeryüzü Yansıma Bandı
SR_B3	Kırmızı Yeryüzü Yansıma Bandı
SR_B4	Yakın Kızılötesi Yeryüzü Yansıma Bandı
SR_B5	Kısa Dalga Kızılötesi-1 Yeryüzü Yansıma Bandı
SR_B6	-
SR_B7	Kısa Dalga Kızılötesi-2 Yeryüzü Yansıma Bandı

Çizelge 3. 2. Landsat-8 Uydusu Yüzey Yansımaları Bandları (GEE Platformu, 2024)

Landsat-8 Uydusu Yeryüzü Yansıma Bantları	Açıklama
SR_B1	Ultra Mavi Yeryüzü Yansıma Bandı
SR_B2	Mavi Yeryüzü Yansıma Bandı
SR_B3	Yeşil Yeryüzü Yansıma Bandı
SR_B4	Kırmızı Yeryüzü Yansıma Bandı
SR_B5	Yakın Kızılötesi Yeryüzü Yansıma Bandı
SR_B6	Kısa Dalga Kızılötesi-1 Yeryüzü Yansıma Bandı
SR_B7	Kısa Dalga Kızılötesi-2 Yeryüzü Yansıma Bandı

3.3.2. Google earth engine

Google Earth Engine, inceleme ve analiz amacıyla petabayta kadar ulaşan veri kümelerini depolamak ve işlemek üzere tasarlanmış bir platformdur (Kumar ve Mutanga, 2018). 2008 yılında, Landsat uydu serisi görüntülerinin kullanımı ücretsiz olmuştur. Bu gelişmenin ardından Google, tüm veri kümelerini arşivleyerek platformun kullanımını açık hale getirmiştir. Bu sayede, isteyen herkes bu platform üzerinde çalışma yapabilmektedir. Google Earth Engine platformunun veri arşivi içerisinde, uydu görüntülerinin yanı sıra, Coğrafi Bilgi Sistemleri tabanlı vektör veri kümeleri, sosyal, demografik, hava durumu, dijital yükseklik modelleri ve iklim veri katmanları bulunmaktadır.

Her kullanıcı, Google bulut kaynakları içerisinde, uydu görüntüleri vasıtasıyla kendi verilerini oluşturarak, çalışmalar yapabilmektedir. Google'ın sağlamış olduğu bu ücretsiz ve kolay erişim, yalnızca bilim insanları için değil, tüm insanlar adına uzaktan algılama, geniş alan gözetlemesi, coğrafi analizler, harita oluşturma vb. alanlarda, bu kaynakların kullanılmasına olanak sağlamaktadır. En yeni bilgisayarların veya en son yazılımların büyük işlem gücüne ihtiyaç duyulmamaktadır. Aynı zamanda bu, araştırmacıların dünyanın en az gelişmiş ülkelerinde bulunan sınırlı kaynaklar açısından, en gelişmiş ülkelerdekilerle aynı analizleri yapma becerisine sahip olmalarına imkân sağlamıştır (Google, 2024).

3.4. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi, farklı algoritmalar ile çözülmesi istenilen problemleri çözebilmektedir. Problemi çözebilmek için kullanılacak model seçiminde, çözmek istenilen problem, değişken sayısı, kullanılan algoritma vb. faktörler etkilidir. Bu çalışmada kullanılan makine öğrenmesi algoritmaları Karar Ağacı, Destek Vektör Makinesi, K-En Yakın Komşular, Topluluk Sınıflandırıcısı, Kernel Yaklaşım Sınıflandırıcısı ve Yapay Sinir Ağı modellerinden oluşmaktadır.

3.4.1. Karar ağacı modeli

Karar Ağaçları, makine öğrenmesi yaklaşımının denetimli öğrenme türlerinden biridir. Sınıflandırma ve regresyon için kullanılabilir. Bu algoritma ile basit karar

kuralları kullanılarak veri özellikleri çıkarılır. Çıkarılan veri özellikleri ile hedef değişken tahmin edilebilir. Bu model, dallardan oluşmaktadır. Her dal için yeni özellik çıkarımı yapılabilir. Dolayısıyla dal sayısının artması ile özellik çıkarımı da artacağından, model karmaşıklılaşsa da tahminlerin doğruluk oranları artacaktır. (Sonquist ve Morgan, 1970).

Karar Ağaçlarının bazı avantajları;

- Algoritmayı anlamak kolay olduğundan, yorumlaması da kolaydır.
- Az veri seti ile çalışma yapılabilir.
- Ağaçtaki dal sayısı arttıkça, veri tahmin yeteneği eğitim verilerine göre logaritmik olarak artar.
- Farklı türlerdeki verileri işleyebilir.
- İç yapısı anlaşılır bir model olduğundan, koşulların açıklanması 1 ve 0'lar ile kolayca açıklanabilir.
- Farklı istatistiksel testler kullanılabildiğinden, modelin güvenilirliği öngörülebilir (Breiman ve ark., 1984).

Karar Ağaçlarının bazı dezavantajları şunlardır:

- Verileri iyi genelleştirmeyen, aşırı karmaşık ağaç dalları oluşturulmasına aşırı uyum denir. Bu sebeple model düzgün çalışmayabilir. Bu sorunun önüne geçebilmek için, dal sayısını azaltmak gerekmektedir. Modelin öğrenmesinde işe yaramayacak olan dallar budanmalıdır.
- Veri setlerindeki küçük farklar sebebiyle, tamamen farklı ağaç dalları oluşabilir. Bu sebeple, küçük farklar içeren veri setlerinde model düzgün çalışmayabilir.
- Karar Ağaçlarının tahminleri, parça parça sabit yaklaşımlar olup, ne düzgün ne de sürekli.
- Veri seti dengelenmeden bu modele sokulduğunda, bazı sınıfların baskın olmasıyla önyargılı ağaçlar oluşur ve sonuçlar istenildiği gibi olmayabilir (Quinlan, 1993).

Karar Ağaçları algoritmasının matematiksel eşitliği, aşağıdaki gibidir. Verilen eğitim vektörleri x ile, bir etiket vektörü y ile, düğümdeki veriler m ile, örnekler Q_m ve n_m ile, bir özellikten oluşan eşik verileri j ve t_m ile, her aday bölünmesi $\theta=(j,t_m)$ ile, safsızlık fonksiyonu G ile ve seçilen çözülmüş görevler H ile

gösterilmiştir. $Q_m^{\text{left}}(\theta)$ ve $Q_m^{\text{right}}(\theta)$ ise alt kümeleri temsil etmektedir (Hastie, 2009).

$$Q_m^{\text{left}}(\theta) = \{(x, y) | x_j \leq t_m\} \quad (3.1)$$

$$Q_m^{\text{right}}(\theta) = Q_m \setminus Q_m^{\text{left}}(\theta) \quad (3.2)$$


$$G(Q_m, \theta) = \frac{n_m^{\text{left}}}{n_m} H(Q_m^{\text{left}}(\theta)) + \frac{n_m^{\text{right}}}{n_m} H(Q_m^{\text{right}}(\theta)) \quad (3.3)$$

3.4.2. Destek vektör makinesi

Destek Vektör Makinesi modeli, makine öğrenmesi yaklaşımının en çok kullanılan model türlerinden biridir. Destek Vektör Makineleri modeli ile sınıflandırma ve regresyon analizi yapılmaktadır. Denetimli öğrenme türlerinden olan bu model, veri setlerini analiz eden ilişkili öğrenme algoritmalarından oluşur (Vapnik ve Chervonenkis, 1992). Destek Vektör Makineleri doğrusal sınıflandırma yapabildiği gibi, doğrusal olmayan sınıflandırmaları da yapabilmek adına farklı çekirdek hileleri kullanabilmektedir. Giriş verilerini, yüksek boyutlu özellik alanlarına gizlice eşleyebilir. Basit bir mantıkla, farklı sınıflar arasında boşluklar oluşturur (Şekil 3.7). Sınıflar arasında oluşturduğu boşluklar arasındaki mesafeyi olabildiğince açarak, sınıflandırma aşamasındaki hataları en aza indirmeyi amaçlar (Mahesh, 2020).

Destek Vektör Makinesi modelinin matematiksel eşitliği, aşağıdaki gibidir. Eşitlikte verilen x ve y değerleri destek vektörlerini, w minimuma indiren parametre değerini, b ise tüm destek vektörlerin ortalamasını temsil etmektedir (Wu ve ark., 2004).

$$i = 1 \dots n \quad Y_i((w, X_i) + b) \geq 1 \quad (3.4)$$



Şekil 3. 7. DVM Modeli (Cano, Research Gate, 2018)

3.4.3. K-En yakın komşular

Eğitim verilerini kaydederek, genel bir model oluşturmadan veri komşularına bağlı olarak yapılan örnek tabanlı öğrenme türüne denir. Her noktanın en yakın komşularının, basit çoğunluk oyuyla sınıflandırma yapar. Bir noktanın en yakın komşuları içinde, en fazla temsilciye sahip olan veri sınıfı, sorgu noktasına atanır (Hodges, 1965).

K-En Yakın Komşular algoritması, içerdiği sorgu noktalarının en yakın komşularına bağlı olan öğrenme türüdür. Buradaki k değeri, bir tam sayı olmakla birlikte, kullanıcı tarafından belirlenir. Bu algoritmada değerin optimum seçimi, büyük ölçüde veriye bağlıdır. K değerinin büyük olarak seçilmesi, genel olarak gürültünün etkilerini azaltmaktadır, fakat bu sebeple sınıflandırmadaki belirginlik azalacak ve doğruluk oranı düşecektir (Thomas ve Hart, 1967).

Sorgu noktalarına atanan değerler, en yakın komşularının çoğunluk oylarıyla hesaplanmaktadır. Bir başka deyişle, en yakın komşu sınıflandırması aynı biçimdeki ağırlıkları kullanır. Bazı veri setleri için, komşuları kendilerine daha yakın olan komşular ile uyumlu ağırlıklandırmak, modele daha fazla katkıda bulunabilir. Kullanıcının tanımlayacağı bir fonksiyon ile ağırlıklar belirlenebilir (Goldberger ve ark., 2005).

K-En Yakın Komşular algoritmasının matematiksel eşitliği, aşağıdaki gibidir. Eşitlikte verilen N değeri n boyutlu gerçek uzayı, i ve j döngü sayısını, p ise olasılığı temsil etmektedir (Goldberger ve ark., 2005).

$$\arg_L \max \sum_{i=0}^{N-1} p_i \quad (3.5)$$

$$p_i = \sum_{j \in C_i} p_{ij} \quad (3.6)$$

3.4.4. Topluluk öğrenimi

Topluluk öğrenimi, birden fazla modelin birleştirilmesi ile oluşturularak, bir problemin çözümlenmesini sağlayan algoritmalarındandır. Topluluk öğrenimi algoritmasının kullanılma amacı, modelin performansını arttırmaktır. Aynı zamanda, problem için yanlış model seçilmesi olasılığını azaltmaktadır. Topluluk öğreniminin diğer uygulamaları arasında, modelin verdiği kararın güvenilirliğini arttırma, en uygun özellikleri seçme, veri setlerini birleştirme, daha önceki bilgilerin üzerine yeni bilgileri katma ve hata düzeltme gibi özellikler bulunmaktadır (Mahesh, 2020).

Topluluk öğrenimi, belirli öğrenme algoritmalarından oluşan birkaç modelin tahminlerini birleştirebilir. Bu sayede ise, tek bir tahmin modelinin sağlamlığını geliştirmiş olur. Topluluk yöntemlerinin iki çok ünlü örneği, eğitim artırılmış ağaçlar ve rastgele ormanlardır. Daha genel olarak, topluluk modelleri, Bagging yöntemleri, model istifleme, oylama gibi ortalama yöntemlerinde veya AdaBoost gibi artırmada ağaçların ötesinde herhangi bir temel öğreniciye uygulanabilir (Drucker, 1997).

Topluluk algoritmasının matematiksel eşitliği, aşağıdaki gibidir. Eşitlikte verilen F fonksiyonu, m döngü sayısını, h ise olasılığı temsil etmektedir (Freund ve Schapire, 1995).

$$F_M(x_i) = \sum_m h_m(x_i) \quad (3.7)$$

3.4.5. Kernel yaklaşım sınıflandırıcısı

Çekirdekler, GP'nin öncesinin ve sonrasının şeklini belirleyen, önemli bir bileşenidir. Veri noktalarının benzerliklerini değerlendirerek, birbirine benzeyen veri noktalarının da benzer hedef değerlerine sahip olması gerektiğini varsayarak birleştirirler. Daha sonra, bu fonksiyonu kodlarlar. Kernel algoritması, iki farklı başlıkla incelenebilir. Bunlardan ilki olan durağan çekirdekler, sadece iki veri noktasının mesafesine bağlı

olarak değişir, fakat mutlak değerlerine bağlı değildir ve bu sebeple giriş alanındaki çevrilere karşı değişmezdir. Durağan çekirdekler aynı zamanda izotropik ve anizotropik çekirdeklere ayrılabilir, burada izotropik çekirdekler giriş alanındaki dönüşlere karşı da değişmezdir. Diğer kernel türü ise durağan olmayan çekirdeklerdir. Durağan olmayan çekirdekler, veri noktalarının belirli değerlerine bağlıdır (Driscoll, 1973).

Çekirdek yaklaşım sınıflandırıcısı algoritmasının matematiksel eşitliği, aşağıdaki gibidir. Eşitlikte verilen k çekirdekleri, x giriş verilerini, i ve j döngü sayılarını ve v ise içi ürün uzayını temsil etmektedir (Rasmussen ve Williams, 2006).


$$k(x_i x_j) = \frac{1}{\Gamma(v)2^{v-1}} \left(\frac{\sqrt{2v}}{l} d(x_i x_j) \right)^v K_v \left(\frac{\sqrt{2v}}{l} d(x_i x_j) \right) \quad (3.8)$$

3.4.6. Yapay sinir ağları

Yapay Sinir Ağı, bir veri kümesindeki bilgileri, insan beynindeki nöronlara benzer şekilde çalışarak, tanımayabilen algoritma türüdür. Buradan da anlaşılacağı gibi, Yapay Sinir Ağları, insan beynindeki nöronlara eşdeğer olması için yapılmış, yapay nöronlardır. Yapay Sinir Ağları, giriş verilerinin değişmesinden etkilenmez. Bu sayede algoritma, çıkış verilerini elde etmede, herhangi bir ekstra ihtiyaç duymadan elde edebileceği en iyi sonucu oluşturur. Yapay zekâdan geliştirilen bu algoritma, özellikle ticari sektörlerde oldukça popüler olarak kullanılmaktadır.

Yapay Sinir Ağları; giriş, gizli ve çıkış katmanı olmak üzere üç katmandan oluşur (Şekil 3.8). Giriş katmanı, adından da anlaşılacağı üzere giriş verilerini alır. Gizli katman ise, giriş verileri üzerinde işlemler yapar. Son olarak çıkış katmanı ise, kendisine gelen verileri hesaplayarak çıkış verisi üretir (Mahesh, 2020).

Çok katmanlı perceptron, giriş ve çıkış verilerinin boyut sayısından oluşan bir veri seti üzerinde eğitim alarak, bir fonksiyonu öğrenen denetimli öğrenme algoritmasıdır (Rosenblatt, 1960). Bu algoritmada sınıflandırma veya regresyon yapılabilmesi için, bir miktar özelliğin ve hedeflerin verilmesi yeterlidir. Algoritma veri setinden aldığı bilgilerle, doğrusal olmayan bir fonksiyon oluşturarak, öğrenmeyi gerçekleştirir. Giriş ve çıkış katmanları arasında, bir veya daha fazla gizli katman bulundurması sebebiyle, lojistik regresyondan ayrılır (Lecun ve ark., 1998).



Şekil 3. 8. YSA Modeli (Cano, Research Gate, 2018)

YSA matematiksel eşitliği, aşağıdaki gibidir. Eşitlikte verilen, x giriş verilerini, i ve n döngü sayılarını, W ağırlıkları ve y ise çıkış verilerini temsil etmektedir (Rosenblatt, 1960).

$$y = \sum_{i=0}^n W_i x_i \quad ya \ da \ v = \sum_{i=0}^n W_i x_i + b, \quad y = \varphi(v) \quad (3.9)$$

3.5. Karışıklık Matrisi

Günlük hayattaki ihtiyaçlar ile ortaya çıkan bazı işlerin kolaylaştırılması için, sınıflandırma algoritmaları ve modeller kullanılmaktadır. Bu modeller, sonlu olan bir veri setine göre tahmin yapabilirler. Fakat bu tahminleri kusursuz olarak yapamazlar ve bazı veriler hedeflenen değerlerle uyuşmayabilir. İşte bu modellerin, başarı durumlarını değerlendirmek için karışıklık matrisi oluşturulmuştur. Bu matris, modelin performansı ile ilgili gerekli bilgileri tablo şeklinde vererek, modeli değerlendirmemizi sağlar (Room, 2019).

Bir anlamda, bu matris gerçek değerleri ve tahmin edilen değerleri gösterir (Şekil 3.10). Sınıf sayısına göre, gerçek değerler ayrı sütunlarda gösterilir. Her sınıf için doğru ve yanlış tahmin edilen değerler de, satırlarda gösterilir. Örneğin, su ve toprak başlıkları altında iki farklı sınıf olduğunu varsayarsak, aslında "toprak" olan verilerin, "su" olarak öngörüldüğünü kayıt edebilir. Bu sayede modelin performansı görülmüş olur (Room, 2019).

Karmaşıklık matrisi, sadece ikili sınıflandırmada değil, çoklu sınıflandırma problemlerinde de oldukça kullanışlıdır. Matristen hesaplanabilen birçok performans ölçütü vardır (Room, 2019).

Gerçek Değer			
Tahmin edilen değer		Doğrular	Yanlışlar
		Doğrular	Yanlışlar
	Doğrular	DP (TP) Doğru Pozitif (True Positive)	YP (FP) Yanlış Pozitif (False Positive)
	Yanlışlar	YN (FN) Yanlış Negatif (False Negative)	DN (TN) Doğru Negatif (True Negative)

Şekil 3. 9. Karışıklık Matrisi (Room, 2019)

3.5.1. Doğruluk

Karışıklık matrisinin her sınıf için doğru tahmin edilen değerlerin, toplam veri sayısına olan oranına doğruluk oranı denir. Bu orana bağlı olarak, modelin ne kadar başarılı olduğu değerlendirilebilir. Doğruluk oranı arttıkça, modelin güvenilirliği de artacaktır. Formülü aşağıda verildiği gibidir.

$$\text{Doğruluk}(\text{Accuracy}) = \frac{TP+TN}{\text{TOPLAM}} \quad (3.10)$$

3.5.2. Hata oranı

Karışıklık matrisinin hata oranı, her sınıf için yanlış tahmin edilen veri sayısı toplamının, toplam veri sayısına oranıdır. Aynı zamanda 1'den doğruluk oranının çıkarılması ile hesaplanır.

$$\text{Hata Oranı}(\text{Error Rat}) = \frac{FP+FN}{\text{TOPLAM}} \quad (3.11)$$

$$\text{Hata Oranı} = 1 - \text{Doğruluk} \quad (3.12)$$

3.5.3. Hassasiyet

Hassasiyet, pozitif sınıf tahminlerinin, gerçekten söz konusu sınıfa ait olma oranıdır. Kesinliği anlamının bir başka yolu da, rastgele seçilen bir örneğin, belirli bir sınıfa ait olma olasılığını ölçmesidir.

$$Hassasiyet(Precision) = \frac{TP}{TP+FP} \quad (3.13)$$

3.5.4. Duyarlılık

Gerçek pozitif örneklerin, ne kadarının pozitif olarak sınıflandırıldığını gösterir.

$$Duyarlılık(Recall) = \frac{TP}{TP+FN} \quad (3.14)$$

3.5.5. F1 skor

F1 Skor ise Hassasiyet (Precision) ve Duyarlılık (Recall) skorlarının harmonik ortalamasıdır.

$$F1\ Skor = \frac{2*(Precision*Recall)}{Precision+Recall} \quad (3.15)$$

3.6. ROC Eğrisi

Sinyal algılama teorisinde, alıcı işletim karakteristiği olarak tanımlanmaktadır. İkili sınıflandırma sistemlerinde, her iki sınıf arasındaki eşik değerlerinin farklı olduğu zamanlarda, ROC eğrisi hassasiyetin kesinliğe olan oranıyla belirlenmektedir. ROC eğrisi doğru pozitif değerlerin, yanlış pozitiflere oranıyla da elde edilebilmektedir. (Swets, 1996).


Sınıflandırma işlemlerindeki başarının artırılması için, algoritmanın kesinlik ve hassasiyeti arasında denge sağlanmalıdır. Kesinlik ve hassasiyet arasındaki bu dengenin kurulabilmesi için ise, veri setlerindeki pozitif ve negatif örneklerin eşit bir dağılım göstermeyeceği göz önüne alındığında, ROC eğrisinden elde edilecek veriler ile

değerlendirmeler yapılabilir (Gribskov ve Robinson, 1996). ROC eğrisinin altında kalan alan AUC olarak adlandırılır. ROC eğrisi, sınıflandırma için belirlenen eşik değerlerine bağlı olarak, algoritmalarından elde edilen doğru pozitiflerin sayısının, yanlış pozitiflerin bir fonksiyonu olarak çizilmesinden oluşmaktadır. ROC puanının 1 olması, model performansının %100 başarı sağlaması anlamına gelirken, 0 olması ise, model performansının tamamen başarısız olduğunu gösterir (Swets, 1996).

4. BULGULAR VE TARTIŞMA

4.1. Google Earth Engine Kullanılarak Elde Edilen Veriler


Batman Çayı'nın su yolu incelemesini yaptığımız bu çalışmada, 2000 ile 2024 yılları arasındaki değişimler değerlendirilmiştir. Bu zaman aralığında, her 5 yılda bir (2020-2024 arasında 4 yıl) Batman Çayı'nın takip ettiği, ortalama su yolu gözlemlenmiştir. Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6'da 2000-2024 yılları arasındaki su yolu, çalışma alanının kuzeyinden güneyine doğru sıralanmış bir şekilde gösterilmiştir.



Şekil 4. 1. Batman Çayı Su Yolu Karşılaştırılması-1 (GEE Platformu, 2024)


Şekil 4.1'de çalışma alanının en kuzey noktası olan Çatakköprü mevkiinin hemen güneyinde yer alan bölgelerde, Batman Çayı'nın her 5 yıldaki ortalama su yolu ile birlikte atıl alanlar görülmektedir. Şekil 4.1 incelendiğinde, Batman Çayı su yolunun 24 yıl içerisindeki zaman aralığında, nasıl bir değişime uğradığı net bir şekilde görülmektedir.

Her 5 yıl için, farklı renklerle gösterilen su yolları arasındaki farklar, gözler önüne serilmektedir.




Şekil 4. 2. Batman Çayı Su Yolu Karşılaştırılması-2 (GEE Platformu, 2024)

Şekil 4.2’de çalışma alanının kuzey bölgesinde yer alan Düvecik mevkiinin hemen güneyindeki bölgelerde, Batman Çayı’nın her 5 yıldaki ortalama su yolu ile birlikte atıl alanlar görülmektedir. Buradan çıkarılacak sonuca bakıldığında, yine Batman Çayı su yolunun 24 yıl içerisindeki zaman aralığında uğradığı değişim, Şekil 4.1’dekine benzer olarak net bir şekilde görülmektedir. Farklı zamanlardaki, su yolları arasındaki farklar görülmektedir.




Şekil 4. 3. Batman Çayı Su Yolu Karşılaştırılması-3 (GEE Platformu, 2024)

Şekil 4.3’de yine önceki görsellere benzer olarak, Batman Çayı su yolunun 24 yıl içerisindeki zaman aralığında uğradığı değişim net şekilde görülmektedir. Burada dikkat çeken bir diğer nokta ise, atıl alanların ciddi miktarda bir alanı kapsamasıdır.




Şekil 4. 4. Batman Çayı Su Yolu Karşılaştırılması-4 (GEE Platformu, 2024)

Şekil 4.4'te Batman Çayı'nın, havalimanının hemen batısında kalan alanları görülmektedir. Bu görselde de, yine önceki görsellere benzer olarak, Batman Çayı su yolunun 24 yıl içerisindeki zaman aralığında, uğradığı değişim net şekilde görülmektedir. Burada dikkat çeken bir diğer nokta ise, görselin güney kısmında yer alan alanlarda, Batman Çayı su yolunun önceki görsellere göre daha sabit olduğudur.



Şekil 4. 5. Batman Çayı Su Yolu Karşılaştırılması-5 (GEE Platformu, 2024)

Şekil 4.5'te havalimanının güneyinde kalan alanlardaki, Batman Çayı su yolu görülmektedir. Bu görselde de, yine önceki görsellere benzer olarak Batman Çayı su yolunun 24 yıl içerisindeki zaman aralığında uğradığı değişim net şekilde görülmektedir. Burada dikkat çeken bir diğer nokta ise, görselin güney kısmında yer alan alanlarda Batman Çayı su yolunun, özellikle sarı ve turuncu (2020-2024) olarak renklendirilmiş olan yıllar arasında, daha genişlediği görülmektedir.



Şekil 4. 6. Batman Çayı Su Yolu Karşılaştırılması-6 (GEE Platformu, 2024)

Şekil 4.6’da çalışma alanının en güney ucu olan Oymataş mevki kuzeyinde kalan alanlardaki, Batman Çayı su yolu görülmektedir. Burada dikkat çeken nokta ise, bir önceki görselde olduğu gibi, Batman Çayı su yolunun özellikle sarı (2020) olarak renklendirilmiş olan zamanda, oldukça genişlediğidir.

Yukarıdaki şekiller incelendiğinde, 2000-2024 yılları arasındaki, Batman Çayı Su yolu üzerinde meydana gelen değişiklikler göze çarpmaktadır. 2018 yılında yapılan Ilısu Barajı’nın etkisi ise, 2020 ve 2024 yıllarında net şekilde ortaya çıkmaktadır. Özellikle Oymataş bölgesinin olduğu mevkide, su yolu ciddi miktarda genişlemiştir.

Sonuç olarak ise, 2000-2024 yılları arasında Batman Çayı’nın takip ettiği su yolları, farklı renkler kullanılarak gösterilmiştir (2000-Mor, 2005-Mavi, 2010-Turkuaz, 2015-Yeşil, 2020-Sarı, 2024-Turuncu). Elde edilen bu veriler ışığında, Batman Çayı’nın yaklaşık 25 yıllık zaman aralığı içerisinde yaşamış olduğu değişim, ortaya çıkmaktadır.

Bu deęişimlerden de yola çıkarak, Batman Çayı etrafındaki atıl bölge olarak nitelendirebileceğimiz alanların, nasıl oluştuęu da anlaşılmaktadır. Oymataş bölgesi mevkiinde, Ilısu Barajı'nın faaliyete geçmesinin ardından, su yolunun genişledięi düşünöldüğünde, o bölgede herhangi bir atıl alanın kalmadığı deęerlendirilebilir. O bölgenin kuzeyinde kalan alanlar için ise, su yolu genişliğinin daha dar olmasından dolayı, atıl bölgelerin de ciddi miktarda yer kapladığı görölmektedir. Su yolunun sürekli deęişiminden kaynaklı olarak ortaya çıkan, bu atıl bölgelerin tarım vb. amaçlarla ölk ekonomisine kazandırılabilceęi düşünölmektedir.

4.2. Makine Öğrenmesi Kullanılarak Elde Edilen Veriler

2020-2024 yılları arasında, belirlenen noktalardan alınan spektral bant parametreleri ile oluşturulan veri setleri, makine öğrenmesi yaklaşımı vasıtasıyla farklı algoritmalara öğretilmiş ve her iki alan için sınıflandırma çalışması yapılmıştır. Bu çalışma ile deęişen yıllarla birlikte, sulu alan ile atıl bölge arasındaki ilişkinin incelenmesi amaçlanmıştır.

2000-2003 yılları arasındaki yansıma deęerlerini içeren veri seti, K-Cross Validation (çapraz doęrulama) ile alt veri gruplarına ayrılmıştır. Deęişik K deęerleri denenmiş ve sistem başarısı incelenmiştir. K deęerinin sistem performansını çok etkilemedięi görölmüştür. K deęeri 5 alınarak Karar Ağaçları, Destek Vektör Makinesi, K-En Yakın Komşular, Topluluk Sınıflandırıcısı, Kernel Yaklaşım Sınıflandırıcısı ve Yapay Sinir Ağları algoritmaları eğitilmiştir. Sonrasında eğitilen sisteme, 2016 sonrası yıllardaki yansıma deęerlerini içeren veri seti, test amaçlı yüklenmiştir. Son olarak ise 2016 sonrası yıllardaki yansıma deęerleri düzenlenerek, tekrardan sisteme test amaçlı yüklenmiştir.

Sonuç olarak, bu çalışma ile Batman Çayı su yolunu analiz etmek için, 2000-2003 yılları arasındaki veri setinden elde edilen sonuçlar, 2016 sonrası yıllardaki veri setlerinden elde edilen sonuçlarla kıyaslanarak incelenmiştir. Bu doęrultuda, aynı algoritmaların iki farklı zaman aralığındaki, 3 farklı veri seti ile vermiş olduęu performans karşılaştırılmıştır.

Farklı algoritmalar ile, veri setlerinden elde edilen doęruluk oranlarını içeren bilgiler, Çizelge 4.1'de sunulmuştur. Çizelge 4.1'de, tüm algoritmalarda göröldüğü gibi, farklı yıllarda işlenen ve düzenlenmiş veri setlerinin doęruluk oranları arasında, ciddi ayrışma olduęu görölmektedir. Buradan yola çıkacak olursak, doęruluk oranındaki bu

düşüşün sebebinin, su yolunun değişmesinden kaynaklandığı anlaşılmaktadır. Yani uydu görüntüleri üzerinden de görülmekte olan, su yolundaki değişimi, yansıma değerlerinden alınan veri setleri de doğrular niteliktedir.

Çizelge 4. 1. Makine Öğrenmesi Yaklaşımı ile Farklı Veri Setlerinden Elde Edilen Sonuçlar

Makine Öğrenmesi Algoritmaları		2000-2003 Yıllarındaki Veri Seti	2016 Sonrası Yıllardaki Veri Seti	2016 Sonrası Yıllardaki Veri Seti Düzeltilmiş
Doğruluk Oranları	Karar Ağaçları	%88.8	%61.3	%83.8
	Destek Vektör Makinesi	%90.0	%73.8	%96.3
	K-En Yakın Komşular	%82.5	%67.5	%96.3
	Topluluk Sınıflandırıcısı	%93.8	%60.0	%81.3
	Kernel Yaklaşım Sınıflandırıcısı	%92.5	%76.3	%91.3
	Yapay Sinir Ağları	%93.8	%72.5	%98.8

Çizelge 4.1’de, 2000-2003 yılları arasındaki veri setinden elde edilen doğruluk oranlarının, farklı algoritmalara göre %93.8 ile %82.5 aralığında olduğu görülmektedir. 2000 yılındaki Landsat 7 uydu görüntülerinden seçilen 80 noktanın, yansıma değerleri ile eğitilen sistemde, 2000-2003 yılları arasındaki veri seti ile elde edilen doğruluk oranlarına bakıldığında, Batman Çayı su yolu üzerinde ciddi anlamda değişikliğin olmadığı değerlendirilebilir.


Eğitilmiş bu sistemi, aynı 80 noktanın 2016 sonrası yıllardaki yansıma değerlerinden oluşan veri seti ile test ettiğimizde ise, doğruluk oranlarının %76.3 ile %60 aralığında olduğu görülmüştür. Doğruluk oranında yaşanan bu düşüşün sebebinin ise, Batman Çayı su yolu üzerinde meydana gelen değişikliklerden kaynaklandığı değerlendirilmektedir.

Son olarak aynı 80 noktanın, 2016 sonrası yıllardaki yansıma değerlerinden oluşan veri seti, yansıma değerlerine ve 2016 yılı uydu görüntülerine göre, “Su” ve


“Toprak” olarak yeniden düzenlenerek, eğitilmiş olan sistem üzerinde test edilmiştir. Önceki veri seti içerisinde, 40 adet su ve 40 adet toprak olarak seçilen bölgeler düzenlendiğinde, 53 adet su ve 27 adet toprak alana dönüşmüştür. Bu test sonuçlarına bakıldığında ise, doğruluk oranlarının %98.8 ile %81.3 aralığında olduğu görülmüştür. Bu sonuçlardan da anlaşılacağı üzere, Batman Çayı su yolunun yaşadığı değişim veri seti üzerinde manuel olarak düzeltilmiş ve bu sayede sistemin doğruluk oranlarının arttığı görülmüştür.

4.2.1. Karar ağaçları algoritmasına ait sonuçlar

Karar Ağaçları algoritması ile 2000 yılına ait Landsat 7 uydu görüntülerinden seçilen 80 noktanın, 2000-2003 yılları arasındaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %88.8 olmuştur. Şekil 4.7’de görüldüğü gibi veri setinden elde edilen sonuçların, oldukça başarılı olduğu görülmektedir. Buradan çıkarılacak ilk sonuç Batman Çayı su yolunun 2000-2003 yılları arasında çok değişime uğramamasıdır.




Şekil 4. 7. Karar Ağaçları Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi



Şekil 4. 8. Karar Ağaçları Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi

2016 sonrası yıllardaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı ise %61.3 olmuştur. Şekil 4.8’de görüldüğü gibi 2016 sonrası yıllardaki veri seti ile algoritmadan elde edilen doğruluk değerinin oldukça düşük olduğu düşünüldüğünde, geçen 16 yıllık zaman aralığında Batman Çayı su yolunun, ciddi anlamda değişime uğradığı değerlendirilmektedir.



Şekil 4. 9. Karar Ağaçları Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi


2016 sonrası yıllardaki yansıma değerlerini içeren düzenlenmiş veri setinden elde edilen doğruluk oranı ise %83.8 olmuştur. Şekil 4.9’da görüldüğü gibi 2016 sonrası yıllardaki veri setinin düzenlenmesinin ardından, algoritmadan elde edilen doğruluk

değerinin oldukça başarılı olduğu düşünüldüğünde, 2000 yılı Landsat 7 uydu görüntülerinden seçilen 80 adet noktanın, 2016 sonrası veri seti içinde düzenlenerek Batman Çayı su yolu üzerindeki “Su” ve “Toprak” alanların yaşamış olduğu değişim sonuçlara bakıldığında anlaşılmaktadır.

Karar Ağaçları algoritması ile farklı yıllardaki veri setleri elde edilen ROC eğrileri yukarıda görüldüğü gibidir. Grafikler yorumlandığında birinci ve üçüncü veri setinde doğru pozitif oranlarının yüksek, yanlış pozitif oranlarının ise düşük olduğu görülmektedir. İkinci veri setinde ise bu durumun daha farklı olduğu ve doğru pozitif oranlarının düştüğü, yanlış pozitif oranlarının ise arttığı görülmektedir. Buradan da anlaşılabileceği üzere, Batman Çayı su yolundaki yıllara göre meydana gelen değişiklikler sebebiyle, yanlış tahmin sayıları artarken, doğru tahmin sayıları azalmıştır.

4.2.2. Destek vektör makinesi algoritmasına ait sonuçlar

Destek Vektör Makinesi algoritması ile 2000-2003 yılları arasındaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %90 olmuştur. Şekil 4.10'da görüldüğü gibi veri setinden elde edilen sonuçların, oldukça başarılı olduğu görülmektedir. Buradan çıkarılacak ilk sonuç, Batman Çayı su yolunun 2000-2003 yılları arasında çok değişime uğramamasıdır.




Şekil 4. 10. Destek Vektör Makinesi Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi

görüntülerinden seçilen 80 adet noktanın 2016 sonrası veri seti içinde düzenlenerek Batman Çayı su yolu üzerindeki “Su” ve “Toprak” alanların yaşamış olduğu değişim gözler önüne serilmiştir.


Destek Vektör Makinesi algoritması ile farklı yıllardaki veri setleri elde edilen ROC eğrileri yukarıda görüldüğü gibidir. Grafikler yorumlandığında birinci ve üçüncü veri setinde doğru pozitif oranlarının yüksek, yanlış pozitif oranlarının ise düşük olduğu görülmektedir. İkinci veri setinde ise bu durumun daha farklı olduğu ve doğru pozitif oranlarının düştüğü, yanlış pozitif oranlarının ise arttığı görülmektedir. Buradan da anlaşılacağı üzere Batman Çayı su yolundaki yıllara göre meydana gelen değişiklikler sebebiyle, yanlış tahmin sayıları artarken, doğru tahmin sayıları azalmıştır.

4.2.3. K-En yakın komşular algoritmasına ait sonuçlar

K-En Yakın Komşular algoritması ile 2000-2003 yılları arasındaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %82,5 olmuştur. Şekil 4.13’de görüldüğü gibi veri setinden elde edilen sonuçların oldukça başarılı olduğu görülmektedir. Buradan çıkarılacak ilk sonuç Batman Çayı su yolunun 2000-2003 yılları arasında çok değişime uğramamasıdır.




Şekil 4. 13. KNN Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi



Şekil 4. 14. KNN Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi

2016 sonrası yıllardaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %67.5 olmuştur. Şekil 4.14’de görüldüğü gibi 2016 sonrası yıllardaki veri seti ile algoritmadan elde edilen doğruluk değerinin oldukça düşük olduğu düşünüldüğünde, geçen 16 yıllık zaman aralığında Batman Çayı su yolunun ciddi anlamda değişime uğradığı değerlendirilmektedir.



Şekil 4. 15. KNN Algoritması 2016 Sonrası Yıllardaki Düzeltilmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi


2016 sonrası yıllardaki yansıma değerlerini içeren düzenlenmiş veri setinden elde edilen doğruluk oranı %96.3 olmuştur. Şekil 4.15’te görüldüğü gibi 2016 sonrası yıllardaki veri setinin düzenlenmesinin ardından algoritmadan elde edilen doğruluk değerinin oldukça başarılı olduğu düşünüldüğünde, 2000 yılı Landsat 7 uydu görüntülerinden seçilen 80 adet noktanın 2016 sonrası veri seti içinde düzenlenerek

Batman Çayı su yolu üzerindeki “Su” ve “Toprak” alanların yaşamış olduğu değişim görülmektedir.


K-En Yakın Komşular algoritması ile farklı yıllardaki veri setleri elde edilen ROC eğrileri yukarıda görüldüğü gibidir. Grafikler yorumlandığında birinci ve üçüncü veri setinde doğru pozitif oranlarının yüksek, yanlış pozitif oranlarının ise düşük olduğu görülmektedir. İkinci veri setinde ise bu durumun daha farklı olduğu ve doğru pozitif oranlarının düştüğü, yanlış pozitif oranlarının ise arttığı görülmektedir. Buradan da anlaşılaçağı üzere Batman Çayı su yolunun yıllara göre yaşadığı değişiklikler, yanlış tahmin sayılarını arttırırken, doğru tahmin sayılarının azalmasına sebep olmuştur.

4.2.4. Topluluk sınıflandırıcısı algoritmasına ait sonuçlar

Topluluk Sınıflandırıcısı algoritması ile 2000-2003 yılları arasındaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %93,8 olmuştur. Şekil 4.16’da görüldüğü gibi veri setinden elde edilen sonuçların oldukça başarılı olduğu görülmektedir. Buradan çıkarılacak ilk sonuç Batman Çayı su yolunun 2000-2003 yılları arasında çok değişime uğramamasıdır.




Şekil 4. 16. Topluluk Sınıflandırıcısı Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi



Şekil 4. 17. Topluluk Sınıflandırıcısı Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi

2016 sonrası yıllardaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %60 olmuştur. Şekil 4.17’de görüldüğü gibi 2016 sonrası yıllardaki veri seti ile algoritmadan elde edilen doğruluk değerinin oldukça düşük olduğu düşünüldüğünde, geçen 16 yıllık zaman aralığında Batman Çayı su yolunun ciddi anlamda değişime uğradığı değerlendirilmektedir.



Şekil 4. 18. Topluluk Sınıflandırıcısı Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi


2016 sonrası yıllardaki yansıma değerlerini içeren düzenlenmiş veri setinden elde edilen doğruluk oranı %81.3 olmuştur. Şekil 4.18’de görüldüğü gibi 2016 sonrası yıllardaki veri setinin düzenlenmesinin ardından algoritmadan elde edilen doğruluk

değerinin oldukça başarılı olduğu düşünüldüğünde, 2000 yılı Landsat 7 uydu görüntülerinden seçilen 80 adet noktanın 2016 sonrası veri seti içinde düzenlenerek Batman Çayı su yolu üzerindeki “Su” ve “Toprak” alanların yaşamış olduğu değişim anlaşılmaktadır.


Topluluk Sınıflandırıcısı algoritması ile farklı yıllardaki veri setleri elde edilen ROC eğrileri yukarıda görüldüğü gibidir. Grafikler yorumlandığında birinci ve üçüncü veri setinde doğru pozitif oranlarının yüksek, yanlış pozitif oranlarının ise düşük olduğu görülmektedir. İkinci veri setinde ise bu durumun daha farklı olduğu ve doğru pozitif oranlarının düştüğü, yanlış pozitif oranlarının ise arttığı görülmektedir. Buradan da anlaşılaçağı üzere Batman Çayı su yolundaki yıllara göre meydana gelen değişiklikler yanlış tahmin sayılarını arttırırken, doğru tahmin sayılarını azaltmıştır.

4.2.5. Yapay sinir ağları algoritmasına ait sonuçlar

Yapay Sinir Ağları algoritması ile 2000-2003 yılları arasındaki yansına değerlerini içeren veri setinden elde edilen doğruluk oranı %93,8 olmuştur. Şekil 4.19’da görüldüğü gibi veri setinden elde edilen sonuçların oldukça başarılı olduğu görülmektedir. Buradan çıkarılacak ilk sonuç Batman Çayı su yolunun 2000-2003 yılları arasında çok değişime uğramamasıdır.




Şekil 4. 19. Yapay Sinir Ağları Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi



Şekil 4. 20. Yapay Sinir Ağları Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi

2016 sonrası yıllardaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %72.5 olmuştur. Şekil 4.20’de görüldüğü gibi 2016 sonrası yıllardaki veri seti ile algoritmadan elde edilen doğruluk değerinin oldukça düşük olduğu düşünüldüğünde, geçen 16 yıllık zaman aralığında Batman Çayı su yolunun ciddi anlamda değişime uğradığı değerlendirilmektedir.



Şekil 4. 21. Yapay Sinir Ağları Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi


2016 sonrası yıllardaki yansıma değerlerini içeren düzenlenmiş veri setinden elde edilen doğruluk oranı %98.8 olmuştur. Şekil 4.21’de görüldüğü gibi 2016 sonrası yıllardaki veri setinin düzenlenmesinin ardından algoritmadan elde edilen doğruluk değerinin oldukça başarılı olduğu düşünüldüğünde, 2000 yılı Landsat 7 uydu

görüntülerinden seçilen 80 adet noktanın 2016 sonrası veri seti içinde düzenlenerek Batman Çayı su yolu üzerindeki “Su” ve “Toprak” alanların yaşamış olduğu değişim ortaya çıkmıştır.


Yapay Sinir Ağları algoritması ile farklı yıllardaki veri setleri elde edilen ROC eğrileri yukarıda görüldüğü gibidir. Grafikler yorumlandığında birinci ve üçüncü veri setinde doğru pozitif oranlarının yüksek, yanlış pozitif oranlarının ise düşük olduğu görülmektedir. İkinci veri setinde ise bu durumun daha farklı olduğu ve doğru pozitif oranlarının düştüğü, yanlış pozitif oranlarının ise arttığı görülmektedir. Buradan da anlaşılacağı üzere Batman Çayı su yolundaki yıllara göre meydana gelen değişim, yanlış tahmin sayılarının artmasına, doğru tahmin sayılarının azalmasına sebep olmuştur.

4.2.6. Kernel yaklaşım sınıflandırıcısı algoritmasına ait sonuçlar

Kernel Yaklaşım Sınıflandırıcısı algoritması ile 2000-2003 yılları arasındaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %92,5 olmuştur. Şekil 4.22’de görüldüğü gibi veri setinden elde edilen sonuçların oldukça başarılı olduğu görülmektedir. Buradan çıkarılacak ilk sonuç Batman Çayı su yolunun 2000-2003 yılları arasında çok değişime uğramamasıdır.




Şekil 4. 22. Kernel Algoritması 2000-2003 Yılları Arasındaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi



Şekil 4. 23. Kernel Algoritması 2016 Sonrası Yıllardaki Veri Seti Karışıklık Matrisi ve ROC Eğrisi

2016 sonrası yıllardaki yansıma değerlerini içeren veri setinden elde edilen doğruluk oranı %72.5 olmuştur. Şekil 4.23'te görüldüğü gibi 2016 sonrası yıllardaki veri seti ile algoritmadan elde edilen doğruluk değerinin oldukça düşük olduğu düşünüldüğünde, geçen 16 yıllık zaman aralığında Batman Çayı su yolunun ciddi anlamda değişime uğradığı değerlendirilmektedir.



Şekil 4. 24. Kernel Algoritması 2016 Sonrası Yıllardaki Düzenlenmiş Veri Seti Karışıklık Matrisi ve ROC Eğrisi

2016 sonrası yıllardaki yansıma değerlerini içeren düzenlenmiş veri setinden elde edilen doğruluk oranı %91.3 olmuştur. Şekil 4.24'de görüldüğü gibi 2016 sonrası yıllardaki veri setinin düzenlenmesinin ardından algoritmadan elde edilen doğruluk değerinin oldukça başarılı olduğu düşünüldüğünde, 2000 yılı Landsat 7 uydu görüntülerinden seçilen 80 adet noktanın 2016 sonrası veri seti içinde düzenlenerek

Batman ayı su yolu zerindeki “Su” ve “Toprak” alanların yařamıř olduėu deėiřim netleřtirilmiřtir.

řekil 4.24’de Kernel algoritması ile farklı yıllardaki veri setleri ile elde edilen ROC eėrileri yukarıda grldė gibidir. Grafikler yorumlandığında birinci ve nc veri setinde doėru pozitif oranlarının yksek, yanlış pozitif oranlarının ise dřk olduėu grlmektedir. İkinci veri setinde ise bu durumun daha farklı olduėu ve doėru pozitif oranlarının dřtė, yanlış pozitif oranlarının ise arttıėı grlmektedir. Buradan da anlařılacaėı zere Batman ayı su yolundaki yıllara gre meydana gelen deėiřiklikler yanlış tahmin sayılarını arttırırken, doėru tahmin sayılarını ise azaltmıřtır.


5. SONUÇLAR VE ÖNERİLER

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


5.1 Sonuçlar

5.1.1. GEE kullanılarak elde edilen yaklaşık sonuçların değerlendirilmesi


GEE üzerinden yapılan çalışma neticesinde elde edilen ve Şekil 5.1-Şekil 5.5'te, kırmızı alan içerisinde kalan bölgelerde bulunan atıl alanlar göze çarpmaktadır. Çalışma sahası içerisindeki, Batman Çayı yatağının yaklaşık 4370.8 hektarlık alanı kapsadığı ve Batman Çayı yüzey alanının ise 582.35 hektar olduğu düşünüldüğünde, geriye kalan 3788.45 hektarlık alan atıl bölgeyi oluşturmaktadır (Openstreet, 2025). Bu bölgeler için, su yolunun uygun bir alanda sabitlendiği düşünüldüğünde, bölgeye ciddi bir miktarda arazi kazandırılabilir.




Şekil 5. 1. Batman Çayı Üzerindeki Atıl Alan-1 (GEE Platformu, 2024)




Şekil 5. 2. Batman Çayı Üzerindeki Atıl Alan-2 (GEE Platformu, 2024)



Şekil 5. 3. Batman Çayı Üzerindeki Atıl Alan-3 (GEE Platformu, 2024)



Şekil 5. 4. Batman Çayı Üzerindeki Atıl Alan-4 (GEE Platformu, 2024)



Şekil 5. 5. Batman Çayı Üzerindeki Atıl Alan-5 (GEE Platformu, 2024)

Yukarıdaki şekiller incelendiğinde, Batman Çayı üzerinde bulunan atıl bölgeler, Batman şehir merkezinin yaklaşık 25 km kuzeyi ile yaklaşık 6 km güneyinde kalan alan arasında bulunmaktadır. Bu atıl bölgeler yaklaşık 3788.45 hektarlık (37.88 km²) alanı kapsamaktadır (GEE, 2025).

Sonuç olarak, Batman Çayı'nın düzenli bir akış rejiminde olmamasından kaynaklanan bu düzensiz su yolu, ciddi bir miktarda bölgenin atıl alan olmasına sebep olmaktadır. Su yolunun uygun bir bölgeye sabitlenmesi durumunda, yüksek miktarda alanın kazanımından söz edilebilir.

5.1.2. Makine öğrenmesi yaklaşımı ile elde edilen yaklaşık sonuçların değerlendirilmesi

Makine Öğrenmesi yaklaşımı üzerinden elde edilen sonuçlara bakıldığında, 2000-2003 yılları arasındaki veri seti ile doğruluk oranının %82,5-%93,8 arasında olduğu görülmektedir. Seçilen 80 adet noktanın da, 2000 yılı uydu görüntülerinden belirlendiği düşünüldüğünde, elde edilen doğruluk oranları oldukça yüksektir.

2016 sonrası yıllardaki yansıma değerlerini içeren veri setini, aynı algoritmalarda uyguladığımızda ise doğruluk oranının %60-%76,3 arasında değiştiğini görmekteyiz. Bu durumdan çıkarılması gereken esas nokta, 2000 yılından sonraki zamanlarda Batman Çayı su yolunda yaşanan değişimlerdir. %90'lardan %60'lara düşen doğruluk oranından da anlaşılacağı üzere, Batman Çayı su yolu, veri setilerinin alınmış olduğu 20 yıllık zaman zarfı içerisinde, oldukça değişim yaşamıştır. Makine öğrenmesi yaklaşımı ile tespit edilen su yolu değişimi, GEE üzerinden elde edilen uydu görüntülerinde de net şekilde görülmektedir. Yani her iki çalışma birbirini destekler niteliktedir.

2016 sonrası yıllardaki yansıma değerleri düzenlenerek oluşturulan veri setini, aynı algoritmalarda uyguladığımızda ise, doğruluk oranının %81,3-%98,8 arasında değiştiğini görmekteyiz. 2000 yılı uydu görüntüsü üzerinden seçilen 80 nokta, 2016 yılı uydu görüntüsüne göre veri seti üzerinden düzenlendiğinde doğruluk oranları yeniden artmaktadır. Bu durum değerlendirildiğinde, Batman Çayı su yolunun ilgili zaman aralığında yaşadığı değişim anlaşılmaktadır.

Çalışmamızın öncelikli amacının su yolu değişiminin takibi olmasından kaynaklı seçilen noktalar, 2000 yılı uydu görüntüleri üzerinden alınmıştır. Yani bu şartlar altında seçilen nokta sayısı arttırıldığında, doğruluk oranının daha da düşeceği düşünülmekle birlikte, Batman Çayı üzerindeki su yolunda yaşanan değişimlerin daha da netleşeceği düşünülmektedir.

5.2 Öneriler

Dünya üzerinde bulunan akarsuların büyük çoğunluğunun su yolu düzgün olmamakla birlikte, yıllara göre farklı akış rejimleri sergiledikleri görülmektedir. Bu sebeple, akarsuların akış rejimlerinden kaynaklı olarak, birçok alan atıl olarak kalmaktadır. Bu tez çalışmasında, Batman Çayı su yolu incelenmiş ve tarım vb. anlamda

kazandırılabilir atıl alanların analizi yapılmıştır. Yapılan analizin ülke ekonomisine ve bölge halkına fayda sağlayacağı değerlendirilmektedir.

Uzaktan algılama teknikleri ile Landsat 7 ve 8 uydu görüntüleri kullanılarak, GEE üzerinden yıllara göre elde edilen uydu görüntüleri incelenmiş ve su yolundaki değişim gözlemlenmiştir. Bununla birlikte yine Landsat 7-8 uydusu üzerinden farklı yıllardaki yeryüzü yansıma değerleri alınarak, bu değerler ile veri setleri oluşturulmuş ve makine öğrenmesi yaklaşımı ile incelenmiştir.

Bu çalışmadan elde edilen tüm sonuçlar ışığında atıl bölge olarak tabir ettiğimiz alanın yaklaşık 3788.45 hektar olduğu düşünüldüğünde, su yolunun uygun bir hat üzerinde sabitlenebileceği değerlendirilmektedir. Bunun sonucu olarak, kazanılacak alanın arazi koşullarının da elverdiği (Toprak verimi, alanın ticari yönden faydalı olup olmayacağı vb.) şartlar altında değerlendirilmesinin, hem bölge halkı hem de ülke ekonomisine katkı sağlayacağı düşünülmektedir.

Aynı şekilde ülkemizde bulunan diğer akarsuların da akış yolları incelendiğinde, benzer sonuçlarla karşılaşılabileceği değerlendirilmektedir. Buradan hareketle, yapılacak benzer çalışmalar ile su yollarının sabitlenmesi durumunda, ciddi miktardaki atıl bölgelerin ülke ekonomisine kazandırılabilir olduğu değerlendirilmektedir.

Bu çalışmada, 2000-2024 yılları arasındaki değişiklikler incelenmiş olup, daha eski yıllara gidildiğinde, olumlu veya olumsuz yönde farklı sonuçların da elde edilebileceği düşünülmektedir. Makine öğrenmesi yaklaşımı aşamasında kullanılan veri setlerinde, atmosferik şartların da etkisiyle, genel anlamda kayıpların yaşandığı tarih aralıkları bulunmaktadır. Veri alınabilen yıllar için ise, en sağlıklı verilerin Haziran ile Ekim ayları arasında alındığı tespit edilmiştir. Bunun sebebinin, Batman bölgesinin sahip olduğu iklimden kaynaklandığı değerlendirilmektedir. İlerleyen dönemlerde yapılacak benzer çalışmalarda, tüm verilerin eksiksiz bir şekilde alınabileceği sistemlerin kullanılmasının ve araştırma zaman aralığının da, daha geniş tutulmasının faydalı olabileceği düşünülmektedir.

KAYNAKLAR

- Acharya, T. D., Subedi, A., Huang, H., & Lee, D. H. (2019). Application of water indices in surface water change detection using Landsat imagery in Nepal. *Sens. Mater*, 31(1429), 10-18494.
- Acharya, T. D., Yang, I. T., Subedi, A., & Lee, D. H. (2016, November). Change detection of lakes in Pokhara, Nepal using Landsat data. In *Proceedings* (Vol. 1, No. 2, p. 17). MDPI.
- Aggarwal, S. (2004). Principles of remote sensing. *Satellite remote sensing and GIS applications in agricultural meteorology*, 23(2), 23-28.
- Alkan, D. (2023). U-net derin öğrenme mimarisi kullanılarak yanmış alanların uydu görüntülerinden tespiti (Master's thesis, Konya Teknik Üniversitesi).
- Arslanoğlu, M.C., Alp, Y., Kılınç, M., Süner, M.S. (2003). Batman Tarım Master Planı: İl Tarım Kırsal Kalkınma Master Planlarının Hazırlanmasına Destek Projesi, 46-47.
- Bhattacharjee, S., Islam, M. T., Kabir, M. E., & Kabir, M. M. (2021). Land-use and land-cover change detection in a north-eastern wetland ecosystem of Bangladesh using remote sensing and GIS techniques. *Earth Systems and Environment*, 5(2), 319-340.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Cart. Classification and regression trees*.
- Cano, A. (2018). A survey on graphic processing unit computing for large-scale data mining. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(1), e1232.
- Chang, L., Cheng, L., Huang, C., Qin, S., Fu, C., & Li, S. (2022). Extracting urban water bodies from Landsat imagery based on mNDWI and HSV transformation. *Remote Sensing*, 14(22), 5785.
- Cheng, G., Deng, G., & Wang, D. (2015). Remote Sensing Monitoring Water Area of Dongting Lake Based on MNDWI. *Journal of Water Resources Research*, 4(3), 234-239.
- Crammer, K., & Singer, Y. (2001). On the algorithmic implementation of multiclass kernel-based vector machines. *Journal of machine learning research*, 2(Dec), 265-292.
- Çağlayan, E. B., Erel, F., Samur, E. B., Deniz, M., Mobariz, M. A., & Kaplan, G. (2020). Uzaktan algılama teknikler ile Akşehir Gölü'ndeki alansal değişiminin izlenmesi. *Türkiye Uzaktan Algılama Dergisi*, 2(2), 70-76.

- Çevresen Etki Değerlendirme ve İzin Şube Müdürlüğü, İl Çevre Durum Raporları (Çevre ve Şehircilik Bakanlığı, 2012-2023), 17-27.
- Deoli, V., Kumar, D., Kumar, M., Kuriqi, A., & Elbeltagi, A. (2021). Water spread mapping of multiple lakes using remote sensing and satellite data. *Arabian Journal of Geosciences*, 14, 1-15.
- Driscoll, M. F. (1973). The reproducing kernel Hilbert space structure of the sample paths of a Gaussian process. *Zeitschrift für Wahrscheinlichkeitstheorie und verwandte Gebiete*, 26, 309-316.
- Du, Z., Linghu, B., Ling, F., Li, W., Tian, W., Wang, H., ... & Zhang, X. (2012). Estimating surface water area changes using time-series Landsat data in the Qingjiang River Basin, China. *Journal of Applied Remote Sensing*, 6(1), 063609-063609.
- Efe, H., & Önen, F. (2015). Batman Çayı'nın taşkın analizinin HEC-RAS programıyla yapılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 6(2), 83-92.
- El-Asmar, H. M., Hereher, M. E., & El Kafrawy, S. B. (2013). Surface area change detection of the Burullus Lagoon, North of the Nile Delta, Egypt, using water indices: A remote sensing approach. *The Egyptian Journal of Remote Sensing and Space Science*, 16(1), 119-123.
- El-Asmar, H. M., El-Kafrawy, S. B., & Taha, M. M. (2014). Monitoring coastal changes along Damietta Promontory and the barrier beach toward Port Said east of the Nile Delta, Egypt. *Journal of Coastal Research*, 30(5), 993-1005.
- Google, Earth Engine Data Catalog, Landsat Collections, Collection 2, (<https://developers.google.com>), [Erişim Tarihi: 25.12.2024].
- Guo, Q., Pu, R., Li, J., & Cheng, J. (2017). A weighted normalized difference water index for water extraction using Landsat imagery. *International journal of remote sensing*, 38(19), 5430-5445.
- Hastie, T. (2009). *The elements of statistical learning: data mining, inference, and prediction*.
- H. Drucker. "Improving Regressors using Boosting Techniques", 1997.
- Hui, F., Xu, B., Huang, H., Yu, Q., & Gong, P. (2008). Modelling spatial-temporal change of Poyang Lake using multitemporal Landsat imagery. *International Journal of Remote Sensing*, 29(20), 5767-5784.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.

- Kilic Gul, F. (2018). Geomorphometry-Automatic Landform Classification. *Journal of Geography-Cografya Dergisi*, (36).
- Le Hung, T., Van Hoan, K., Ly, T. T. M., & Nga, N. T. T. (2020). Application of remote sensing technique for shoreline change detection in Ninh Binh and Nam Dinh provinces (Vietnam) during the period 1988 to 2018 based on water indices. *Russian Journal of Earth Sciences*, 20(2), 4.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381-386.
- Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). *Machine learning: algorithms and applications*. Crc Press.
- Mutanga, O., & Kumar, L. (2019). Google earth engine applications. *Remote sensing*, 11(5), 591.
- Naik, B. C., & Anuradha, B. (2018). Extraction of water-body area from high-resolution Landsat imagery. *International Journal of Electrical and Computer Engineering (IJECE)*, 8(6), 4111-4119.
- Orr, G. B., & Müller, K. R. (Eds.). (1998). *Neural networks: tricks of the trade*. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Özelkan, E. (2019). Uzaktan algılama ile belirlenen baraj gölü alanının zamansal değişiminin meteorolojik kuraklık ile değerlendirilmesi: Atikhisar barajı (Çanakkale) örneği. *Türk Tarım ve Doğa Bilimleri Dergisi*, 6(4), 904-916.
- Rokni, K., Ahmad, A., Selamat, A., & Hazini, S. (2014). Water feature extraction and change detection using multitemporal Landsat imagery. *Remote sensing*, 6(5), 4173-4189.
- Room, C. (2019). Confusion matrix. *Mach. Learn*, 6, 27.
- Rosenblatt, F. (1960). Perceptron simulation experiments. *Proceedings of the IRE*, 48(3), 301-309.
- Roweis, S., Hinton, G., & Salakhutdinov, R. (2004). Neighbourhood component analysis. *Adv. Neural Inf. Process. Syst.(NIPS)*, 17(513-520), 4.
- Salzberg, S. L. (1994). *C4. 5: Programs for machine learning by j. ross quinlan*. morgan kaufmann publishers, inc., 1993.
- Scikit Learn, Decision Trees, Support Vector Machines, Nearest Neighbours, Gaussian Processes, Ensembles, Neural Network (<https://scikit-learn.org>), [Erişim Tarihi: 14.01.2025].

- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14, 199-222.
- Swets, J. A. (2014). *Signal detection theory and ROC analysis in psychology and diagnostics: Collected papers*. Psychology Press.
- Wikipedia, “ROC”, [online], (<https://tr.wikipedia.org>), [Erişim Tarihi: 27.12.2024].
- Williams, C. K., & Rasmussen, C. E. (2006). *Gaussian processes for machine learning* (Vol. 2, No. 3, p. 4). Cambridge, MA: MIT press.
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., ... & Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote sensing of environment*, 225, 127-147.
- Wu, T. F., Lin, C. J., & Weng, R. (2003). Probability estimates for multi-class classification by pairwise coupling. *Advances in Neural Information Processing Systems*, 16.
- Williams, C. K., & Rasmussen, C. E. (2006). *Gaussian processes for machine learning* (Vol. 2, No. 3, p. 4). Cambridge, MA: MIT press.
- Yan, D., Huang, C., Ma, N., & Zhang, Y. (2020). Improved landsat-based water and snow indices for extracting lake and snow cover/glacier in the tibetan plateau. *Water*, 12(5), 1339.
- Yang, J., & Du, X. (2017). An enhanced water index in extracting water bodies from Landsat TM imagery. *Annals of GIS*, 23(3), 141-148.
- Yousefiroshan, Y. (2022). Estimation of Lake Urmia water area using Landsat 8 satellite imagery using MNDWI Index.
- Y. Freund, and R. Schapire, “A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting”, 1997.