



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



SENTİNEL-2 UYDU VERİLERİ İLE ARAZİ
KULLANIMI SINIFLANDIRMASI: MAKİNE
ÖĞRENMESİ ALGORİTMALARININ
KARŞILAŞTIRILMASI

Mehmet Oktay KUTRAK

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Eylül-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet Oktay KUTRAK tarafından hazırlanan “Sentinel-2 Uydu Verileri İle Arazi Kullanımı Sınıflandırması: Makine Öğrenmesi Algoritmalarının Karşılaştırılması” adlı tez çalışması 11/09/2025 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan / Danışman

Prof. Dr. Ferruh YILDIZ
(Konya Teknik Üniversitesi)

Üye

Prof. Dr. Hakan KARABÖRK
(Konya Teknik Üniversitesi)

Üye

Doç. Dr. Pınar BACAŞIZ
(Osmaniye Korkut Ata Üniversitesi)

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

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

İmza

Mehmet Oktay KUTRAK

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

SENTİNEL-2 UYDU VERİLERİ İLE ARAZİ KULLANIMI SINIFLANDIRMASI: MAKİNEÖĞRENMESİ ALGORİTMALARININ KARŞILAŞTIRILMASI

Mehmet Oktay KUTRAK

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Harita Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Ferruh YILDIZ

2025, 95 Sayfa

Jüri

**Prof. Dr. Ferruh YILDIZ
Prof. Dr. Hakan KARABÖRK
Doç. Dr. Pınar BACAŞIZ**

Bu tez çalışmasında 10 m mekânsal çözünürlüğe sahip olan Sentinel-2A uydu verileri kullanılarak Arazi Kullanımı/Arazi Örtüsü sınıflandırma çalışması yapılmıştır. Bu doğrultuda farklı makine öğrenmesi algoritmaları kullanılmış ve bu algoritmaların sınıflandırma doğrulukları karşılaştırılmıştır. Çalışmanın uygulama alanı Konya ili sınırları içerisinde yapılmıştır. 2018, 2021, 2024 yıllarına ait uydu görüntüleri kullanılarak, hem zamansal analiz gerçekleştirilmiş hem de arazi üzerindeki değişimler incelenmiştir. Sınıflandırma süreci Google Earth Engine platformu üzerinden JavaScript programlama dili ile yürütülmüştür. Çalışma sürecinde rastgele orman, k-en yakın komşu ve Naive Bayes, destek vektör makinelerinin lineer ve polinom çekirdek(Kernel) fonksiyonu algoritmaları kullanılmış ve elde edilen sonuçlar analiz edilmiştir. Her bir algoritmanın performansı %70-%30 ve %80-%20 veri oranlarına göre ayrı ayrı değerlendirilmiştir. Böylelikle, sınıflandırma başarımının veri oranlarından etkilenip etkilenmediği analiz edilmiştir. Sınıflandırma sonuçları, hata matrisi üzerinden genel doğruluk, kappa değeri, F1score değeri, üretici ve kullanıcı gibi doğruluk metrikleri ile değerlendirilmiştir. Sonuçlar incelendiğinde en yüksek doğruluk değerlerine DVM-Polinom algoritması sahip olmuştur. Hem genel doğruluk (%96) hem de kappa değeri (0.94) açısından üstünlük sağlamıştır. Ayrıca, yıllara ait görüntüler karşılaştırıldığında tarım, yerleşim ve sanayi bölgesi alanlarında değişimlerin mevcut olduğu gözlemlenmiştir. Tez kapsamında elde edilen bulgular, makine öğrenmesi algoritmalarının Arazi Kullanımı/Arazi Örtüsü sınıflandırmasındaki başarılarını ortaya koymuş ve her iki veri oranlarının performanslara olan etkisini açıklamıştır.

Bu çalışmanın önemi, dört farklı makine öğrenmesi algoritmalarını aynı çalışma alanı üzerinden ve eğitim verileri ile karşılaştırıp, yöntemlerin performans farklılıklarının incelenmesidir. Bu konu ile ilgili yapılan çalışmalarda ya tek bir tarih üzerinden ya da tek bir veri oranı (%80-%20 veya %70-%30) ile çalışılmıştır. Çalışma kapsamında ise, üç farklı tarihe ait görüntüler ile iki adet veri oranı kullanılmış ve birlikte değerlendirilmiştir. Aynı zamanda, zamansal analiz ile arazi üzerindeki değişimler incelenmiştir. Ayrıca hata matrisi sonucu elde edilen doğruluk metrikleri ayrıntılı bir şekilde yorumlanmış ve karşılaştırılmıştır. Bu bağlamda tez kapsamında elde edilen bulgular, makine öğrenmesi algoritmalarının Arazi Kullanımı/Arazi Örtüsü sınıflandırmasındaki etkinliğini ortaya koyarken, veri oranlarının değişimi ile doğruluk oranlarının üzerindeki etkisi de vurgulanmıştır.

Anahtar Kelimeler: Arazi Örtüsü, Arazi Kullanımı, Destek Vektör Makineleri, k-En Yakın Komşu, Naive Bayes, Rastgele Orman, Sentinel-2, Uzaktan Algılama

ABSTRACT

MS THESIS

LAND USE CLASSIFICATION WITH SENTINEL-2 SATELLITE DATA: COMPARISON OF MACHINE LEARNING ALGORITHMS

Mehmet Oktay KUTRAK

**Konya Technical University
Institute of Graduate Studies
Department of Geomatic Engineering**

Advisor: Prof. Dr. Ferruh YILDIZ

2025, 95 Pages

Jury

Prof. Dr. Ferruh YILDIZ

Prof. Dr. Hakan KARABORK

Assoc. Prof. Dr. Pinar BACAŞIZ

In this thesis, land use/land cover (LULC) classification was carried out using Sentinel-2A satellite imagery with a spatial resolution of 10 m. Different machine learning algorithms were applied, and their classification accuracies were compared. The study area is located within the boundaries of Konya Province. By using satellite images from the years 2018, 2021, and 2024, both temporal analyses were performed and land cover changes were examined. The classification process was conducted on the Google Earth Engine platform using the JavaScript programming language. Random Forest, k-Nearest Neighbors, Naive Bayes, and Support Vector Machines with linear and polynomial kernels were employed, and the results were analyzed. The performance of each algorithm was separately evaluated using 70–30% and 80–20% training/testing data splits, enabling the analysis of whether classification performance was influenced by different data ratios. Classification results were assessed through confusion matrix-based accuracy metrics, including overall accuracy, Kappa coefficient, F-score, producer's accuracy, and user's accuracy. The results showed that the SVM with polynomial kernel achieved the highest accuracy, with 96% overall accuracy and a Kappa value of 0.94. Furthermore, comparisons of different years revealed notable changes in agricultural, residential, and industrial areas. The findings of this thesis highlight the effectiveness of machine learning algorithms in LULC classification and clarify the impact of different training/testing ratios on classification performance.

The significance of this study lies in comparing four machine learning algorithms on the same study area with the same training data to examine performance differences. In related studies, either a single year or only one data split ratio (70–30% or 80–20%) was typically used. In contrast, this research employed images from three different years combined with two data ratios and evaluated them together. Moreover, land cover changes were examined through temporal analysis, and accuracy metrics obtained from the confusion matrix were interpreted and compared in detail. In this context, the findings of the thesis not only demonstrate the effectiveness of machine learning algorithms in LULC classification but also emphasize the impact of varying data ratios on accuracy levels..

Keywords: k-Nearest Neighbour, Land Cover, Land Use, Naive Bayes, Random Forest, Remote Sensing, Sentinel-2, Support Vector Machines,

ÖNSÖZ

Yüksek lisans eğitimim ve tez çalışma sürecinde bilgi birikimi, hoşgörüsü ve tecrübeleri ile akademik gelişimimde bana yol gösteren, öğrencilerin kalbinde yer edinen saygıdeğer danışman hocam Prof. Dr. Ferruh Yıldız'a en içten teşekkürlerimi sunuyorum.

Tez çalışmam boyunca bilgi ve tecrübelerini benimle paylaşan, bu süre zarfında bana rehberlik eden, sabrı ve desteği ile bu tez çalışmasının tamamlanmasında büyük katkısı bulunan Arş. Gör. Dr. Duygu Arıkan İspir'e teşekkür ederim.

Hayatım boyunca her anımda yanımda olan, sevgileri ve fedakârlıkları ile bana güç veren, motivasyon kaynağım değerli eşime ve canım aileme sonsuz minnettarım. İyi ki varsınız.

Mehmet Oktay KUTRAK
KONYA-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM.....	11
3.1. Uzaktan Algılamada Görüntü Sınıflandırması ve Sınıflandırma Yöntemleri	11
3.1.1. Piksel tabanlı sınıflandırma yöntemi	11
3.1.2. Makine öğrenmesi ile sınıflandırma yöntemi	12
3.1.2.1. Rastgele orman algoritması	13
3.1.2.2. k-En yakın komşu algoritması	14
3.1.2.3. Naive Bayes algoritması	15
3.1.2.4. Destek vektör makineleri algoritması	15
3.1.3. Doğruluk analizi	16
3.2. Kullanılan Veri	18
3.2.1. Çalışma alanı.....	18
3.2.2. Sentinel-2 uydusu	19
3.2.3. Google Earth Engine platformu ve JavaScript	21
3.2.4. ArcGIS yazılımı.....	23
4. BULGULAR VE TARTIŞMA.....	24
4.1. Makine öğrenmesi ile sınıflandırma çalışması	25
4.1.1. Rastgele orman algoritması ile sınıflandırma	25
4.1.2. Naive Bayes algoritması ile sınıflandırma.....	31
4.1.3. K-En yakın komşu algoritması ile sınıflandırma.....	37
4.1.4. Destek vektör makineleri algoritması ile sınıflandırma.....	43
4.2. Araştırma Sonuçları	56
4.3. Tartışma	74
5. SONUÇLAR VE ÖNERİLER	79
KAYNAKLAR	81

SİMGELER VE KISALTMALAR

Kısaltmalar

AK	: Arazi Kullanımı
AÖ	: Arazi Örtüsü
CBS	: Coğrafi Bilgi Sistemleri
DVM	: Destek Vektör Makineleri
EÇB	: En Çok Benzerlik
ESA	: Avrupa Uzay Ajansı
GBT	: Gradient Boosted Trees
GEE	: Google Earth Engine
KA	: Karar Ağaçları
KNN	: K-En Yakın Komşu
MO	: Maksimum Olasılık
RO	: Rastgele Orman
SAM	: Spectral Angle Mapper
UA	: Uzaktan Algılama
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Geçmişten günümüze kadar insanoğlu çevresini anlama, yorumlama ve yaşadığı coğrafi sınırların ötesine geçerek yeni yerler keşfetme arayışında olmuştur. Bu doğrultuda yeryüzünü, dünyayı ve hatta uzayı incelerken, elde ettiği bilgileri kullanarak yaşam standartlarını arttırmayı hedeflemiş ve bu bilgileri gelecek nesillere aktarmayı amaç edinmiştir. Bu amaç doğrultusunda birçok araç ve teknoloji geliştirilmiştir. Bu teknolojilerden biri de uzaktan algılama (UA) teknolojisidir.

UA teknolojisi, yeryüzüne ilişkin bilgileri farklı spektral, mekânsal ve zamansal çözünürlüklerde görüntüleyerek, bu bilgilere daha hızlı, güncel ve güvenilir bir şekilde ulaşılmasını sağlamaktadır (Yalçın, 2022; Khatami ve ark., 2016). UA, yeryüzündeki cisimlere fiziksel bir dokunuş olmadan, yani uzak bir mesafeden aygıt tarafından cisimler hakkında çeşitli verilerin elde edilmesi ve elde edilen verilerin değerlendirilerek analiz edilmesi bilimi ve tekniği olarak tanımlanabilir (Chipman ve ark., 2015; Çetin, 2020).

UA teknolojisi ilk başlarda askeri amaçlar için geliştirilmiş olsa da, zamanla teknolojik ilerlemeler ve özellikle bilişim alanındaki gelişmeler sayesinde kullanım alanları genişlemiştir. Günümüzde bu teknoloji, hidrolojik uygulamalar (Algancı ve ark., 2010), zirai uygulamalar (Bellvert ve ark., 2025), ormancılık uygulamaları (Çoban ve Gündoğdu, 2020), jeolojik uygulamalar (He ve ark., 2025), arkeolojik uygulamalar (Erbay, 2018), haritacılık uygulamaları (Arpitha ve ark., 2023), doğal afet izleme ve değerlendirme çalışmaları (Yiğit ve Uysal, 2019), meteoroloji (Norzaee ve ark., 2024) gibi alanlarda sıkça kullanılmaktadır. Bahsedilen bu uygulamalar arasında haritacılık uygulamaları, UA'nın önemli araştırma konularından birisidir. Özellikle Arazi Kullanımı/Arazi Örtüsü (AK/AÖ) belirleme çalışmalarında, UA kritik bir role sahiptir (Kappas ve Noi, 2017).

AK/AÖ belirleme çalışmaları yeryüzünü bir sistem olarak modellemek ve anlamak için önemli bir bileşendir (Chipman ve ark., 2015). Arazi örtüsü ve arazi kullanımı kavramları, her ne kadar birbirlerinin yerine kullanılsa da, temelde farklı anlamları ifade etmektedir. Arazi kullanımı, belirli bir arazi parçasının insanların ihtiyaçlarını karşılamak için nasıl kullanılacağını ifade ederken, arazi örtüsü ise yeryüzünde bulunan beşeri ve doğal unsurları (tarım alanı, su yüzeyi, bitki örtüsü, yeşil alanlar, orman, yollar, binalar vb.) ifade eder (Çölkesen, 2009; Metin, 2022).

AK/AÖ belirlenmesi çalışmalarında bilgilerin doğru ve güncel olarak elde edilmesi; özellikle gelişmekte olan ülkelerde ekonomik kalkınma, sanayileşme ve insan

yaşamının sürdürülebilirliği için ve iklim değişikliği ile çevresel modellemenin geliştirilmesi açısından temel bir gerekliliktir (Arpitha ve ark., 2023; Talukdar ve ark., 2020). Bunun yanı sıra, kentsel büyüme ve bölgesel planlamada, çevresel etki değerlendirmesi, doğal afet yönetiminden, toprak erozyonu ve tuzluluk oranı tahminine kadar çeşitli alanlarda karar destek mekanizmalarının temelini oluşturur (Talukdar ve ark., 2020).

AK/AÖ belirlenmesinde, yeryüzüne ilişkin doğru ve verimli bilgiler elde etmek için genellikle görüntü sınıflandırması yöntemi kullanılmaktadır. Görüntü sınıflandırması çoğunlukla uydu ve hava görüntüleri üzerinden yapılır (Kıraç, 2021). Ancak uydu görüntüleri, istenilen bilgilere hızlı ve güncel olarak ulaşabilmesi, ulaşması zor alanlarda görüntü sağlayabilmesi ve farklı zamansal ve mekânsal çözünürlükte veriler elde edebilmesi açısından, sınıflandırma çalışmalarında önemli bir veri kaynağı olarak öne çıkmaktadır (Metin, 2022). Görüntü sınıflandırma, uydu ve hava görüntülerinden elde edilen spektral verileri analiz ederek, görüntüdeki her bir pikselin, belli bir arazi örtüsü sınıfına ait olup olmadığını belirleme işlemi olarak tanımlanabilir (Richards ve Jia, 2006).

Literatürde çeşitli sınıflandırma yöntemleri bulunmaktadır (Lu ve Weng, 2007). Bu yöntemler veri işleme yaklaşımına göre piksel tabanlı ve nesne tabanlı sınıflandırma olarak ikiye ayrılır. (Blaschke, 2010). Son yıllarda ise yüksek doğruluk ve karmaşık verilerle başa çıkabilme yetenekleri nedeniyle makine öğrenimi yaklaşımı ile görüntü sınıflandırma çalışmalarına olan ilgi artmıştır. Makine öğrenimi yaklaşımı, çok boyutlu verilerle etkili çalışabilmeleri, öğrenme temelli yapıları sayesinde diğer yöntemlere göre daha iyi performans göstermeleri, çeşitliliği ve sağlamlıkları açısından daha çok tercih edilmeye başlanmıştır (Jamil ve ark., 2019).

Makine öğrenimi yaklaşımı denetimli öğrenme ve denetimsiz öğrenme iki sınıfta incelenmektedir (Kıbrıs, 2022). Denetimli öğrenme ile sınıflandırma işleminde, görüntüye ait piksellerin belli bir sınıfı temsil edecek şekilde etiketleme yöntemi kullanılırken; denetimsiz öğrenme işleminde ise kümeleme yöntemi kullanılır (Kıraç, 2021). Görüntü sınıflandırma işlemi için kullanılan birçok makine öğrenimi algoritması mevcuttur. Destek Vektör Makineler (DVM), rastgele orman (RO), Naive Bayes, k-En Yakın Komşu (KNN), Karar Ağaçları (KA), K-Means, ISODATA, Yapay Sinir Ağları, Maksimum Olasılık bu algoritmalarından bazılarıdır.

Bu tez çalışmasında uydu görüntülerine dayalı AK/AÖ sınıflandırmasında farklı makine öğrenmesi algoritmalarının performansları incelenmiştir. Bu kapsamda Avrupa

Uzay Ajansı (ESA) tarafından geliştirilen ve 10 metreye kadar mekânsal çözünürlüğe sahip Sentinel-2 uydu görüntüsü kullanılmıştır. Çalışma kapsamında, 2018, 2021 ve 2024 yıllarına ait veriler analiz edilmiştir. Böylelikle farklı tarihlere ait uydu görüntüleri kullanılarak, arazi örtüsü üzerindeki zamansal değişim incelenmiştir. Sınıflandırma sürecinde, yaygın olarak kullanılan DVM, RO, Naive Bayes ve KNN makine öğrenmesi algoritmaları tercih edilmiştir. Bu algoritmaların tamamı, aynı veri kümeleri üzerinde çalıştırılmış, hesaplanan doğruluk metrikleri (genel doğruluk, üretici doğruluğu, kullanıcı doğruluğu, kappa değeri ve F1score değeri) ve sonuç görüntüleri ile performansları karşılaştırılmıştır.

Tez çalışmasında, sınıflandırma işleminin tüm işlem adımları Google Earth Engine (GEE) platformu üzerinden uygulanmıştır. Genel doğruluk, kullanıcı doğruluğu, üretici doğruluğu, F1score değeri ve kappa değeri gibi doğruluk ölçütleri hesaplanıp, ayrıntılı bir şekilde değerlendirilmiştir. Çalışma doğrultusunda, kullanılan algoritmalarının sınıfları ayırma işlemini daha iyi öğrenmesini sağlamak amacıyla veri kümeleri, hem %80 eğitim verisi-%20 test verisi hem de %70 eğitim verisi-%30 test verisi olarak tanımlanmıştır. Literatür incelendiğinde veri kümeleri genellikle tek bir veri oranı ile tanımlanmakta ve buna göre işlem yapılmaktadır. Tez çalışma kapsamında her iki yöntem de kullanılmış ve bunların karşılaştırılması yapılmıştır. Böylelikle, veri oranlarında ki değişimin sınıflandırma doğruluğunu nasıl etkilediği konusu irdelenmiştir. Elde edilen sonuçlar sayısal, mekânsal ve görsel olarak ortaya sunulmuştur.

Bu çalışmada farklı makine öğrenmesi algoritmaları aynı çalışma alanı ve aynı eğitim verisi üzerinden test edilmiştir. Bunun yanı sıra üç farklı tarihe ait uydu görüntüleri birlikte değerlendirilerek zamansal analiz yapılmıştır. Literatüre bakıldığında çoğunlukla tek bir tarih üzerinden çalışmalar yürütülmüş veya tek bir eğitim-test veri oranlarının etkisi incelenmiştir. Bu tez, hem birden fazla algoritmanın performans farklılıklarını ortaya koyması, zamansal analiz yapılması, farklı oranlarda eğitim-test verilerinin etkisinin incelenmiş olması özelliği ile benzer çalışmalardan ayrılmaktadır.

Çalışma beş farklı bölümden oluşmaktadır. Birinci bölüm, çalışmanın amacını ve önemini açıklayan, çalışmada kullanılan veriler hakkında kısa bilgiler içeren giriş bölümünü içermektedir. İkinci bölümde, çalışmanın konusu ile ilgili araştırmalar yapılmış ve gerçekleştirilen benzer çalışmalardan bahsedilmiştir. Üçüncü bölüm, uzaktan algılama teknolojisi, sınıflandırma yöntemleri ve kullanılan makine öğrenmesi

algoritmalar hakkında bilgiler içermektedir. Dördüncü bölüm, sınıflandırma çalışması sürecinde izlenen işlem adımlarının açıklandığı uygulama bölümü ve işlem sonucunda elde edilen bilgilerin sunulup, yorumlandığı tartışma bölümüdür. Beşinci ve son bölümde ise çalışmanın genel sonuçlarından ve sonraki çalışmalar için çeşitli önerilerden bahsedilmiştir.



2. KAYNAK ARAŞTIRMASI

AK/AÖ sınıflandırması çalışmaları, çevresel yönetim, kentsel planlama ve doğal kaynakların yönetimi gibi konular için önemli bir bileşen haline gelmiştir. Bu bağlamda uydu görüntülerinin yorumlanıp, elde edilen verilerin sınıflandırılması konusunda pek çok çalışma yapılmıştır. Özellikle son yıllarda, UA verilerinin makine öğrenmesi algoritmaları ile sınıflandırma doğruluğunun artırılması önemli çalışma konularından biri olmuştur (Belgiu ve Dragut, 2016). Bu bölümde tez kapsamında kullanılan sınıflandırma yöntemleri, algoritmaları ve veri kaynakları ile ilgili yapılan çalışmalar incelenmiştir.

Danacıoğlu (2023) yaptığı çalışmada, Google Earth Engine (GEE) üzerinde üç çeşit (CART, DVM, RO) makine öğrenmesi algoritması kullanarak sınıflandırma işlemi gerçekleştirmiştir. Araştırmada 2022 yılına ait Sentinel-2 uydu görüntüsü kullanılmıştır. Bu çalışmada İzmir ili AK/AÖ haritasını elde etmek ve kullanılan algoritmaların performanslarının karşılaştırılması amaçlanmıştır. Bu doğrultuda %70 eğitim verisi, %30 test verisi elde edilmiştir. Sınıflandırma işleminde genel doğruluk oranları RO %97.2, DVM %96.1 ve CART %93.3 olarak hesaplanmıştır. Elde edilen sonuçlara göre RO algoritması, genel doğruluğu en yüksek algoritma olarak tespit edilmiştir.

Üstüner ve Şanlı (2017), AK/AÖ sınıflandırma çalışması için DVM, RO ve KNN makine öğrenme algoritmalarını ve parametrik yapıda olan En Çok Benzerlik (EÇB) sınıflandırıcısını kullanmışlardır. Bunun için Landsat-8 uydu görüntüsünden yararlanılmıştır. Yapılan çalışmada elde edilen sonuçlara göre en yüksek genel doğruluğu %96.8 oranı ile DVM vermiştir. En düşük doğruluğu ise parametrik yapıya sahip EÇB sınıflandırıcısı vermiştir.

Arpitha ve ark. (2023), GEE üzerinde üç farklı makine öğrenmesi (CART, DVM, RO) kullanarak Karnataka eyaletinin tamamında AK/AÖ sınıflandırma çalışması yapmayı amaçlamışlardır. Ayrıca 2015-2021 yılları arasındaki AK/AÖ değişimlerini incelemişlerdir. Uydu görüntüsü olarak, Landsat-8 ve Sentinel-2 uydu görüntüleri kullanılmıştır. Elde edilen sonuçlara göre %95 gibi genel doğruluk oranı ile RO algoritması diğer algoritmalara göre daha yüksek sonuç verdiği görülmüştür. Bu çalışmada zaman serisi uydu verilerinin de sınıflandırma başarısını etkilediği vurgulanmıştır.

Talukdar ve ark. (2020) tarafından yapılan çalışmada, UA verileri kullanılarak AK/AÖ sınıflandırma işlemi yapılmıştır. Bu doğrultuda Landsat-8 uydu görüntüleri kullanılmıştır. Çalışma kapsamında RO, DVM, YSA, Spectral Angle Mapper (SAM),

Fuzzy ARTMAP, Mahalanobis Distance makine öğrenmesi algoritmaları tercih edilmiştir. Bulgulara göre RO algoritması hem istatistiksel hem de indekslere dayalı uyumu ile en yüksek genel doğruluk oranına (%89) sahip olduğu gözlemlenmiştir.

Metin (2022) yaptığı çalışmada sınıflandırma işlemi için makine öğrenmesi algoritmalarından DVM, KNN Navie Bayes, KA, RO algoritmalarını kullanmıştır. Çalışma doğrultusunda Göktürk-2, Landsat-8 ve Sentinel-2 uydu görüntülerinden yararlanılmıştır. Araştırma kapsamında DVM algoritmasının hem Göktürk-2 hem de Sentinel-2 uydularında %98 gibi genel doğruluğa sahip en iyi performans gösteren algoritma olduğu tespit edilmiştir.

Kıraç (2021), makine öğrenmesi algoritmalarını kullanarak uzaktan algılanmış görüntüler üzerinden sınıflandırma işlemi gerçekleştirmiştir. Görüntü olarak, UltraCam-X hava kamerası kullanılmıştır. Bunun için Maksimum Olasılık(MO), DVM, YSA algoritmalarını kullanmıştır. Yapılan deneyler sonucunda genel doğruluk oranı en yüksek %82.6 gibi bir sonuçla YSA olduğu tespit edilmiştir. DVM ve MO algoritmalarının genel doğruluk oranları sırasıyla %78.7 ve %73.9 olarak hesaplanmıştır.

Yalçın (2022), Sentinel-2 uydu görüntüsü kullanarak sınıflandırma algoritmalarını karşılaştırmış ve doğruluk analizlerini değerlendirmiştir. Yapılan çalışmada denetimsiz sınıflandırma metodu olan K-Kümeleme (K-Means) ve denetimli KNN algoritması kullanılmıştır. Çalışma kapsamında Python dilinde gerekli kodlamalar yapılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma çalışmasında %50 eğitim verisi ve %50 test verisi tanımlanmıştır. Elde edilen sonuçlara göre denetimli KNN algoritması en yüksek sınıflandırma doğruluğunu vermiştir.

Tunca ve Köksal (2021) bitki türlerinin uydu görüntüleri ile sınıflandırılması çalışmasında üç farklı (RO, DVM, KNN) algoritma kullanmıştır. Sınıflandırma işleminde Sentinel-2 uydu görüntüsü tercih edilmiştir. Çalışma kapsamında elde edilen sonuçlara göre en iyi sonucu %95.3 genel doğruluk oranı ile RO verirken, %75.9 genel doğruluk oranı ile DVM algoritmasının en düşük sonuca sahip olduğu tespit edilmiştir. Ayrıca bu çalışmada %70 eğitim verisi ve %30 test verisi belirlenmiştir.

Kovarnik ve Janova (2025) Sentinel-2 uydu görüntülerine dayalı makine öğrenmesi algoritmaları karşılaştırmıştır. Yapılan araştırmada RO, DVM, Naive Bayes ve CART olmak üzere dört adet algoritma kullanılmıştır. Sınıflandırma işlemi GEE platformu üzerinde gerçekleştirilmiştir. Çalışma doğrultusunda %70 eğitim verisi ve

%30 test verisi elde edilmiştir. Sonuçlara göre RO algoritması %98.3 sınıflandırma doğruluğu ile en yüksek orana sahip olduğu görülmüştür.

Oturanç (2024) yaptığı çalışmada Sentinel-2B uydu görüntüsü kullanarak sınıflandırma işlemi gerçekleştirmiştir. Çalışmada DVM ve YSA algoritmaları ile NDVI ve NDRE indekslerinin doğruluk analizleri incelenmiştir. Elde edilen sonuçlara göre DVM algoritması %89 genel doğruluk oranı ile en yüksek sınıflandırma doğruluğuna sahip olduğu görülmüştür. %84 genel doğruluk oranı ile de NDRE indeksi en düşük sonucu vermiştir.

Cui ve ark. (2023) tarafından geliştirilen eğitim örneklerinin otomatik olarak üretilmesi yöntemiyle bir sınıflandırma çalışması yapılmıştır. Bu çalışmada makine öğrenmesi algoritmaları kullanılmıştır. GEE üzerinden yapılan bu sınıflandırma çalışmasında RO algoritması %92.99 genel doğruluk oranı ile en yüksek sonucu vermiştir.

Hosseiny ve ark. (2022) Sentinel-2 uydu görüntüleri ve yardımcı verileri kullanarak bir arazi sınıflandırması gerçekleştirmiştir. Çalışmada hem makine öğrenmesi hem de derin öğrenme algoritmaları kullanılmış ve bu algoritmaların karşılaştırmalı analizi yapılmıştır. Bu doğrultuda elde edilen sonuçlara göre derin öğrenme algoritması olan ResNet50 algoritması %92.95 oranı ile en yüksek sınıflandırma doğruluğunu verdiği görülmüştür. Makine öğrenmesi algoritmaları ise %83-86 arasında değişim göstermiştir.

Zhoe ve ark. (2024) tarafından gerçekleştirilen çalışmada, GEE platformu üzerinden Sentinel-2 uydu verileri kullanılarak sınıflandırma çalışması yapılmıştır. Bu çalışmada üç farklı makine öğrenmesi algoritması (RO, DVM, CART) kullanılmıştır. Çalışma kapsamında %70 eğitim verisi ve %30 test verisi tanımlanmıştır. Ayrıca NDVI, MNDWI ve NDBI gibi yardımcı veriler de kullanılarak her iki yöntemin performansları değerlendirilmiştir. Yapılan çalışmanın sonuçlarına göre makine öğrenmesi algoritmaları diğer yönteme göre yüksek bir başarı elde etmiştir.

Guizani ve ark. (2025) tarafından yapılan çalışmada, 2018, 2020 ve 2022 yıllarına ait Sentinel-2 ve Landsat 8 uydu verileri ile arazi sınıflandırması gerçekleştirilmiştir. Çalışma doğrultusunda üç adet makine öğrenmesi algoritması (DVM, MO, RO) kullanılmıştır. Bu kapsamda bu üç algoritmanın karşılaştırmalı analizi yapılmıştır. Bu kapsamda %70 eğitim verisi ve %30 test verisi elde edilmiştir. Sonuç olarak, Sentinel-2 uydu görüntüleri üzerinden DVM ile yapılan sınıflandırmada %88 genel doğruluk

oranına ulaşılmış ve DVM algoritmasının diğer algoritmalarla göre daha iyi bir sonuç verdiği tespit edilmiştir.

Shetty (2019) yaptığı çalışmada, GEE platformu üzerinden AK/AÖ sınıflandırması yapılmıştır. Gerçekleştirilen bu çalışmada DVM, RO, CART olmak üzere üç farklı makine öğrenmesi algoritması kullanılmıştır. Bu kapsamda %70 eğitim verisi ve %30 test verisi belirlenmiştir. Çalışmada, kullanılan algoritmaların karşılaştırmalı analizi değerlendirilmiştir. Landsat 8 uydu verileri kullanılan bu çalışmada RO algoritması diğerlerine göre daha iyi bir sınıflandırma doğruluğu vermiştir.

Dzulhijjah ve ark. (2025), orman alanlarını doğru bir şekilde sınıflandırmak için Sentinel-2 uydu görüntüleri üzerinden bir çalışma gerçekleştirmiştir. Bu çalışmada RO, DVM, KNN, CART ve GBT gibi makine öğrenmesi algoritmaları kullanılmış ve bunların karşılaştırmalı analizi yapılmıştır. Elde edilen eğitim ve test verileri sırasıyla %80-%20 olarak belirlenmiştir. Yapılan çalışma sonucunda en yüksek sonucu RO ve GBT algoritmaları vermiştir.

Basheer ve ark. (2022), farklı uydu görüntüleri (Sentinel, Landsat, Planet) ve farklı platform (ArcGIS Pro, GEE) üzerinden bir arazi sınıflandırması gerçekleştirmiştir. Gerçekleştirilen bu sınıflandırma işleminde RO, DVM, KA, KNN gibi algoritmaların performansları değerlendirilmiştir. Elde edilen sonuçlara göre DVM algoritmasının her iki platformda diğer algoritmalarla kıyasla en yüksek performansı sergilediği görülmüştür.

Zafar ve ark. (2024) tarafında yapılan bir araştırmada, AK/AÖ sınıflandırması için makine öğrenmesi algoritmalarının karşılaştırmalı analizi gerçekleştirilmiştir. Bunun için yaygın olarak kullanılan RO, CART, DVM algoritmaları tercih edilmiştir. Çalışma kapsamında Landsat-7, Landsat-8 ve Landsat-9 uydularından alınan 2008, 2015 ve 2022 tarihlerine ait görüntüler kullanılmıştır. Araştırmada, %70 eğitim verisi ve %30 test verisi belirlenmiştir. Sonuçlara göre, RO %95,2 genel doğruluk oranı ile en iyi performans gösteren algoritma olarak tespit edilmiştir.

Loukika ve ark. (2021), Sentinel-2 ve Landsat-8 verileri kullanarak, 2016-2018-2020 yıllarına ait görüntüler üzerinden bir sınıflandırma çalışması yapmışlardır. Sınıflandırma çalışması için DVM, RO, CART algoritmaları kullanılmıştır. Ayrıca NDWI ve NDVI gibi yardımcı verilerden de faydalanılmıştır. Bu kapsamda %70 eğitim verisi ve %30 test verisi belirlenmiştir. Sonuçlar incelendiğinde RO algoritmasının her iki uydu görüntülerinde de yüksek sınıflandırma doğruluğu sergilediği görülmüştür.

Qian ve ark. (2015) tarafından yapılan çalışmada, arazi örtüsü sınıflandırması için makine öğrenme algoritmalarından DVM, Naive Bayes, CART ve KNN algoritmaları kullanılmıştır. Çalışmada WorldView-2 uydu görüntüleri üzerinden sınıflandırma gerçekleştirilmiştir. Sonuçlar incelendiğinde DVM ve NB algoritmaları sırasıyla %92,6 ve %96,4 genel doğruluk oranları ile en yüksek sonuçları vermiştir.

Jamil ve Bayram (2018) yaptıkları çalışmada, büyük ölçekli verilerden AK/AÖ sınıflandırması için makine öğrenmesi algoritmalarından DVM, YSA ve RO kullanılmıştır. Görüntüler UltraCam-X hava kamerasıyla elde edilmiştir. Sonuçlara göre YSA algoritması diğer algoritmalara göre daha yüksek sınıflandırma doğruluğu vermiştir.

Tablo 2.1’de kaynak araştırmasının özeti verilmiştir.



Tablo 2.1: Kaynak araştırması özeti

Yazar/Yıl	Çalışmanın Konusu	Veri Seti	Yöntem	Örnek Veri	Bulgular
Danacıoğlu,2023	Makine Öğrenmesi Algoritmalarını Karşılaştırmak	Sentinel-2 Uydusu	CART,DVM,RO	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu RO algoritması vermiştir.
Üstüner ve Ark., 2017	Makine Öğrenmesi Algoritmalarını Karşılaştırmak	Landsat-8 Uydusu	DVM,RO,KNN	Belirtilmemiş	En yüksek sonucu DVM algoritması vermiştir.
Arpitha ve Ark., 2023	2015-2021 Yılları Arasındaki AK/AÖ değişimi analizi	Sentinel-2 Uydusu	CART,DVM,RO	Belirtilmemiş	En yüksek sonucu RO algoritması vermiştir.
Talukdar ve Ark., 2020	Uzakta Algılama Verileri ile AK/AÖ sınıflandırması	Landsat-8 Uydusu	RO,DVM,YSA,SAM, Fuzzy,ARTMAP,Mahalanobis Distance	Belirtilmemiş	En yüksek sonucu RO algoritması vermiştir.
Metin, 2022	Farklı Uyduların AK/AÖ Sınıflandırma Çalışmasında Karşılaştırmalı Analizi	Göktürk-2, Landsat-8, Sentinel-2	DVM,Naive Bayes,RO,KA,KNN	Belirtilmemiş	Göktürk Uydusu ile Yapılan Çalışmada DVM En yüksek Sonucu vermiştir.
Kıraç, 2021	Makine Öğrenmesi Algoritmaları ile Görüntü Sınıflandırma	UltraCam-X dijital hava kamerası	MO, DVM, YSA	Belirtilmemiş	En yüksek Sonucu YSA algoritması vermiştir.
Yalçın, 2022	Makine Öğrenmesi Algoritmalarını Karşılaştırmak	Sentinel-2 Uydusu	K-Means, KNN	%50 Eğitim Verisi %50 Test Verisi	En yüksek Sonucu KNN algoritması vermiştir.
Tunca ve Köksal, 2021	Bitki Türlerini Uydu Görüntüleri İle Sınıflandırma	Sentinel-2 Uydusu	DVM,RO,KNN	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu RO algoritması vermiştir.
Kovarnik ve Janova, 2025	Makine Öğrenmesi Algoritmalarını Karşılaştırmak	Sentinel-2 Uydusu	RO, DVM, Naive Bayes, CART	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu RO algoritması vermiştir.
Oturanç, 2024	Makine Öğrenmesi Algoritmaları ile AK/AÖ Belirlemek	Sentinel-2 Uydusu	DVN, YSA, NDVI, NDRE	Belirtilmemiş	En yüksek sonucu DVM algoritması vermiştir.
Cui ve Ark., 2023	Eğitim Örneklerinin Otomatik Üretilmesi Yöntemiyle Sınıflandırma Çalışması	Landsat-8 Uydusu	CART,DVM,RO	Belirtilmemiş	En yüksek sonucu RO algoritması vermiştir.
Hosseiny ve Ark., 2022	Uydu Görüntüleri ve Yardımcı Veriler ile Sınıflandırma Çalışması	Sentinel-2 Uydusu	DVM,RO,CNN,XGB ResNet50	Belirtilmemiş	En yüksek sonucu ResNet50 algoritması vermiştir.
Zhoe ve Ark., 2024	Makine Öğrenmesi Algoritmaları ile Yardımcı Verilerin Karşılaştırılması	Sentinel-2 Uydusu	RO,DVM,CART, NDVI,MNDWI, NDBI	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu Makine Öğrenmesi algoritmaları vermiştir.
Guizani ve Ark., 2025	3 Farklı yıla ait Uydu Görüntüleri ile Arazi Sınıflandırma Çalışması	Sentinel-2, Landsat-8 Uydusu	DVM, MO,RO	%70 Eğitim Verisi %30 Test Verisi	Sentinel-2 Uydusu ile Yapılan Çalışmada DVM En yüksek Sonucu vermiştir
Shetty, 2019	GEE Platformu Üzerinden AK/AÖ Sınıflandırma Çalışması	Landsat-8 Uydusu	DVM,RO,CART	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu RO algoritması vermiştir.
Dzulhijjah ve Ark., 2025	Orman Alanlarını Sınıflandırma Çalışması	Sentinel-2 Uydusu	RO,DVM,KNN, CART, GBT	%80 Eğitim Verisi %20 Test Verisi	En yüksek sonucu RO ve GBT algoritması vermiştir.
Basheer ve Ark., 2022	Farklı Uydu ve Farklı Platform Üzerinden Arazi Sınıflandırması Çalışması	Sentinel, Landsat, Planet	RO,DVM,KA,KNN	Belirtilmemiş	ArcGis ve GEE platformunda DVM Algoritması en yüksek sonucu vermiştir.
Zafar ve Ark., 2024	Makine Öğrenmesi Algoritmalarını Karşılaştırmak	Landsat-7, Landsat-8, Landsat-9	DVM,RO,CART	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu RO algoritması vermiştir.
Loukika ve Ark., 2021	3 Farklı yıla ait Uydu Görüntüleri ile Arazi Sınıflandırma Çalışması	Sentinel-2, Landsat-8 Uydusu	DVM,RO,CART	%70 Eğitim Verisi %30 Test Verisi	En yüksek sonucu RO algoritması vermiştir.
Qian ve Ark., 2015	Arazi Örtüsü Sınıflandırma Çalışması	WorldView-2	DVM, Naive Bayes,CART, KNN	Belirtilmemiş	En yüksek sonucu DVM algoritması vermiştir.
Jamil ve Bayram, 2018	Arazi Örtüsü Sınıflandırma Çalışması	UltraCam-X dijital hava kamerası	DVM,YSA,RO	Belirtilmemiş	En yüksek Sonucu YSA algoritması vermiştir.

3. MATERYAL VE YÖNTEM

Bu bölümde tez çalışması sürecinde ilk olarak UA teknolojisinin görüntü sınıflandırmasındaki rolü vurgulanmıştır. Ardından kullanılan sınıflandırma yöntemi, makine öğrenmesi algoritmaları, doğruluk metrikleri ve veri setlerinden bahsedilmiştir. Son olarak uygulama kısmı ile de sınıflandırma sürecinin iş akışı anlatılmıştır.

3.1. Uzaktan Algılamada Görüntü Sınıflandırması ve Sınıflandırma Yöntemleri

Günümüzde yeryüzü hakkında hızlı ve güvenilir bir şekilde bilgi edinebilmek için UA teknolojisi büyük önem taşımaktadır. UA teknolojisinin kullanılabilmesi için çeşitli araçlar geliştirilmiştir. Uydu görüntüleri de bunlardan biridir. Teknolojinin gelişmesiyle uydu sayısı artmış ve UA ile ilgili yapılan çalışmalarda sıkça kullanılmaya başlanmıştır. Ulaşılması zor alanlarda görüntü alabilmesi, mekânsal, zamansal ve spektral çözünürlük gibi zengin özellikleri sayesinde kullanım alanı artmıştır.

Uydu görüntüleri kullanılarak yeryüzü hakkında bilgi edinmek için genellikle görüntü sınıflandırma yöntemleri kullanılmaktadır. (Metin, 2022). Görüntü sınıflandırma işlemi, görüntüdeki aynı spektral özelliklere sahip piksellerin, bir grup altında bir araya gelmesi olarak tanımlanabilir (Kıraç, 2021; Sağlam, 2024). Bu gruplama belli bir matematik işlemlerine göre yapılmaktadır (Çölkesen, 2009).

Görüntülerin sınıflandırılması işlemi ile arazilerin kullanımı veya yıllar içindeki değişimleri kolayca analiz edilmektedir. Bu bağlamda çeşitli sınıflandırma yöntemleri geliştirilmiştir. Tez çalışmasında piksel tabanlı yöntem kullanıldığı için bu yöntemden bahsedilecektir.

3.1.1. Piksel tabanlı sınıflandırma yöntemi

Piksel tabanlı sınıflandırma yönteminde, görüntüde yer alan pikseller kullanılmaktadır. Bu yöntemde, görüntünün en küçük birimi olan pikseller, spektral özelliklerine göre gerekli algoritmaların yardımıyla ilgili sınıflara atanır (Arıkan ve Yıldız, 2023). Piksel tabanlı sınıflandırma yöntemi denetimli ve denetimsiz sınıflandırma olarak iki grupta incelenmektedir.

Denetimli sınıflandırma yöntemi, bir kullanıcı yardımıyla gerçekleştirilir. Bu yöntemde çalışma alanı üzerinden örnek alanlar (eğitim verileri) belirlenir ve sınıfların spektral özellikleri tanımlanır (Al-Karkhi, 2019). Ardından sınıflandırma işlemine geçilir. Denetimli sınıflandırma yöntemi kendi içinde de parametrik ve parametrik olmayan yöntem olarak iki gruba ayrılmaktadır. Parametrik olan yöntemlere En Kısa Mesafe, EÇB gibi yaklaşımlar örnek olarak verilebilir. DVM, RO, YSA, KA gibi yaklaşımlar ise parametrik olmayan yaklaşımlara örnektir.


Denetimsiz sınıflandırma yönteminde ise, bir kullanıcıya gerek duyulmamaktadır. Bu yöntemde eğitim verileri oluşturulmaz. Çalışma alanı hakkında bilgi sahibi olunmadığı durumlarda tercih edilir. ISODATA, K-Means gibi yaklaşımlar bu yöntem için tercih edilmektedir.

3.1.2. Makine öğrenmesi ile sınıflandırma yöntemi

Piksel tabanlı ve nesne tabanlı sınıflandırma gibi geleneksel yöntemlere için birçok yöntem geliştirilmiştir. Makine öğrenmesi bu yöntemlerden biridir ve bu yöntemlerin başında gelmektedir (Kıraç, 2021). Bu yöntem ile sınıflandırma işlemi yapılırken insan etkisi mümkün olduğu kadar azaltılarak, hem zaman açısından tasarruf sağlanması hem de çalışmaların daha verimli bir şekilde yürütülmesi planlanmıştır. Makine öğrenmesi yöntemi, elde edilen verileri belli modellere göre sınıflandırıp, bu modelleri referans alarak gelecek sonuçlar için tahminlerde bulunmaktadır (Kıbrıs, 2022).

Makine öğrenmesinin karışık verileri kolayca haritalama, yüksek boyutlu verileri hızlı ve güvenilir bir şekilde işleme gibi özellikleri bulunmaktadır. Bu özellikleri sayesinde UA teknolojisinde sıkça kullanılır hale gelmiştir (Shetty, 2019). Bu yöntem ile sınıflandırma işlemi yapmak için çeşitli yaklaşımlar geliştirilmiştir. Denetimli öğrenme ve denetimsiz öğrenme en sık kullanılan yaklaşımlar arasındadır. (Talukdar ve ark., 2020).

Şekil 3.1’de makine öğrenmesinin hiyerarşisi bulunmaktadır.



Şekil 3.1: Makine öğrenmesi hiyerarşisi

Denetimsiz öğrenmede bir kullanıcıya ihtiyaç duyulmamaktadır. Etiketleme işlemleri otomatik olarak gerçekleştirilir. Bu yöntemde kullanıcı hatası en aza indirilir (Kıraç, 2021). K-Means, Fuzzy, ISODATA en çok kullanılan denetimsiz öğrenme algoritmalarıdır.


Denetimli öğrenme, makine öğrenmesi yöntemleri arasında en çok tercih edilen yöntemdir. Bu yöntemde etiketleme işlemleri bir kullanıcı tarafından yapılır. Veriler etiketlendikten sonra çeşitli algoritmalar yardımıyla sınıflandırma işlemi gerçekleştirilir. (Kıraç, 2021). Bu yöntemde, kullanıcı etiketleme işlemini doğru olarak tanımladığı sürece, denetimsiz öğrenme yöntemine göre daha yüksek sonuçlar elde edilir. Denetimli öğrenme yönteminde çeşitli algoritmalar kullanılmaktadır. Bunlar; DVM, YSA, RO, Naive Bayes, KNN, CART, KA gibi algoritmalar denetimli öğrenme algoritmalarıdır. Tez çalışması sürecinde; DVM, KNN, RO ve Naive Bayes algoritmaları kullanıldığı için bu algoritmalarından bahsedilecektir.

3.1.2.1. Rastgele orman algoritması

Torbalama yönteminin geliştirilmiş hali olarak bilinmektedir (Metlek ve Kayaalp, 2020). Hem sınıflandırma hem de regresyon için kullanılmaktadır. Denetimli öğrenme algoritmaları arasında yer almaktadır. Sınıflandırma işlemi sırasında birden fazla karar ağacı üretir ve bunlara dayalı olarak sınıflandırma tahmini yapar. Algoritmada iki adet parametre bulunmaktadır. Bunlardan biri ağaç sayısını ifade eden N parametresidir. Bir diğeri ise ağaçların yapısı için gerekli olan ve düğümlerde yer alması gereken m parametresidir. Bu parametre değişken sayısını temsil etmektedir. (Breiman, 2001)

RO algoritması ilk olarak Tin Kam Ho tarafından geliştirilmiş olup, Breiman ve arkadaşları bu algoritmayı genişletmişlerdir (Sağlam, 2024). Algoritmada bulunan ağaçlar birbirinden bağımsızdır. Bu durum algoritmanın aşırı öğrenmeye dirençli olmasını sağlamaktadır (Bakdemir, 2024). KA ile RO algoritması genelde birbirine benzetilmektedir. Aralarındaki temel fark; RO algoritmasında yer alan düğümlerin rastgele oluşuyor olmasıdır (Arıkan ve Yıldız, 2023).

Şekil 3.2’de RO algoritmasının genel gösterimi bulunmaktadır.



Şekil 3.2: Rastgele orman algoritması (Tunca ve Köksal, 2021)

3.1.2.2. k-En yakın komşu algoritması

Sınıflandırma ve regresyon yöntemlerinde kullanılan denetimli öğrenme algoritmasıdır. KNN algoritması basit ve anlaşılır yapıya sahip olduğu için kullanışlıdır. Denetimli algoritmalar arasında yer aldığı için veriler, kullanım aşamasında eğitim verisi ve test verisi olarak ayrılır (Metlek ve Kayaalp, 2020). KNN algoritmasının performansını etkileyen parametreler bulunmaktadır; k parametresi ve uzaklık ölçütleri. (Taşçı ve Onan, 2016). K parametresi komşu sayısını ifade etmektedir. Uzaklık ölçütleri için, Öklid, Manhattan, Chebyshev ve Dilca ölçütleri kullanılmaktadır (Taşçı ve Onan, 2016). Çalışmada Öklid uzaklık ölçütü kullanıldığı için bu parametreden bahsedilmiştir.

Öklid uzaklık ölçütü, iki nokta arasındaki doğrusal uzaklığı ifade eder ve yakınlık ölçümünde kullanılır (Taşçı ve Onan, 2016). Algoritmanın çalışma prensibi şu şekildedir;

- İlk önce k komşu sayısı belirlenir. Bu parametre tek sayı olmalıdır, çünkü sınıfların eşit olması algoritmayı zorlar.
- Kullanılacak uzaklık ölçütü belirlenir.
- Komşular, belirlenen uzaklık ölçüsüne göre hesaplanır ve sınıflandırma yapılır. (Sağlam 2024; Metlek ve Kayaalp, 2020).

3.1.2.3. Naive Bayes algoritması

Tembel bir makine öğrenmesi algoritması olan bu algoritma adını ünlü matematikçi Thomas Bayes'den alır. (Zhang, 2004). Denetimli öğrenme algoritmalar arasındadır. Sınıflandırma aşaması için küçük miktarda eğitim verisinin tanımlanması yeterlidir (Metin, 2022).

Naive Bayes algoritması, belli bir özellikteki varlığın, başka bir özelliğin varlığını bağımsız olarak tanır. Örnek vermek gerekirse; bir nesnenin kırmızı renkte olduğunu, yuvarlak bir şekle sahip olduğunu ve 3 inç büyüklükte olduğunu var sayalım. Bu nesnenin bir elma olduğunu düşündüğümüzde, her bir özellik, diğer özelliklerden bağımsız olmaktadır. Böylece nesnenin elma olma olasılığı artmış olmaktadır. Bu nedenle algoritma “naive” yani saf olarak adlandırılır.

3.1.2.4. Destek vektör makineleri algoritması


DVM algoritması regresyon analizlerinde de kullanılsa da, genel olarak sınıflandırma çalışmaları için tercih edilmektedir. İstatistiksel öğrenme teorisine dayanan, denetimli öğrenme algoritmasıdır. (Cortes, 1995). DVM algoritmasının temel amacı, iki sınıfı birbirinden ayırabilecek, aralarındaki marjı maksimize eden optimum hiper düzlemi tanımlamaktır (Bulut ve Günlü, 2016; Çölkesen, 2009).

DVM algoritması, küçük ve orta ölçeklere sahip veriler için yüksek performans göstermektedir. (Sağlam, 2024) Bu algoritma eğitim verilerinin bilgilerine bağlı olarak, sınıf etiketlerini öğrenmek için bir model oluşturur. Bu algoritma sınıflandırma aşamasında iken verilerden bir hiper düzlem meydana getirir. N boyutlu bir veri kümesinde, sınıflandırma yapmak için N-1 boyutlu bir hiper düzlem tanımlanır. İki sınıflı problemlerde sonsuz sayıda veri kümelerini ayırabilecek hiper düzlem bulunsa da, sadece maksimum marja yakın olan hiper düzlem seçilir.

Hiper düzlem matematiksel olarak aşağıdaki gibi ifade edilmektedir (Arıkan ve Yıldız, 2023).

$$wTx+b=0 \quad (1)$$

Burada w, normal vektör olarak ifade edilir, x veri noktası ve b ise hiper düzlemin kesişim noktası olarak ifade edilir. Şekil 3.3'te de gösterildiği gibi sınırda yer alan noktalar destek vektör olarak adlandırılır.



Şekil 3.3: İkili sınıflandırma probleminin DVM ile çözümü.

DVM algoritması verilerin türüne bağlı olarak çekirdek (Kernel) fonksiyonlarına ihtiyaç duymaktadır. Çekirdek fonksiyonları doğrusal olmayan verilerin sınıflandırılmasında kullanılır. Literatürde, doğrusal olmayan veriler için geliştirilen farklı çekirdek fonksiyonları bulunmaktadır (Akar ve Görmüş, 2019). Çalışmada polinom ve lineer fonksiyonu kullanıldığı için Tablo 3.1’de sadece bu iki fonksiyona yer verilmiştir.

Tablo 3.1: DVM’de kullanılan çekirdek fonksiyonları

Çekirdek Fonksiyonları	Formüller	Parametreler	Açıklama
Lineer	$K(x_i, x_j) = x_i \cdot x_j$	-	Doğrusal olarak ayrılabilen veriler için kullanılır.
Polinom	$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + C)^d$ $\gamma > 0$	d : polinom derecesi, γ : ölçekleme parametresi	Eğitim verilerinin normalleştirildiği problemler için kullanılır.

3.1.3. Doğruluk analizi

AK/AÖ sınıflandırma çalışmalarında elde edilen haritalarının doğruluklarının değerlendirilmesi, çalışmaların güvenilirliği açısından önemli bir yere sahiptir (Metin, 2022). Sınıflandırma sonucunda belirlenen sınıfların, gerçek uzaydaki durumları ile uyumlu olup olmadıklarını tespit etmek için doğruluk analizi yapılması gerekir. (Metin,

2022; Alganci ve Efe, 2023). Bu amaçla, sınıflandırma çalışmalarında çeşitli doğruluk ölçütleri kullanılmaktadır. Bunlar; genel doğruluk, kappa değeri, F1score, üretici doğruluğu ve kullanıcı doğruluğudur.

Genel Doğruluk, doğru bir şekilde sınıflandırılan toplam piksel sayısının, elde edilen toplam piksel sayısına oranıdır. Sınıflandırmanın genel etkinliğini gösterir. Matematiksel ifadesi aşağıda gösterilmiştir (Danacıoğlu, 2023).

$$\text{Genel Doğruluk} = \frac{\text{Doğru Sınıflandırılan Piksel Sayısı}}{\text{Elde Edilen Piksel Sayısı}} \times 100 \quad (2)$$

Üretici Doğruluğu, her bir sınıftaki doğru sınıflandırılan piksellerin, o sınıfa ait toplam piksel sayısına oranı ifade eder. Matematiksel ifade aşağıdaki gibidir (Danacıoğlu, 2023).

$$\text{Üretici Doğruluğu} = \frac{\text{Her Sınıftaki Doğru Sınıflandırılan Piksel Sayısı}}{\text{O sınıfa Ait Toplam Piksel Sayısı (Sütun)}} \times 100 \quad (3)$$

Kullanıcı Doğruluğu, her bir sınıftaki doğru sınıflandırılan piksellerin, o sınıfa ait toplam piksel sayısına oranı olarak tanımlanabilir (Metin, 2022).

$$\text{Kullanıcı Doğruluğu} = \frac{\text{Her Sınıftaki Doğru Sınıflandırılan Piksel Sayısı}}{\text{O sınıfa Ait Toplam Piksel Sayısı (Satır)}} \times 100 \quad (4)$$

Kappa değeri, sınıflandırma işlemlerinde, algoritmaların rastgele tahminlerinde ne kadar iyi olduğunu ifade eder (Danacıoğlu, 2023) Kappa değeri, 0 ile 1 arasında bir değer alır. Elde edilen değer 1'e yakın olması sonucun iyi olduğunu, 0'a yakın olması ise kötü olduğunu gösterir. Matematiksel ifadesi aşağıda gösterilmiştir.

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} * x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} * x_{+i}} \quad (5)$$

Formüldeki N toplam piksel sayısını, r tanımlanan sınıf sayısını, x_{i+} toplam satırı, x_{+i} toplam sütunu ve x_{ii} hata matrisindeki köşegen elemanlarını (doğru olarak sınıflandırılan pikselleri) ifade eder (URL1).

F1score ise, sınıflandırma çalışmalarında kullanılan modelin kesinlik ve duyarlılık arasındaki dengeyi sağlayan bir metriktir. (URL2) Matematiksel ifadesi aşağıdaki gibidir.

$$F1score = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \times 100 \quad (6)$$

Formülde gösterilen kesinlik, sınıflandırıcının pozitif dediği verilerin gerçekte de pozitif olup olmadığını ifade eder. Duyarlılık ise, pozitif verilerin tanımlanmasında sınıflandırıcının ne kadarını seçtiğini gösterir (Metin, 2022). Yani kesinlik, sınıflandırıcı veriye yol dediğinde gerçekte de yol olma olasılığını hesaplar. Duyarlılık ise yol alanları içinde gerçekten yol olarak bulabildiği oranı hesaplar.

3.2. Kullanılan Veri

3.2.1. Çalışma alanı


Konya ili, Türkiye'nin İç Anadolu Bölgesi'nde yer almaktadır. Yüzölçümü bakımından ülkenin en büyük şehridir. Deniz seviyesinden yüksekliği ortalama 1016 m'dir. Batısında Afyonkarahisar ve Isparta, doğusunda Niğde ve Kahramanmaraş, güneyinde Mersin ve Antalya, kuzeyinde ise Aksaray ve Ankara illeri bulunmaktadır. Konya'da, karasal iklim hâkim olup, yazları sıcak ve kurak, kışları ise soğuk ve yağışlı geçmektedir.

TÜİK 2024 verilerine göre şehirdeki toplam nüfus yaklaşık 2 milyon 330 bin kişidir. Nüfusun büyük bir çoğunluğu kent merkezinde yaşamaktadır. Konya'da yaşayan nüfusun büyük bir bölümü tarım ve sanayi sektörlerinde çalışmaktadır (TÜİK 2024)

Tahıl ambarı olarak anılan Konya'nın, geniş ve düz ovaya sahip olması tarım faaliyetleri için önemli bir yer haline gelmiştir. Ülke genelindeki tarım arazilerinin yaklaşık %11,2'si Konya'da bulunmaktadır (URL3). Buğday, mısır, ayçiçeği, arpa, şeker pancarı gibi ürünler yaygın olarak yetiştirilmekte olup, son zamanlarda sebze üretimi de yapılmaktadır (URL3).

Son dönemlerde Konya sanayi sektöründe gelişmeler kaydetmiştir. Organize sanayi ve küçük sanayiler ile birlikte ülke ekonomisine katkı sağlamaktadır. Konya Organize Sanayi Bölgesi, tarım ve sanayinin iş birliği yapmasını sağlayarak, şehrin ekonomisinin yapısını çeşitlendirmektedir (Demiröz ve Yıldız, 2021). Bu yönleri ile Konya, hem sanayi hem de tarım açısından ülkenin önemli merkezlerinden biri haline gelmiştir.

Çalışma sürecinde kullanılan çalışma alanı, Konya ilinin yaklaşık olarak $32^{\circ}27'45.03''$ - $32^{\circ}38'19.08''$ K ve $37^{\circ}53'58.82''$ - $38^{\circ}02'27.92''$ D koordinatları arasında kalmaktadır. Çalışma alanı 243 km²'lik bir alanı kapsamaktadır. Şekil 3.4'te çalışma alanı ve çalışma alanı üzerinde belli başlı bölgeler gösterilmiştir.



Şekil 3.4: Çalışma alanı ve üzerinde bulunan belli başlı bölgeler.

3.2.2. Sentinel-2 uydusu

UA teknolojisinin gelişmesiyle birlikte, yeryüzü üzerindeki değişimlerin incelenmesi için uydu sayısı artmış ve bu uyduların kullanımı da yaygınlaşmıştır. Bu

uydular arasında Landsat, MODIS, Sentinel gibi uydular yer almakta olup, Sentinel uyduları yeryüzü değişimlerinin incelenmesinde sık tercih edilen veri kaynağı olmuştur. Sentinel uyduları Avrupa Uzay Ajansı (ESA) tarafından geliştirilen bir uydu filosudur (Danacıoğlu, 2023). Copernicus programı çerçevesinde uzaya gönderilen bu uydular yeryüzünün gözlenmesi için tasarlanmıştır. (ESA, 2024)

Sentinel uyduları arasında en çok tercih edilen uydu Sentinel-2 uydusudur. (Yalçın, 2022) Sentinel-2 serisi, Sentinel-2A ve Sentinel-2B olmak üzere çift uydudan oluşmaktadır. Sentinel-2A Haziran 2015, Sentinel-2B Mart 2017 tarihinde uzaya fırlatılmıştır. Çalışma kapsamında Sentinel-2A uydu görüntüleri kullanılmıştır. 13 adet multispektral bant içeren bu uydular, 10m, 20m ve 60m mekânsal çözünürlüğe sahiptir (Wang ve ark., 2016). Tablo 3.2’de uyduya ait bantlar gösterilmiştir.

Sentinel-2A ve Sentinel-2B uydu çiftleri, 5 günde bir 56°G ve 83°K enlemleri arasında kıyı ve kara gözetimi için görüntüleme sağlamaktadır. Ayrıca bu uydu ücretsiz olup kullanıcılar için Level 1C ve Level 2A olmak üzere iki adet ürün sağlar. Level 1C atmosfer üstü gözlem yaparken, Level 2A ise atmosfer altı gözlem yapmaktadır (Fang, 2023).

Tablo 2.2: Sentinel-2 uydusuna ait bantlar ve özellikleri (ESA, 2024).

Bant No	Bant Adı	Merkez Dalga Boyu (µm)	Mekânsal Çözünürlük (m)	Radyometrik Çözünürlük	Kullanım Alanları
B1	Kıyı aerosol	0.443	60	12-bit	Su yüzeyinde aerosol tespiti
B2	Mavi	0.490	10		Su gövdesi ve bitki örtüsü harıtlama
B3	Yeşil	0.560	10		Bitki örtüsü ve su izleme
B4	Kırmızı	0.665	10		Bitki örtüsü ve arazi örtüsü sınıflandırması
B5	Kırmızı Kenar	0.705	20		Kırmızı kenar tespiti
B6	Kırmızı Kenar	0.740	20		Kırmızı kenar tespiti
B7	Kırmızı Kenar	0.783	20		Kırmızı kenar tespiti
B8	NIR	0.842	10		Bitki sağlığı, su/karayolu ayrımı
B8A	Dar NIR	0.865	20		Bitki türü ayrımı, biyofiziksel parametreler
B9	Su Buharı	0.945	60		Atmosferik su buharı tespiti
B10	SWIR – Cirrus	1.375	60		Cirrus bulutlarının tespiti
B11	SWIR	1.610	20		Bitki su içeriği, toprak nemi, yangın izleme
B12	SWIR	2.190	20		Bitki su içeriği, toprak nemi, yangın izleme

Son zamanlarda Sentinel-2 uydusunun ücretsiz olması, açık erişimli olması ve çok bantlı yapısı sayesinde; arazi kullanımı/arazi örtüsü değişiminin belirlenmesi (Algancı ve Efe, 2023; Arpitha ve ark., 2023), orman yangınları (Makineci, 2024), bitki türlerinin belirlenmesi (Tunca ve Köksal, 2021) yüzey su alanlarının tespiti (Pahlevan ve ark., 2017) gibi birçok alanda tercih edilen ver kaynağı haline gelmiştir. Bu tez çalışma sürecinde Sentinel-2A uydu görüntüleri kullanılmıştır.

Sınıflandırma çalışmasında, temel renk bilgisi sunan B2, B3, B4 görünür bantları; bitki örtüsünü ayırt etmede kullanılan B5 kırmızı kenar bandı; bitki sağlığını ayırt etmede kullanılan B8 yakın kızılötesi bandı; bitki örtüsü türleri arasında kontrast sağlayan B11 kısa dalga kızılötesi bandı kullanılmıştır. Bu bant kombinasyonu literatürde farklı çalışmalarda kullanılmış ve etkin sonuçlara ulaşılmıştır (Nguyen ve ark., 2020; Wang ve ark., 2021)

Tez çalışmasında NDVI gibi indeksler kullanılmamış olsa da, Bu bantların birlikte kullanılması, tarım arazileri, yeşil alanlar ve kentsel alanlar gibi sınıfların birbirinden ayrılmasını kolaylaştırmaktadır. Kullanılan bantların her biri, farklı spektral aralıklarda ve kendilerine has yansıma özelliklerine sahiptir. Bu doğrultuda; tarım alanları, yeşil bitki örtüsü alanları, kentsel bölgeler gibi sınıfların birbirinden ayrılmasını kolaylaştırmaktadır. Bu bağlamda bantların birlikte kullanılması, her bandın sağladığı spektral bilgi ile sınıflandırma başarısını arttırmaktadır (Phiri, 2020).


3.2.3. Google Earth Engine platformu ve JavaScript

Uydu görüntülerini işlemek için çeşitli yazılımlar geliştirilmiştir. ArcGIS, QGIS, SNAP, eCognition, GEE gibi açık kaynak kodlu yazılımlar bunlardan bazılarıdır (Yılmaz ve ark., 2021). Çalışma sürecinde GEE platformu tercih edilmiştir. GEE platformu büyük verileri işlemeye kolaylık sağlamaktadır (Yılmaz ve ark., 2021). GEE, Google tarafından geliştirilen ücretsiz, açık kaynak kodlu ve bulut tabanlı bir analiz platformudur (Gorelick ve ark., 2017). Uydu görüntülerinin analiz edilmesi, görselleştirilmesi ve işlenmesi amacıyla tasarlanmıştır (Bozduman, 2021)

GEE platformu, uydu verilerini hızlı bir şekilde işleyip kolayca analiz etmesinin yanı sıra, her kullanıcı için uydu görüntülerine erişimi kolaylaştıran algoritmalara sahiptir (Phan ve ark., 2020). Kullanıcılar, bünyesinde barındıran Sentinel, MODIS, Landsat gibi uydulara eş zamanlı olarak erişim sağlayabilmekte ve bu uydular ile çeşitli analizler yapabilmektedir (Xiong ve ark., 2017). Bu platform, orman uygulamaları (Ram ve ark., 2021), tarım uygulamaları (You ve ark., 2021), kentsel ve sulak alanların

haritalanması (Zafar ve ark., 2023), yer yüzeyi sıcaklığı (Yousif ve Shneen, 2015), görüntü sınıflandırma gibi birçok uygulamalarda sıkça kullanılmaktadır.

GEE, web tabanlı entegre geliştirme ortamı (IDE) sayesinde Python ve JavaScript kodlama dilleri ile komut dosyalarının yazılmasını ve geliştirilmesine yardımcı olmaktadır (Alkan, 2020; Dong ve ark., 2016). Çalışma sürecinde JavaScript kodlama dili kullanılmıştır. Şekil 3.5'te GEE platformunun arayüzü gösterilmiştir. Ayrıca bu platformda bulunan RO, DVM, Naive Bayess, CART, KNN gibi çeşitli makine öğrenmesi algoritmaların kodları yazılarak, sınıflandırma gibi işlemler yapılabilmektedir. Bu algoritmalar ile büyük veri kümeleri üzerinde kolay ve hızlı bir şekilde çalışmalar yürütülmektedir. Bu yönleri ile GEE, uydu verileri ve makine öğrenmesi tabanlı AK/AÖ sınıflandırma çalışmalarında da çok sık tercih edilir olmuştur.




Şekil 3.5: GEE platformu ara yüzü

JavaScript, interaktif web sayfaları geliştirmek için tasarlanan güçlü bir programlama dilidir (Flanagan, 2020). Web geliştiriciler tarafından yaygın olarak kullanılan JavaScript, GEE platformunda uydu verilerinin analizini, işlenmesini ve sınıflandırma işlemlerini gerçekleştirmek için kullanılmaktadır. GEE'de yer alan kod editörü çevrimiçi olup, JavaScript dili ile büyük ölçekli uydu görüntüleri üzerinde hızlı analizler yapılmaktadır (Gorelick ve ark., 2017). JavaScript programlama dili ile kullanıcılar, GEE platformu üzerinde yer alan makine öğrenmesi algoritmalarını

kullanarak; sınıflandırma işlemi, ön işleme, spektral indeks oluşturma gibi işlemleri kolay bir şekilde yapmaktadır.

3.2.4. ArcGIS yazılımı


ArcGIS, ESRI (Environmental Systems Research Institute) tarafından geliştirilen bir CBS (coğrafi bilgi sistemleri) yazılımıdır. Bu yazılım, coğrafi bilgilerin toplanması, görselleştirilmesi, analiz edilmesi için kullanılmaktadır. Ayrıca elde edilen coğrafi veriler görselleştirilerek etkili haritalar oluşturulabilir (ESRI, 2024). Şekil 3.6’da sınıflandırma sonucu elde edilen sonuç görüntülerinin, ArcGIS yazılımı ile görselleştirilmesi gösterilmiştir.



Şekil 3.6: Sonuç görüntülerinin ArcGIS yazılımı ile görselleştirilmesi.

4. BULGULAR VE TARTIŞMA

Yapılan tez çalışması çerçevesinde ilk önce sınıflandırma işleminin yapılacağı çalışma alanı belirlenmiştir (Şekil 3.4). Ardından çalışmada kullanılan Sentinel-2A uydu görüntüsüne ait 07.04.2018, 01.05.2021 ve 05.04.2024 tarihli veriler toplanmıştır. Uydu görüntüleri <https://dataspace.copernicus.eu/> adlı web sitesinden temin edilmiştir. Bu web sitesi, AB'nin Copernicus programı kapsamında sunulan, uydu verilerine ücretsiz erişim sağlayan bir platformdur. Daha sonra temin edilen uydu verilerine bulut maskeleme, görüntü aktarma ve görüntü kırpma gibi ön işleme adımları uygulanmıştır. Ardından toplam 1209 adet piksel tanımlanmıştır. Bu pikseller, algoritmaların performanslarını karşılaştırmak amacıyla ilk önce; %70 eğitim - %30 test verisi olarak, daha sonra %80 eğitim - %20 test verisi olarak ayrılmıştır. Bu adımdan sonra sınıflandırma işlemi için algoritmalar seçilmiştir. Eğitim verileri, tutarlılığı sağlamak ve karşılaştırmaları güvenilir bir şekilde yapmak için aynı veriler kullanılmıştır. Ardından sınıflandırma sonucu oluşan sonuç görselleri haritalandırılmış ve elde edilen hata matrisi ile birlikte doğruluk analizleri yapılmıştır. Son olarak elde edilen sonuçlar karşılaştırılmıştır. Şekil 4.1'de çalışmanın iş akışını gösteren bir görsel bulunmaktadır.




Şekil 4.1: İş akış şeması

4.1. Makine öğrenmesi ile sınıflandırma çalışması

GEE platformu üzerinden sınıflandırma çalışması yapmadan önce ilk olarak, çalışma alanı belirlenir. Ardından 2018, 2021 ve 2024 yıllarına ait Sentinel-2A uydu görüntüleri çağırılır. Uydu görüntülerini çağırmak için “ee.Image()” adlı parametre kullanılır. Daha sonra “.clip()” fonksiyonu ile çalışmanın yapılacağı alan kırpılır. Ardından Şekil 3.5’te gösterilen “Geometri Araçları” menüsünden bir geometri aracı seçilir ve harita üzerinden işaretlemeler yapılarak, örnek veri seti oluşturulur. Oluşturulan toplam 1209 adet piksel, “FeatureCollection” olarak tanımlanır ve sınıf etiketleri atanır. “.sampleRegions()” fonksiyonu yardımıyla da örnek veriler uydu verisi ile eşleştirilerek, sınıflandırma için veri seti oluşturulur. Bu işlemlerin ardından sınıflandırma adımını geçilir.

4.1.1. Rastgele orman algoritması ile sınıflandırma

RO algoritması ile sınıflandırma işlemi yapmak için “.smileRandomForest()” fonksiyonu kullanılmıştır. Karar ağacı sayısı ile model eğitilerek en iyi sonucu veren ağaç sayısı belirlenir. Çalışmada karar ağacı sayısı, en iyi sonucu verdiği için 100 olarak belirlenmiştir. Daha sonra “.classify()” ile görüntü sınıflandırılmıştır. Son olarak ArcGIS yazılımı ile sonuç görüntüleri görselleştirilmiş ve haritalandırılmıştır. Bu süreçte 2018, 2021 ve 2024 yıllarına ait uydu verileri sırasıyla sınıflandırılmıştır. Şekil 4.2’de %70 eğitim verisi ve %30 test verisi ile elde edilen sonuç görüntüsü, Tablo 4.1’de ise hata matrisi ve doğruluk metrikleri bulunmaktadır. Şekil 4.3’te %80 eğitim verisi - %30 test verisi oranları sonucu elde edilen sonuç görüntüsü, Tablo 4.2’de ise hata matrisi ve doğruluk metrikleri gösterilmektedir.



Şekil 4.2: %70 eğitim verisi %30 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.1 incelendiğinde, 2018 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında toplam 71 adet pikselin 54 tanesinin doğru sınıflandırıldığı, 6 tanesinin yerleşim alanı sınıfı olarak ve 11 tanesinin ise tarım alanı sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında, 62 adet pikselin 48 tanesi doğru sınıflandırılırken, geriye kalan pikseller ise yol, boş alan, sanayi bölgesi ve tarım alanı sınıfları ile karışmıştır. Yol sınıfı için, 59 adet pikselden 44 tanesi doğru sınıflandırılırken, 3 tanesi tarım alanı, 1 tanesi sanayi bölgesi, 9 tanesi boş alan, 1 tanesi ise yeşil alan olarak yanlış sınıflandırılmıştır. Boş alan sınıfında, 576 adet pikselin 6 tanesi tarım alanı, 90 tanesi yerleşim alanı ve 20 tanesi yeşil alan sınıfları ile karışmıştır. Buna karşılık 460 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 232

tanesi doğru sınıflandırılırken, geriye kalan pikseller boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 2 tanesi yol sınıfı ile karışırken, geriye kalan pikseller doğru bir şekilde sınıflandırılmıştır.


Tablo 3.1: %70 eğitim verisi %30 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	54	6	0	0	11	0	71
	Yerleşim Alanı	0	48	1	9	3	1	62
	Yol	1	0	44	10	4	0	59
	Boş Alan	20	90	0	460	6	0	576
	Tarım Alanı	0	0	0	15	232	0	247
	Sanayi Bölgesi	0	0	2	0	0	192	194
	Toplam	75	144	47	494	256	193	1209
	Ü.D.	72.00	33.33	93.62	93.12	90.63	99.48	
	K.D.	76.06	77.42	74.58	79.86	93.93	98.97	
Genel Doğruluk: %85				Kappa Değeri: 0.80				
2021	Yeşil Alan	47	21	0	1	2	0	71
	Yerleşim Alanı	0	38	1	23	0	0	62
	Yol	1	3	47	8	0	0	59
	Boş Alan	0	103	0	466	7	0	576
	Tarım Alanı	26	0	0	3	218	0	247
	Sanayi Bölgesi	7	0	0	3	0	184	194
	Toplam	81	165	48	504	227	184	1209
	Ü.D.	58.02	23.03	97.92	92.46	96.04	100.00	
	K.D.	66.20	61.29	79.66	80.90	88.26	94.85	
Genel Doğruluk: %83				Kappa Değeri: 0.86				
2024	Yeşil Alan	63	6	0	2	0	0	71
	Yerleşim Alanı	1	46	0	14	1	0	62
	Yol	1	8	41	8	0	1	59
	Boş Alan	0	50	0	524	2	0	576
	Tarım Alanı	0	0	0	33	214	0	247
	Sanayi Bölgesi	0	1	0	0	1	192	194
	Toplam	65	111	41	581	218	193	1209
	Ü.D.	96.92	41.44	100.00	90.19	98.17	99.48	
	K.D.	88.73	74.19	69.49	90.97	86.64	98.97	
Genel Doğruluk: %89				Kappa Değeri: 0.85				
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.1’de yer alan 2021 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında toplam 71 adet pikselin 47 tanesinin doğru sınıflandırıldığı, 21 tanesinin yerleşim alanı sınıfı olarak, 1 tanesinin boş alan sınıfı ve 2 tanesinin ise tarım alanı sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında, 62 adet pikselin 38 tanesi doğru sınıflandırılırken, geriye kalan pikseller ise yol ve boş alan sınıfları ile karışmıştır. Yol sınıfı için 59 adet pikselden 47 tanesi doğru sınıflandırılırken, 3 tanesi yerleşim alanı, 8 tanesi boş alan, 3 tanesi ise yeşil alan olarak yanlış sınıflandırılmıştır. Boş

alan sınıfında, 576 adet pikselin 7 tanesi tarım alanı, 103 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 466 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 218 tanesi doğru sınıflandırılırken, geriye kalan pikseller boş alan ve yeşil alan sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 3 tanesi boş alan ve 7 tanesi yeşil alan sınıfları ile karışırken, geriye kalan pikseller doğru bir şekilde sınıflandırılmıştır.

2024 yılına ait hata matrisi sonuçlarına göre; 71 adet pikselin 63 tanesinin doğru sınıflandırıldığı, 2 tanesinin boş alan sınıfı, 6 tanesinin yerleşim alanı sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 46 tanesi doğru sınıflandırılırken, geriye kalan piksellerin yeşil alan, boş alan ve tarım alanı sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 41 tanesi doğru sınıflandırılırken, geriye kalan pikseller tarım alanı sınıfı hariç diğer sınıflarla karışmıştır. Boş alan sınıfında 576 adet pikselin 2 tanesi tarım alanı, 50 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 524 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 214 tanesi doğru sınıflandırılırken, geriye kalan pikseller boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 192 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir.



Şekil 4.3: %80 eğitim verisi %20 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.2 incelendiğinde, 2018 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında toplam 71 adet pikselin 60 tanesinin doğru sınıflandırıldığı, geriye kalan piksellerin yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında, 62 adet pikselin 51 tanesi doğru sınıflandırılırken, geriye kalan pikseller ise yol, boş alan, yeşil alan ve tarım alanı sınıfları ile karışmıştır. Yol sınıfı için, 59 adet pikselden 46 tanesi doğru sınıflandırılırken, 8 tanesi boş alan, 1 tanesi ise yeşil alan, 4 tanesi ise yerleşim alanı olarak yanlış sınıflandırılmıştır. Boş alan sınıfında, 576 adet pikselin 4 tanesi tarım alanı, 131 tanesi yerleşim alanı ve 10 tanesi yeşil alan sınıfları ile karışmıştır. Buna karşılık 431 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 233 tanesi doğru sınıflandırılırken, geriye kalan pikseller boş alan ve yerleşim

alanı sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 188 tanesi doğru sınıflandırılmış, geriye kalan pikseller yanlış sınıflandırılmıştır.

Tablo 4.2: %80 eğitim verisi %20 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	60	6	2	0	3	0	71
	Yerleşim Alanı	1	51	1	7	2	0	62
	Yol	1	4	46	8	0	0	59
	Boş Alan	10	131	0	431	4	0	576
	Tarım Alanı	0	9	0	5	233	0	247
	Sanayi Bölgesi	0	1	4	0	1	188	194
	Toplam	72	202	53	451	243	188	1209
	Ü.D.	83.33	25.25	86.79	95.57	95.88	100.00	
	K.D.	84.51	82.26	77.97	74.83	94.33	96.91	
Genel Doğruluk: %83				Kappa Değeri: 0.78				
2021	Yeşil Alan	45	13	0	0	13	0	71
	Yerleşim Alanı	0	43	1	18	0	0	62
	Yol	0	1	53	4	0	1	59
	Boş Alan	0	153	0	417	6	0	576
	Tarım Alanı	0	0	0	1	246	0	247
	Sanayi Bölgesi	0	0	0	0	0	194	194
	Toplam	45	210	54	440	265	195	1209
	Ü.D.	100.00	20.48	98.15	94.77	92.83	99.49	
	K.D.	63.38	69.35	89.83	72.40	99.60	100.00	
Genel Doğruluk: %83				Kappa Değeri: 0.77				
2024	Yeşil Alan	68	3	0	0	0	0	71
	Yerleşim Alanı	2	42	2	14	2	0	62
	Yol	0	1	50	7	0	1	59
	Boş Alan	0	55	0	520	1	0	576
	Tarım Alanı	0	3	0	34	210	0	247
	Sanayi Bölgesi	0	1	0	0	1	192	194
	Toplam	70	105	52	575	214	193	1209
	Ü.D.	97.14	40.00	96.15	90.43	98.13	99.48	
	K.D.	95.77	67.74	84.75	90.28	85.02	98.97	
Genel Doğruluk: %89				Kappa Değeri: 0.85				
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								


Tablo 4.2’de bulunan 2021 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında toplam 71 adet pikselin 45 tanesinin doğru sınıflandırıldığı, 13 tanesinin yerleşim alanı sınıfı olarak ve 13 tanesinin ise tarım alanı sınıfı olarak yanlış sınıflandırıldığı

görülmektedir. Yerleşim alanı sınıfına bakıldığında, 62 adet pikselin 43 tanesi doğru sınıflandırılırken, geriye kalan pikseller ise yol ve boş alan sınıfları ile karışmıştır. Yol sınıfı için 59 adet pikselden 53 tanesi doğru sınıflandırılırken, 1 tanesi yerleşim alanı, 4 tanesi boş alan, 1 tanesi ise sanayi bölgesi olarak yanlış sınıflandırılmıştır. Boş alan sınıfında, 576 adet pikselin 6 tanesi tarım alanı, 153 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 417 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 246 tanesi doğru sınıflandırılırken, geriye kalan pikseller boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin tamamı doğru bir şekilde sınıflandırılmıştır.

2024 yılına ait hata matrisi sonuçlarına göre; 71 adet pikselin 68 tanesinin doğru sınıflandırıldığı, 3 tanesinin yerleşim alanı sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 42 tanesi doğru sınıflandırılırken, geriye kalan piksellerin yeşil alan, boş alan, yol ve tarım alanı sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 50 tanesi doğru sınıflandırılırken, geriye kalan pikseller yerleşim alanı, boş alan ve sanayi bölgesi sınıflarıyla karışmıştır. Boş alan sınıfında 576 adet pikselin 1 tanesi tarım alanı, 55 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 520 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 210 tanesi doğru sınıflandırılırken, geriye kalan pikseller boş alan ve yerleşim alanı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 192 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller yanlış sınıflandırılmıştır.

4.1.2. Naive Bayes algoritması ile sınıflandırma

Naive Bayes algoritması ile sınıflandırma işlemi yapmak için “.smileNaiveBayes()” fonksiyonu kullanılmıştır. Bu algorithmada parametreye ihtiyaç olmadığı için bir parametre belirlenmemiştir. Daha sonra “.classify()” ile görüntü sınıflandırma adımına geçilmiştir. Son olarak ArcGIS yazılımı ile sonuç görüntüleri görselleştirilmiş ve haritalandırılmıştır. Bu süreçte 2018, 2021 ve 2024 yıllarına ait uydu verileri sırasıyla sınıflandırılmıştır. Şekil 4.4’te %70 eğitim verisi ve %30 test verisi ile elde edilen sonuç görüntüsü, Tablo 4.3’te ise hata matrisi ve doğruluk metrikleri bulunmaktadır. Şekil 4.5’te %80 eğitim verisi - %30 test verisi oranları sonucu elde edilen sonuç görüntüsü, Tablo 4.4’te ise hata matrisi ve doğruluk metrikleri gösterilmektedir.



Şekil 4.4: %70 eğitim verisi %30 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.3'te yer alan 2018 yılına ait hata matrisi sonucu incelendiğinde; yeşil alan sınıfında 71 adet pikselin 65 tanesinin doğru sınıflandırıldığı, 5 tanesinin tarım alanı sınıfı ve 1 tanesinin de boş alan sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 50 tanesi doğru sınıflandırılırken, 5 pikselin yol sınıfı olarak, 7 pikselin boş alan sınıfı olarak yanlış sınıflandırıldığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 47 tanesi doğru sınıflandırılırken, geriye kalan pikseller; sanayi bölgesi, tarım alanı, boş alan, yol, yerleşim alanı sınıfları ile karışmıştır. Boş alan sınıfında 576 adet pikselin 23 tanesi tarım alanı, 63 tanesi yerleşim alanı ve 2 tanesi yeşil alan sınıfları ile karışmıştır. Buna karşılık 488 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 39 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer tüm sınıflar ile karışmıştır Sanayi

bölgesi sınıfında ise elde edilen 194 adet pikselin 192 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller yol sınıfı ile karışmıştır.


Tablo 4.3: %70 eğitim verisi %30 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	65	0	0	1	5	0	71
	Yerleşim Alanı	0	50	5	7	0	0	62
	Yol	0	1	47	7	2	2	59
	Boş Alan	2	63	0	488	23	0	576
	Tarım Alanı	49	69	37	53	39	0	247
	Sanayi Bölgesi	0	0	2	0	0	192	194
	Toplam	116	183	91	556	69	194	1209
	Ü.D.	56.03	27.32	51.65	87.77	56.52	98.97	
	K.D.	91.55	80.65	79.66	84.72	15.79	98.97	
Genel Doğruluk: %73 Kappa Değeri: 0.63								
2021	Yeşil Alan	52	0	2	4	13	0	71
	Yerleşim Alanı	0	40	8	9	5	0	62
	Yol	1	0	49	8	1	0	59
	Boş Alan	0	3	0	571	2	0	576
	Tarım Alanı	150	53	32	1	11	0	247
	Sanayi Bölgesi	2	0	15	0	0	177	194
	Toplam	205	96	106	593	32	177	1209
	Ü.D.	25.37	41.67	46.23	96.29	34.38	100.00	
	K.D.	73.24	64.52	83.05	99.13	4.45	91.24	
Genel Doğruluk: %74 Kappa Değeri: 0.64								
2024	Yeşil Alan	59	0	0	9	3	0	71
	Yerleşim Alanı	0	34	1	9	18	0	62
	Yol	0	0	42	1	12	4	59
	Boş Alan	0	13	0	534	29	0	576
	Tarım Alanı	5	50	85	36	71	0	247
	Sanayi Bölgesi	10	3	34	3	0	144	194
	Toplam	74	100	162	592	133	148	1209
	Ü.D.	79.73	34.00	25.93	90.20	53.38	97.30	
	K.D.	83.10	54.84	71.19	92.71	28.74	74.23	
Genel Doğruluk: %73 Kappa Değeri: 0.62								
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.3'teki 2021 yılına ait hata matrisi sonucuna göre; yeşil alan sınıfında 71 adet pikselin 52 tanesinin doğru sınıflandırıldığı, 13 tanesinin tarım alanı, 2 tanesinin

yol ve 4 tanesinin de boş alan sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 40 tanesi doğru sınıflandırılırken, 8 pikselin yol sınıfı olarak, 9 pikselin boş alan ve 5 adet pikselin tarım alanı sınıfı olarak yanlış sınıflandırıldığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 49 tanesi doğru sınıflandırılırken, geriye kalan pikseller; tarım alanı, boş alan, yeşil alanı sınıfları ile karışmıştır. Boş alan sınıfında 576 adet pikselin 2 tanesi tarım alanı, 3 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 571 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 11 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer tüm sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 177 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller yol sınıfı ile karışmıştır.

2024 yılına ait hata matrisi sonuçları incelendiğinde ise; yeşil alan sınıfında 71 adet pikselin 59 tanesinin doğru sınıflandırıldığı, 3 tanesinin tarım alanı ve 9 tanesinin de boş alan sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 34 tanesi doğru sınıflandırılırken, 1 pikselin yol sınıfı olarak, 9 pikselin boş alan ve 18 adet pikselin tarım alanı sınıfı olarak yanlış sınıflandırıldığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 42 tanesi doğru sınıflandırılırken, geriye kalan pikseller; tarım alanı, boş alan ve sanayi bölgesi sınıfları ile karışmıştır. Boş alan sınıfında 576 adet pikselin 29 tanesi tarım alanı, 13 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 534 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 71 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer tüm sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 144 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller geriye kalan pikseller, tarım alanı sınıfı hariç diğer tüm sınıflar ile karışmıştır.



Şekil 4.5: %80 eğitim verisi %20 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.4'te yer alan, 2018 yılına ait hata matrisi sonucuna göre; yeşil alan sınıfında 71 adet pikselin 62 tanesinin doğru sınıflandırıldığı, kalan piksellerin ise yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 41 tanesi doğru sınıflandırılırken, 3 pikselin yol sınıfı olarak, 17 pikselin boş alan sınıfı olarak, 1 tanesi ise tarım alanı olarak yanlış sınıflandırıldığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 42 tanesi doğru sınıflandırılırken, geriye kalan pikseller; sanayi bölgesi, tarım alanı, boş alan, yol, yerleşim alanı sınıfları ile karışmıştır. Boş alan sınıfında 576 adet pikselin 25 tanesi tarım alanı, 41 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 510 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 27 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer tüm sınıflar ile karışmıştır Sanayi bölgesi sınıfında ise elde edilen 194 adet

pikselin 191 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller yol sınıfı ile karışmıştır.

Tablo 4.4: %80 eğitim verisi %20 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	62	0	0	1	8	0	71
	Yerleşim Alanı	0	41	3	17	1	0	62
	Yol	0	2	42	8	5	2	59
	Boş Alan	0	41	0	510	25	0	576
	Tarım Alanı	67	90	22	41	27	0	247
	Sanayi Bölgesi	0	0	3	0	0	191	194
	Toplam	129	174	70	577	66	193	1209
	Ü.D.	48.06	23.56	60.00	88.39	40.91	98.96	
	K.D.	87.32	66.13	71.19	88.54	10.93	98.45	
	Genel Doğruluk: %72				Kappa Değeri: 0.61			
2021	Yeşil Alan	64	0	0	3	4	0	71
	Yerleşim Alanı	0	44	5	7	6	0	62
	Yol	0	0	51	7	1	0	59
	Boş Alan	0	1	0	572	3	0	576
	Tarım Alanı	141	68	35	1	2	0	247
	Sanayi Bölgesi	4	0	7	0	0	183	194
	Toplam	209	113	98	590	16	183	1209
	Ü.D.	30.62	38.94	52.04	96.95	12.50	100.00	
	K.D.	90.14	70.97	86.44	99.31	0.81	94.33	
	Genel Doğruluk: %76				Kappa Değeri: 0.66			
2024	Yeşil Alan	66	0	0	5	0	0	71
	Yerleşim Alanı	0	37	1	7	17	0	62
	Yol	0	0	50	1	6	2	59
	Boş Alan	0	17	0	532	27	0	576
	Tarım Alanı	0	85	66	35	61	0	247
	Sanayi Bölgesi	4	0	0	39	4	147	194
	Toplam	70	139	117	619	115	149	1209
	Ü.D.	94.29	26.62	42.74	85.95	53.04	98.66	
	K.D.	92.96	59.68	84.75	92.36	24.70	75.77	
	Genel Doğruluk: %74				Kappa Değeri: 0.63			
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.4'teki 2021 yılına ait hata matrisi sonucuna göre; yeşil alan sınıfında 71 adet pikselin 64 tanesinin doğru sınıflandırıldığı, 4 tanesinin tarım alanı ve 3 tanesinin


de boş alan sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 44 tanesi doğru sınıflandırılırken, 5 pikselin yol sınıfı olarak, 7 pikselin boş alan ve 6 adet pikselin tarım alanı sınıfı olarak yanlış sınıflandırıldığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 51 tanesi doğru sınıflandırılırken, geriye kalan pikseller; boş alan ve tarım alanı ile karışmıştır. Boş alan sınıfında 576 adet pikselin 3 tanesi tarım alanı, 1 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 572 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 2 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer tüm sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 183 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller yol ve yerleşim alanı sınıfları ile karışmıştır.

2024 yılına ait hata matrisi sonuçları incelendiğinde ise; yeşil alan sınıfında 71 adet pikselin 66 tanesinin doğru sınıflandırıldığı 5 tanesinin de boş alan sınıfı olarak yanlış sınıflandırıldığı görülmektedir. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 37 tanesi doğru sınıflandırılırken, 1 pikselin yol sınıfı olarak, 7 pikselin boş alan ve 17 adet pikselin tarım alanı sınıfı olarak yanlış sınıflandırıldığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 50 tanesi doğru sınıflandırılırken, geriye kalan pikseller; tarım alanı, boş alan ve sanayi bölgesi sınıfları ile karışmıştır. Boş alan sınıfında 576 adet pikselin 27 tanesi tarım alanı, 17 tanesi yerleşim alanı sınıfları ile karışmıştır. Buna karşılık 532 piksel doğru sınıflandırılmıştır. 247 adet tarım alanı pikselinin 61 tanesi doğru sınıflandırılırken, geriye kalan pikseller yeşil alan ve sanayi bölgesi sınıfları hariç diğer tüm sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 147 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller geriye kalan pikseller ise yanlış sınıflandırılmıştır.

4.1.3. K-En yakın komşu algoritması ile sınıflandırma

KNN algoritması ile sınıflandırma işlemi yapmak için “smileKNN()” fonksiyonu kullanılmıştır. Çalışmada en iyi sonucu verdikleri için; k parametresi yani komşu sayısı 1 olarak, kullanılacak metrik mesafesi ise Öklid mesafesi olarak seçilmiştir. Daha sonra “classify()” ile görüntü sınıflandırılmıştır. Son olarak ArcGIS yazılımı ile sonuç görüntüleri görselleştirilmiş ve haritalandırılmıştır. Bu süreçte 2018, 2021 ve 2024 yıllarına ait uydu verileri sırasıyla sınıflandırılmıştır. Şekil 4.6’da %70 eğitim verisi ve %30 test verisi ile elde edilen sonuç görüntüsü, Tablo 4.5’te ise hata matrisi ve doğruluk metrikleri bulunmaktadır. Şekil 4.7’de %80 eğitim verisi - %30 test verisi oranları sonucu elde

edilen sonuç görüntüsü, Tablo 4.6’da ise hata matrisi ve doğruluk metrikleri gösterilmektedir.




Şekil 4.6: %70 eğitim verisi %30 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.5 incelendiğinde 2018 yılı sonuçlarına göre; yeşil alan sınıfında 71 adet pikselin 56 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak 3 piksel tarım alanı, 10 pikselin yerleşim alanı ve 2 piksel boş alan sınıfı olarak yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 51 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, sanayi bölgesi ve yeşil alan sınıfları hariç diğer tüm sınıflar ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 40 tanesi doğru sınıflandırılırken, geriye kalan 1 piksel yerleşim alanı, 6 piksel boş alan ve 3 piksel ise tarım alanı sınıfı ile karışmıştır. Boş alan sınıfında 576 adet pikselin 465 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış

Tablo 4.5'teki verilere göre 2021 yılının sonuçları incelendiğinde; yeşil alan sınıfında 71 adet pikselin 56 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak 14 pikselin yerleşim alanı ve 1 piksel boş alan sınıfı olarak yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 42 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, sanayi bölgesi ve yeşil alan sınıfları hariç diğer tüm sınıflar ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 47 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 504 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 219 tanesi doğru sınıflandırılırken, geriye kalan pikseller, yeşil alan ve yerleşim alan sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 190 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 4 adet piksel yanlış sınıflandırılmıştır.

2024 yılına ait hata matrisi sonuçları incelendiğinde yeşil alan sınıfında 71 adet pikselin 61 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 44 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, sanayi bölgesi ve yeşil alan sınıfları hariç diğer tüm sınıflar ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 44 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 525 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 230 tanesi doğru sınıflandırılırken, geriye kalan pikseller, yerleşim alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 191 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 3 adet piksel yanlış sınıflandırılmıştır.



Şekil 4.7: %80 eğitim verisi %20 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.6’da yer alan 2018 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında 71 adet pikselin 61 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak 9 pikselin yerleşim alanı ve 1 piksel yol sınıfı olarak yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 50 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, boş alan ve tarım alanı sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 44 tanesi doğru sınıflandırılırken, geriye kalan 2 piksel yeşil alanı, 6 piksel yerleşim alanı ve 7 piksel ise boş alan sınıfı ile karışmıştır. Boş alan sınıfında 576 adet pikselin 437 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 223 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan ve yerleşim alanı sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 187

tanisi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 7 adet piksel yanlış sınıflandırılmıştır.

Tablo 4.6: %80 eğitim verisi %20 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	61	9	1	0	0	0	71
	Yerleşim Alanı	0	50	0	5	7	0	62
	Yol	2	6	44	7	0	0	59
	Boş Alan	0	129	0	437	10	0	576
	Tarım Alanı	0	5	0	19	223	0	247
	Sanayi Bölgesi	0	3	4	0	0	187	194
	Toplam	63	202	49	468	240	187	1209
	Ü.D.	96.83	24.75	89.80	93.38	92.92	100.00	
	K.D.	85.92	80.65	74.58	75.87	90.28	96.39	
Genel Doğruluk: %83				Kappa Değeri: 0.77				
2021	Yeşil Alan	49	6	0	0	16	0	71
	Yerleşim Alanı	0	45	1	13	3	0	62
	Yol	0	5	45	8	0	1	59
	Boş Alan	0	99	0	462	15	0	576
	Tarım Alanı	12	1	0	0	234	0	247
	Sanayi Bölgesi	1	0	0	0	0	193	194
	Toplam	62	156	46	483	268	194	1209
	Ü.D.	79.03	28.85	97.83	95.65	87.31	99.48	
	K.D.	69.01	72.58	76.27	80.21	94.74	99.48	
Genel Doğruluk: %85				Kappa Değeri: 0.79				
2024	Yeşil Alan	68	3	0	0	0	0	71
	Yerleşim Alanı	1	46	0	12	3	0	62
	Yol	0	0	51	7	0	1	59
	Boş Alan	0	44	0	530	2	0	576
	Tarım Alanı	0	11	0	1	235	0	247
	Sanayi Bölgesi	0	0	0	0	2	192	194
	Toplam	69	104	51	550	242	193	1209
	Ü.D.	98.55	44.23	100.00	96.36	97.11	99.48	
	K.D.	95.77	74.19	86.44	92.01	95.14	98.97	
Genel Doğruluk: %93				Kappa Değeri: 0.90				
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.6'daki 2021 yılına ait sonuçlar incelendiğinde; yeşil alan sınıfında 71 adet pikselin 49 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak 16 pikselin tarım


alanı ve 6 piksel yerleşim alanı sınıfı olarak yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 45 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, sanayi bölgesi ve yeşil alan sınıfları hariç diğer tüm sınıflar ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 45 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 462 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 234 tanesi doğru sınıflandırılırken, geriye kalan pikseller, yeşil alan ve yerleşim alan sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 193 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 1 adet piksel yanlış sınıflandırılmıştır.

2024 yılı sonuçlarına bakıldığında ise; yeşil alan sınıfında 71 adet pikselin 68 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 46 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, boş alan, tarım alanı ve yeşil alan sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 51 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 530 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 235 tanesi doğru sınıflandırılırken, geriye kalan pikseller, yerleşim alan ve boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 192 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 2 adet piksel yanlış sınıflandırılmıştır.

4.1.4. Destek vektör makineleri algoritması ile sınıflandırma

DVM algoritması ile sınıflandırma işlemi yapmak için “.libsvm()” fonksiyonu kullanılmıştır. Polinom çekirdek (kernel) fonksiyonu için derece değeri 1 ve gamma değeri 0.3 olarak belirlenmiştir. Çünkü en iyi sonucu bu iki parametre değerleri vermiştir. Lineer çekirdek (kernel) fonksiyonu bir parametre içermediği için herhangi bir parametre seçimi yapılmamıştır. Daha sonra “.classify()” ile görüntüler sınıflandırılmıştır. Son olarak ArcGIS yazılımı ile sonuç görüntüleri görselleştirilmiş ve haritalandırılmıştır. Bu süreçte 2018, 2021 ve 2024 yıllarına ait uydu verileri sırasıyla sınıflandırılmıştır. Şekil 4.8’de polinom çekirdek fonksiyonuna ait; %70 eğitim verisi ve %30 test verisi ile elde edilen sonuç görüntüsü, Tablo 4.7’de ise hata matrisi ve doğruluk metrikleri bulunmaktadır. Şekil 4.9’da %80 eğitim verisi - %30 test verisi oranları sonucu elde edilen sonuç görüntüsü, Tablo 4.8’de ise hata matrisi ve doğruluk

metrikleri gösterilmektedir. Şekil 4.10'da lineer çekirdek fonksiyonuna ait; %70 eğitim verisi ve %30 test verisi ile elde edilen sonuç görüntüsü, Tablo 4.9'da ise hata matrisi ve doğruluk metrikleri bulunmaktadır. Şekil 4.11'de %80 eğitim verisi - %30 test verisi oranları sonucu elde edilen sonuç görüntüsü, Tablo 4.10'da ise hata matrisi ve doğruluk metrikleri gösterilmektedir.



Şekil 4.8: Polinom Kernel fonksiyonuna ait %70 eğitim verisi %30 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.7'de de gösterildiği gibi 2018 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında 71 adet pikselin 50 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 51 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, sanayi bölgesi ve yeşil alan sınıfları hariç diğer tüm sınıflar ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 47 tanesi doğru sınıflandırılırken, geriye kalan pikseller

yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 559 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 164 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 180 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 14 adet piksel yol sınıfı olarak yanlış sınıflandırılmıştır.


Tablo 4.7: Polinom Kernel fonksiyonuna ait %70 eğitim verisi %30 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	50	1	0	13	7	0	71
	Yerleşim Alanı	0	51	4	4	3	0	62
	Yol	6	0	47	2	0	4	59
	Boş Alan	0	0	0	559	17	0	576
	Tarım Alanı	11	21	10	41	164	0	247
	Sanayi Bölgesi	0	0	14	0	0	180	194
	Toplam	67	73	75	619	191	184	1209
	Ü.D.	74.63	69.86	62.67	90.31	85.86	97.83	
	K.D.	70.42	82.26	79.66	97.05	66.40	92.78	
Genel Doğruluk: %87					Kappa Değeri: 0.81			
2021	Yeşil Alan	49	1	0	18	3	0	71
	Yerleşim Alanı	1	47	0	14	0	0	62
	Yol	5	2	44	8	0	0	59
	Boş Alan	0	0	0	574	2	0	576
	Tarım Alanı	30	0	0	29	188	0	247
	Sanayi Bölgesi	12	0	0	0	2	180	194
	Toplam	97	50	44	643	195	180	1209
	Ü.D.	50.52	94.00	100.00	89.27	96.41	100.00	
	K.D.	69.01	75.81	74.58	99.65	76.11	92.78	
Genel Doğruluk: %89					Kappa Değeri: 0.85			
2024	Yeşil Alan	64	0	0	0	5	2	71
	Yerleşim Alanı	0	58	0	3	1	0	62
	Yol	1	0	53	5	0	0	59
	Boş Alan	0	1	0	573	2	0	576
	Tarım Alanı	0	0	0	47	200	0	247
	Sanayi Bölgesi	0	0	3	11	1	179	194
	Toplam	65	59	56	639	209	181	1209
	Ü.D.	98.46	98.31	94.64	89.67	95.69	98.90	
	K.D.	90.14	93.55	89.83	99.48	80.97	92.27	
Genel Doğruluk: %93					Kappa Değeri: 0.90			

*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu

Tablo 4.7'deki 2021 yılına ait hata matrisine göre ise, yeşil alan sınıfında 71 adet pikselin 49 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 47 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, yerleşim alanı, boş alan ve yeşil alan sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 44 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 574 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 188 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan ve yeşil alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 180 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 14 adet piksel yol sınıfı olarak yanlış sınıflandırılmıştır.

2024 yılı sonuçlarına göre, yeşil alan sınıfında 71 adet pikselin 64 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 58 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan ve tarım alanı sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 53 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 573 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 200 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 179 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 15 adet piksel yanlış sınıflandırılmıştır.



Şekil 4.9: Polinom Kernel fonksiyonuna ait %80 eğitim verisi %20 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.8’de gösterildiği gibi 2018 yılına ait hata matrisi sonuçlarına göre; yeşil alan sınıfında 71 adet pikselin 48 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 55 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, tarım alanı ve boş alan sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 43 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 542 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 211 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi ve yol sınıfları hariç diğer sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet

pikselin 180 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 14 adet piksel yol sınıfı olarak yanlış sınıflandırılmıştır.


Tablo 4.8: Polinom Kernel fonksiyonuna ait %80 eğitim verisi %20 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	48	0	0	14	9	0	71
	Yerleşim Alanı	0	55	0	6	1	0	62
	Yol	7	3	43	2	0	4	59
	Boş Alan	0	0	0	542	34	0	576
	Tarım Alanı	1	26	0	9	211	0	247
	Sanayi Bölgesi	0	0	14	0	0	180	194
	Toplam	56	84	57	573	255	184	1209
	Ü.D.	85.71	65.48	75.44	94.59	82.75	97.83	
	K.D.	67.61	88.71	72.88	94.10	85.43	92.78	
	Genel Doğruluk: %89				Kappa Değeri: 0.85			
2021	Yeşil Alan	52	1	0	5	13	0	71
	Yerleşim Alanı	0	53	0	9	0	0	62
	Yol	4	0	55	0	0	0	59
	Boş Alan	0	0	0	575	1	0	576
	Tarım Alanı	11	40	0	34	162	0	247
	Sanayi Bölgesi	5	0	0	0	3	186	194
	Toplam	72	94	55	623	179	186	1209
	Ü.D.	72.22	56.38	100.00	92.30	90.50	100.00	
	K.D.	73.24	85.48	93.22	99.83	65.59	95.88	
	Genel Doğruluk: %90				Kappa Değeri: 0.85			
2024	Yeşil Alan	68	0	0	3	0	0	71
	Yerleşim Alanı	0	58	0	4	0	0	62
	Yol	0	0	58	1	0	0	59
	Boş Alan	0	0	0	573	3	0	576
	Tarım Alanı	0	0	0	40	207	0	247
	Sanayi Bölgesi	0	0	1	0	1	192	194
	Toplam	68	58	59	621	211	192	1209
	Ü.D.	100.00	100.00	98.31	92.27	98.10	100.00	
	K.D.	95.77	93.55	98.31	99.48	83.81	98.97	
	Genel Doğruluk: %96				Kappa Değeri: 0.94			
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.8’de yer alan 2021 yılına ait hata matrisine göre ise, yeşil alan sınıfında 71 adet pikselin 52 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan

pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 53 tanesi doğru sınıflandırılırken, geriye kalan piksellerin, boş alan sınıfı ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 55 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 575 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 162 tanesi doğru sınıflandırılırken, geriye kalan pikseller, yerleşim alanı, boş alan ve yeşil alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 186 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan pikseller yanlış sınıflandırılmıştır.

2024 yılı sonuçlarına göre, yeşil alan sınıfında 71 adet pikselin 68 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 58 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan sınıfı ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 58 tanesi doğru sınıflandırılırken, geriye kalan piksel yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 573 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 207 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 192 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 2 adet piksel yanlış sınıflandırılmıştır.



Şekil 4.10: Lineer Kernel fonksiyonuna ait %70 eğitim verisi %30 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.9’da yer alan 2018 yılı hata matrisi sonuçlarına göre; yeşil alan sınıfında 71 adet pikselin 49 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 56 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan ve yol sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 44 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 565 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 159 tanesi doğru sınıflandırılırken, geriye kalan pikseller, sanayi bölgesi sınıfı hariç diğer sınıflar ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 180 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 14 adet piksel yanlış sınıflandırılmıştır.


Tablo 4.9: Lineer Kernel fonksiyonuna ait %70 eğitim verisi %30 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	49	1	0	13	8	0	71
	Yerleşim Alanı	0	56	3	3	0	0	62
	Yol	9	1	44	1	0	4	59
	Boş Alan	0	0	0	565	11	0	576
	Tarım Alanı	11	25	15	37	159	0	247
	Sanayi Bölgesi	0	0	14	0	0	180	194
	Toplam	69	83	76	619	178	184	1209
	Ü.D.	71.01	67.47	57.89	91.28	89.33	97.83	
	K.D.	69.01	90.32	74.58	98.09	64.37	92.78	
Genel Doğruluk: %87				Kappa Değeri: 0.81				
2021	Yeşil Alan	50	1	0	18	2	0	71
	Yerleşim Alanı	0	43	0	19	0	0	62
	Yol	5	3	44	5	0	2	59
	Boş Alan	0	0	0	574	2	0	576
	Tarım Alanı	46	12	0	21	168	0	247
	Sanayi Bölgesi	1	0	1	0	2	190	194
	Toplam	102	59	45	637	174	192	1209
	Ü.D.	49.02	72.88	97.78	90.11	96.55	98.96	
	K.D.	70.42	69.35	74.58	99.65	68.02	97.94	
Genel Doğruluk: %88				Kappa Değeri: 0.83				
2024	Yeşil Alan	63	1	0	5	2	0	71
	Yerleşim Alanı	0	57	0	4	1	0	62
	Yol	1	2	49	7	0	0	59
	Boş Alan	0	0	0	573	3	0	576
	Tarım Alanı	0	0	0	51	196	0	247
	Sanayi Bölgesi	0	0	4	0	1	189	194
	Toplam	64	60	53	640	203	189	1209
	Ü.D.	98.44	95.00	92.45	89.53	96.55	100.00	
	K.D.	88.73	91.94	83.05	99.48	79.35	97.42	
Genel Doğruluk: %93				Kappa Değeri: 0.90				
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.9’da yer alan 2021 yılında ise, yeşil alan sınıfında 71 adet pikselin 50 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 43 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan sınıfı ile karıştığı tespit edilmiştir. Yol

sınıfı için 59 adet pikselden 44 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 574 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 168 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan, yeşil alan ve yerleşim alanı sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 190 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 4 adet piksel yanlış sınıflandırılmıştır.

2024 yılına ait hata matrisi incelendiğinde; yeşil alan sınıfında 71 adet pikselin 63 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 57 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan, tarım alanı ve yeşil alan sınıfları ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 49 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 573 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 196 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 189 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 5 adet piksel yanlış sınıflandırılmıştır.



Şekil 4.11: Lineer Kernel fonksiyonuna ait %80 eğitim verisi %20 test verisi oranları ile elde edilen sonuç görüntüsü a) 2018 yılına ait sonuç görüntüsü b) 2021 yılına ait sonuç görüntüsü c) 2024 yılına ait sonuç görüntüsü

Tablo 4.10’da yer alan 2018 yılı hata matrisi sonuçlarına göre; yeşil alan sınıfında 71 adet pikselin 52 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 54 tanesi doğru sınıflandırılırken, geriye kalan piksellerin yeşil alan sınıfı hariç diğer sınıflar ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 44 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 561 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 149 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan, yeşil alan ve yerleşim alanı sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 180 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 14 adet piksel yanlış sınıflandırılmıştır.

Tablo 4.10: Lineer Kernel fonksiyonuna ait %80 eğitim verisi %20 test verisi oranları ile elde edilen hata matrisi

Yıllar	Sınıflar	Yeşil Alan	Yerleşim Alanı	Yol	Boş Alan	Tarım Alanı	Sanayi Bölgesi	Toplam
2018	Yeşil Alan	52	2	0	13	4	0	71
	Yerleşim Alanı	0	54	2	4	1	1	62
	Yol	6	3	44	2	0	4	59
	Boş Alan	0	0	0	561	15	0	576
	Tarım Alanı	30	55	0	13	149	0	247
	Sanayi Bölgesi	0	0	14	0	0	180	194
	Toplam	88	114	60	593	169	185	1209
	Ü.D.	59.09	47.37	73.33	94.60	88.17	97.30	
	K.D.	73.24	87.10	74.58	97.40	60.32	92.78	
Genel Doğruluk: %86				Kappa Değeri: 0.80				
2021	Yeşil Alan	52	0	0	6	13	0	71
	Yerleşim Alanı	0	51	0	11	0	0	62
	Yol	1	0	56	0	0	2	59
	Boş Alan	0	0	0	568	8	0	576
	Tarım Alanı	14	17	0	24	192	0	247
	Sanayi Bölgesi	7	0	0	0	2	185	194
	Toplam	74	68	56	609	215	187	1209
	Ü.D.	70.27	75.00	100.00	93.27	89.30	98.93	
	K.D.	73.24	82.26	94.92	98.61	77.73	95.36	
Genel Doğruluk: %91				Kappa Değeri: 0.87				
2024	Yeşil Alan	68	0	0	0	3	0	71
	Yerleşim Alanı	0	58	0	4	0	0	62
	Yol	0	1	57	0	0	1	59
	Boş Alan	0	1	0	570	5	0	576
	Tarım Alanı	0	0	0	39	208	0	247
	Sanayi Bölgesi	0	0	1	0	1	192	194
	Toplam	68	60	58	613	217	193	1209
	Ü.D.	100.00	96.67	98.28	92.99	95.85	99.48	
	K.D.	95.77	93.55	96.61	98.96	84.21	98.97	
Genel Doğruluk: %95				Kappa Değeri: 0.93				
*Ü.D.: Üretici Doğruluğu, K.D.: Kullanıcı Doğruluğu								

Tablo 4.10’da bulunan 2021 yılında ise, yeşil alan sınıfında 71 adet pikselin 52 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 51 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan sınıfı ile karıştığı tespit edilmiştir. Yol

sınıfı için 59 adet pikselden 56 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 568 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 192 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan, yeşil alan ve yerleşim alanı sınıfları ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 185 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 9 adet piksel yanlış sınıflandırılmıştır.

2024 yılına ait hata matrisi incelendiğinde; yeşil alan sınıfında 71 adet pikselin 68 tanesinin doğru sınıflandırıldığı görülmektedir. Ancak geriye kalan pikseller yanlış sınıflandırılmıştır. Yerleşim alanı sınıfına bakıldığında 62 adet pikselin 58 tanesi doğru sınıflandırılırken, geriye kalan piksellerin boş alan sınıfı ile karıştığı tespit edilmiştir. Yol sınıfı için 59 adet pikselden 57 tanesi doğru sınıflandırılırken, geriye kalan pikseller yanlış sınıflandırılmıştır. Boş alan sınıfında 576 adet pikselin 570 tanesinin doğru sınıflandırıldığı görülmektedir. Buna karşılık geriye kalan pikseller yanlış sınıflandırılmıştır. 247 adet tarım alanı pikselinin 208 tanesi doğru sınıflandırılırken, geriye kalan pikseller, boş alan sınıfı ile karışmıştır. Sanayi bölgesi sınıfında ise elde edilen 194 adet pikselin 192 tanesi doğru bir şekilde sınıflandırıldığı görülmektedir. Geriye kalan 2 adet piksel yanlış sınıflandırılmıştır.

4.2. Araştırma Sonuçları

Tez çalışması kapsamında, sınıflandırma sonucu elde edilen hata matrisi üzerinden hesaplanan doğruluk oranları ve F1score değerleri, yıllara göre ve veri oranlarına göre değişkenlik göstermiştir. Örneğin; DVM-Polinom algoritması ile yapılan çalışmada, yeşil alan sınıfı her iki veri oranında da üretici doğruluğu 2024 yılında en yüksek sonuca ulaşmıştır. Ancak 70-30 oranında 2021 yılı sonucu, 80-20 oranındaki 2021 sonucuna göre belirgin bir şekilde düşük kalmıştır. Yerleşim alanı sınıfında 70-30 veri oranı ile elde edilen 2021 yılına ait üretici doğruluğu, diğer veri oranına göre daha yüksektir. 80-20 oranında ise bu sınıf, 2024 yılında %100 üretici doğruluğu ile tam doğruluk sağlamıştır.

Yol sınıfında her iki veri oranında 2021 yılına ait üretici doğruluğu %100 olarak hesaplanmıştır. Ancak 2018 ve 2024 yıllarında bu doğruluk, 80-20 veri oranı ile artmıştır. Boş alan sınıfına bakıldığında her iki veri oranında da yakın sonuçlar elde edilmiştir. Ancak 80-20 veri oranı, her yıl daha yüksek üretici doğruluğu sağlamıştır. Tarım alanı sınıfı incelendiğinde 2021 yılında her iki veri oranı da düşük sonuç vermiştir. 2024 yılında ise 80-20 veri oranı, diğer veri oranına göre daha yüksek bir üretici doğruluğuna sahiptir. Sanayi bölgesinde ise 2021 yılında, her iki veri oranı da tam doğruluk sağlamıştır. 2024 yılında ise üretici doğruluğu 80-20 veri oranıyla %100 doğruluğa ulaşmıştır.

Eğitim verisi artırıldığında bazı sınıfların doğruluk oranları da artmıştır. Yeşil alan, tarım alanı ve boş alan gibi sınıflarda bu artış daha belirgindir. Yerleşim alanı gibi sınıflarda ise, bazı yıllarda test verisinin fazla olması daha yüksek sonuç vermiştir. 2024 yılı, hem genel hem de sınıf bazlı doğruluklarda en yüksek üretici doğruluğuna sahip yıl olmuştur.

Bu algoritma ile elde edilen doğruluk sonuçları Tablo 4.11'de gösterilmiştir. F1score değerlerine bakıldığında, yeşil alan sınıfında 2018 yılında 0.70 olan F1score değeri, 2021 yılında 0.58'e gerilemiştir. Eğitim örneğinin az olması ve fenolojik bakımdan farklı olması nedeniyle, algoritma bu değişkenliği yeterince temsil edememiştir.

Tablo 4.11: DVM-Polinom algoritmasına ait doğruluk sonuçları

VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%70- %30	Yeşil Alan	74.63	70.42	0.70	50.52	69.01	0.58	98.46	90.14	0.94
	Yerleşim Alanı	69.86	82.26	0.76	94.00	75.81	0.84	98.31	93.55	0.96
	Yol	62.67	79.66	0.65	100.00	74.58	0.85	94.64	89.83	0.92
	Boş Alan	90.31	97.05	0.92	89.27	99.65	0.94	89.67	99.48	0.94
	Tarım Alanı	85.86	66.40	0.75	96.41	76.11	0.85	95.69	80.97	0.88
	Sanayi Bölgesi	97.83	92.78	0.84	100.00	92.78	0.96	98.90	92.27	0.96
VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%80- %20	Yeşil Alan	85.71	67.61	0.69	72.22	73.24	0.72	100.00	95.77	0.97
	Yerleşim Alanı	65.48	88.71	0.54	56.38	85.48	0.68	100.00	93.55	0.97
	Yol	75.44	72.88	0.55	100.00	93.22	0.96	98.31	98.31	0.98
	Boş Alan	94.59	94.10	0.92	92.30	99.83	0.96	92.27	99.48	0.96
	Tarım Alanı	82.75	85.43	0.55	90.50	65.59	0.76	98.10	83.81	0.91
	Sanayi Bölgesi	97.83	92.78	0.97	100.00	95.88	0.98	100.00	98.97	0.99

Tablo 4.11'e göre yerleşim alanı sınıfında 70-30 oranı ile elde edilen 2018 yılına ait F1score değeri, 80-20 veri oranına göre daha yüksek çıkmıştır. Test verisinin fazla olması nedeniyle, algoritmanın bu sınıfı daha iyi temsil ettiği düşünülmektedir. Yol sınıfında ise F1score değeri her yıl artış göstermektedir. 2018 yılında 70-30 veri oranındaki sonuç, diğer veri oranına göre daha yüksek çıkarken, 2021 ve 2024 yıllarındaki sonuçlarda bu değer, 80-20 veri oranında daha yüksek çıkmıştır. Bunun nedeni yol sınıfının 2021 ve 2024 yıllarında, komşu sınıflar ile spektral benzerliğinin artmasından kaynaklı olabilir. Eğitim verisi artınca bu benzerlik kolay ayırt edilerek, yüksek sonuçların çıkmasını sağlamıştır.

Tarım alanı sınıfında ise her iki veri oranında da artış gözükmemektedir. 2018 yılına ait sonuçlara göre 80-20 oranındaki F1score değeri, diğer orana göre düşük kalmıştır. Buna rağmen, 70-30 veri oranındaki sonuçlara göre artış daha yüksektir. Eğitim verisinin artması buna neden olabilir. Sanayi bölgesi sınıfının spektral özelliği belirgin olduğu için, polinom çekirdek algoritması bu sınıfı daha iyi temsil etmiştir.

DVM-Lineer algoritması ile gerçekleştirilen çalışmada, 2018 yılında, 80-20 oranında en yüksek üretici doğruluk oranları, sanayi bölgesi (%97.30), boş alan (%94.60) sınıflarında elde edilmiştir. Yerleşim alanı %47.37 üretici doğruluğu ile en düşük orana sahiptir. Fakat bu sınıf, 2021 yılında %75.00, 2024 yılında ise %96.67 oranına ulaşmıştır. Yeşil alan sınıfı, 70-30 oranı sonuçlarına göre 2021 yılında en düşük sonucu verirken, 2024 yılında bu üretici doğruluk sonucu %98.44 olarak hesaplanmıştır. Aynı sınıf 80-20 veri oranında her yıl bir önceki yıla göre artış göstermiştir. Sanayi

bölgesi sınıfı, her iki veri oranında da her yıl artış göstermiş, tüm yıllarda %95'in üzerinde üretici doğruluğuna sahip olarak en başarılı sınıf olmuştur. Sonuçlar incelendiğinde eğitim verisinin artması bazı sınıflarda doğruluğu arttırmıştır. Yeşil alan ve yerleşim alanı gibi sınıflarda ise doğruluk düşmüştür. Buna rağmen bu algoritma güçlü bir sınıflandırma performansı göstermiştir. Tablo 4.12'de bu algoritmaya ait sonuçlar bulunmaktadır.

Tablo 4.12: DVM-Linear algoritmasına ait doğruluk sonuçları

VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%70- %30	Yeşil Alan	71.01	69.01	0.70	49.02	70.42	0.58	98.44	88.73	0.93
	Yerleşim Alanı	67.47	90.32	0.77	72.88	69.35	0.71	95.00	91.94	0.93
	Yol	57.89	74.58	0.65	97.78	74.58	0.85	92.45	83.05	0.88
	Boş Alan	91.28	98.09	0.95	90.11	99.65	0.95	89.53	99.48	0.94
	Tarım Alanı	89.33	64.37	0.75	96.55	68.02	0.80	96.55	79.35	0.87
	Sanayi Bölgesi	97.83	92.78	0.95	98.96	97.94	0.98	100.00	97.42	0.99
VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%80- %20	Yeşil Alan	59.09	73.24	0.65	70.27	73.24	0.69	100.00	95.77	0.97
	Yerleşim Alanı	47.37	87.10	0.61	75.00	82.26	0.78	96.67	93.55	0.95
	Yol	73.33	74.58	0.74	100.00	94.92	0.97	98.28	96.61	0.97
	Boş Alan	94.60	97.40	0.96	93.27	98.61	0.96	92.99	98.96	0.95
	Tarım Alanı	88.17	60.32	0.72	89.30	77.73	0.83	95.85	84.21	0.90
	Sanayi Bölgesi	97.30	92.78	0.95	98.93	95.36	0.97	99.48	98.97	0.99

Tablo 4.12'deki F1score değerlerine bakıldığında, 70-30 veri oranındaki sonuçlara göre yeşil alan sınıfı 2018'de 0.70 gibi bir değere sahip iken, 2021 yılında 0.58 değerine gerilemiştir. Bu düşüşün nedeni ise vejetasyonun fenolojik bakımından farklı olduğu için, linear çekirdek fonksiyonunun bu farkı yeterince modelleyememesine bağlanabilir. 80-20 oranındaki yeşil alan sınıfı değerlerine bakıldığında ise tüm yıllarda artış meydana gelmiştir. Bu durum eğitim verisinin artmasıyla algoritmanın, spektral ayrımı daha iyi öğrendiğini göstermektedir. Aynı şekilde yerleşim alanında da 2021 yılında bir düşüş meydana gelmiştir. Bu durum ise farklı çatı malzemeleri, yol ve boş alan sınıflarına olan yakınlığı ile açıklanabilir. Yani iç sınıf heterojenliğe sahip olması nedeniyle algoritma bu ayrımı yapmada zorlanmış olabilir. 80-20 oranına bakıldığında ise, eğitim verisi arttığında bu ayrımı daha iyi yapmış ve hatayı azaltmıştır.

Yol sınıfında ise her iki veri oranında da düzenli bir artış meydana gelmiştir. Ancak 80-20 oranındaki belirgin artış, eğitim verisinin artırılması sayesinde meydana gelmiştir. Boş alan sınıfına bakıldığında, homojen bir yapıya sahip olması nedeniyle kolay bir şekilde temsil edilmiştir. Sonuçlara bakıldığında her iki veri oranında da 0.90'ın üzerinde bir değere sahip olduğu görülmektedir. Tarım alanı sınıfında ise her iki

veri oranında da düzenli bir artış meydana gelmiştir. Sanayi bölgesi sınıfında da düzenli bir artış meydana gelmiştir. Bu durum her iki veri oranında da görülmektedir.

RO algoritması ile elde edilen sonuçlara göre, yeşil alanı sınıfı, 80-20 oranında 2021 yılında %100 üretici doğruluğu sonucuna ulaşılırken, 2024 yılında bu doğruluk oranı %97.14 olarak hesaplanmıştır. 2018 yılında ise %83.33 ile en düşük doğruluğu vermiştir. 70-30 oranında ise 2021 yılında üretici doğruluğu en düşük doğruluğa sahiptir (%58.02). Yerleşim alanında, 80-20 veri oranında en düşük üretici doğrulukları bu sınıfta görülmektedir. Yine aynı şekilde 70-30 veri oranında da bu sınıf en düşük doğruluğa sahiptir.

Yol sınıfı incelendiğinde 80-20 veri oranı ile elde edilen sonuçlara göre 2021 ve 2024 yıllarında %95'in üzerinde değerler ile en başarılı sınıflardan biri olduğu gözlemlenmektedir. 70-30 veri oranında bu sınıf %100 doğruluk ile en yüksek sonucu vermiştir. Boş alan sınıfı, 70-30 veri oranında üç yılda da %90'nın üzerinde doğruluk oranına ulaşarak oldukça iyi bir performans göstermiştir. 80-20 veri oranında ise en yüksek sonucunu 2018 yılında %95.57 oranı ile vermiştir. Tarım alanı, her iki veri oranında da yüksek sonuçlar elde etmiştir. Sanayi bölgesi sınıfı, her iki veri oranında da %95'in üzerinde üretici doğruluk oranlarına sahip olduğu görülmektedir. Diğer sınıflara göre en yüksek sonuca sahip olan sınıf olmuştur. Tablo 4.13'te bu sonuçlar ayrıntılı bir şekilde sunulmuştur.

Tablo 4.13: RO algoritmasına ait doğruluk sonuçları

VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%70- %30	Yeşil Alan	72.00	76.06	0.74	58.02	66.20	0.62	96.92	88.73	0.93
	Yerleşim Alanı	33.33	77.42	0.47	23.03	61.29	0.33	41.44	74.19	0.53
	Yol	93.62	74.58	0.83	97.92	79.66	0.86	100.00	69.49	0.82
	Boş Alan	93.12	79.86	0.86	92.46	80.90	0.86	90.19	90.97	0.81
	Tarım Alanı	90.63	93.93	0.92	96.04	88.26	0.92	98.17	86.64	0.92
	Sanayi Bölgesi	99.48	98.97	0.99	100.00	94.85	0.97	99.48	98.97	0.99
VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%80- %20	Yeşil Alan	83.33	84.51	0.83	100.00	63.38	0.78	97.14	95.77	0.95
	Yerleşim Alanı	25.25	82.26	0.38	20.48	69.35	0.32	40.00	67.74	0.53
	Yol	86.79	77.97	0.82	98.15	89.83	0.95	96.15	84.75	0.89
	Boş Alan	95.57	74.83	0.84	94.77	72.40	0.82	90.43	90.28	0.90
	Tarım Alanı	95.88	94.33	0.96	92.83	99.60	0.96	98.13	85.02	0.91
	Sanayi Bölgesi	100.00	96.91	0.98	99.49	100.00	1.00	99.48	98.97	0.99

Tablo 4.13'e göre RO algoritması, yeşil ve yerleşim alanları hariç diğer sınıflarda oldukça başarılı sonuçlar elde etmiştir. Eğitim verisi arttırıldığında çoğu sınıfta daha tutarlı ve yüksek doğruluk elde edildiği görülmüştür. Ayrıca RO algoritması spektral

özellikleri belirgin olan sınıflarda üstün bir performans göstermiştir. Ancak sınıfların karışık olduğu yerlerde bu performansı düşmüştür.

F1score değerlerine bakıldığında, yeşil alan sınıfı spektral benzerliklere duyarlı olduğu için 2021’de özellikle 70-30 oranında belirgin bir düşüş meydana gelmiştir. Eğitim verisi az olduğu için algoritma bu varyansı yeterince temsil edememiştir. Yerleşim alanı sınıfının ise her iki veri oranında da en düşük değerlere sahip olduğu görülmektedir. Her iki durumda da heterojen olan bu sınıfın ayırt edilmesi güç olmuştur. Yol sınıfı için her iki veri oranında da yüksek sonuçların olduğu görülmektedir. 70-30 veri oranında her yıl artış görülürken, 80-20 oranında 2024’te düşüş meydana gelmiştir. Bu dalgalanmanın, yol sınıfının spektral çeşitliliği ile ilişkili olduğu düşünülmektedir.

Boş alan sınıfı her iki veri oranında da genel olarak yüksek F1score değerleri üretmiştir. 70-30 oranında istikrarını korurken, 80-20 oranında 2021’de düşüş yaşanmış fakat 2024’te toparlanma göstermiştir. Tarım alanı sınıfında ise 70-30 oranı sonuçlarında kademeli artış gözlemlenmiştir. 80-20 oranında ise çok yüksek değerler elde edilmiştir, ancak 2024’te hafif düşüş meydana gelmiştir. Sanayi bölgesi spektral olarak homojen bir yapıya sahip olduğu için RO algoritması oldukça yüksek performans göstermiştir. Özellikle 80-20 oranındaki değerlerin 1.00’a yakın olması, bu sınıfın güçlü ayırt edici spektral özellikleriyle ilişkili olabilir.

Bir diğer algoritma olan Naive Bayes algoritması ile yapılan sınıflandırma çalışmasında, yeşil alan sınıfında 80-20 oranı sonuçlarında 2024 yılı üretici doğruluğu %94.29 iken, 70-30 veri oranında bu doğruluk %79.73 olarak hesaplanmıştır. Bu sınıf, 2018 ve 2021 yıllarında her iki veri oranı sonuçlarında da düşük üretici doğruluğuna sahip olduğu görülmektedir. Yerleşim alanına bakıldığında her iki veri oranında da çok düşük performans gösterilmiştir. Yol sınıfında ise her iki veri oranında da yıl ilerledikçe üretici doğruluk oranları düşmüştür.

Boş alan sınıfı incelendiğinde, her iki veri oranı sonuçlarına göre üç yılda da yüksek doğruluk oranları görülmektedir. En yüksek sonuca 2021 yılında ulaşmış olup, eğitim oranı fark etmeksizin en başarılı sınıf olmuştur. Tarım alanı sınıfı, 2021 yılında her iki oranda da düşüş yaşamıştır. 2024 yılında ise hem 80-20 oranında hem de 70-30 veri oranında birbirine yakın doğruluklar elde edilmiştir. Sanayi bölgesi sınıfında ise tüm yıllarda ve veri oranlarında istikrarlı bir şekilde en yüksek üretici doğruluk oranları elde edilmiştir. Tablo 4.14’te bu algoritmaya ait doğruluk sonuçları gösterilmektedir.

Tablo 4.14: Naive Bayes algoritmasına ait doğruluk sonuçları

VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%70- %30	Yeşil Alan	56.03	91.55	0.70	25.37	73.24	0.38	79.73	83.10	0.87
	Yerleşim Alanı	27.32	80.65	0.41	41.67	64.52	0.51	34.00	54.84	0.43
	Yol	51.65	79.66	0.63	46.23	83.05	0.59	25.93	71.19	0.38
	Boş Alan	87.77	84.72	0.86	96.29	99.13	0.98	90.20	92.71	0.91
	Tarım Alanı	56.52	15.79	0.25	34.38	4.45	0.07	53.38	28.74	0.37
	Sanayi Bölgesi	98.97	98.97	0.99	100.00	91.24	0.95	97.30	74.23	0.84
VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%80- %20	Yeşil Alan	48.06	87.32	0.62	30.62	90.14	0.46	94.29	92.96	0.96
	Yerleşim Alanı	23.56	66.13	0.35	38.94	70.97	0.50	26.62	59.68	0.37
	Yol	60.00	71.19	0.65	52.04	86.44	0.65	42.74	84.75	0.46
	Boş Alan	88.39	88.54	0.88	96.95	99.31	0.98	85.95	92.36	0.92
	Tarım Alanı	40.91	10.93	0.17	12.50	0.81	0.01	53.04	24.70	0.34
	Sanayi Bölgesi	98.96	98.45	0.99	100.00	94.33	0.97	98.66	75.77	0.86

Tablo 4.14 incelendiğinde, eğitim verisi artsa bile düşük doğruluklar dikkat çekmektedir. Bunun nedeni sınıflardaki spektral karışıklık veya benzer görünümlerden kaynaklı olarak algoritmanın ayırım yapmada zorlanıyor olmasıdır.

F1score sonuçlarına bakıldığında, yeşil alan sınıfında 2018 ve 2021 yıllarında düşük bir performans göstermiştir. 2024 yılında ise daha iyi sonuçlar vermiştir. Değerlerin düşük olması algoritmanın bağımsızlık varsayımı yapmasından kaynaklandığı düşünülmektedir. Ayrıca 2021 yılındaki fenolojik farkı da buna etken olabilir. Yerleşim alanı sınıfı heterojen yapısı nedeniyle algoritma için zor bir sınıf olmuştur. Piksellerin karışık olması, algoritmanın bu sınıfı yeterince modelleyememiştir. Veri oranı değişmesine rağmen iyileşme meydana gelmemiştir. Yol sınıfında ise her iki veri oranında da sürekli düşüş gözlemlenmiştir. 80-20 oranında düşüş yaşansa da, 70-30 veri oranına göre iyi sonuçlar vermiştir.

Boş alan sınıfı spektral olarak homojen olduğundan başarılı sonuçlar elde edilmiştir. Genel olarak her iki veri oranıyla stabil ve yüksek değerlere ulaşılmıştır. Tarım alanı, algoritma için en başarısız sınıflardan birisi olmuştur. Algoritmanın bağımsızlık varsayımı, tarımsa spektral değişkenliği tam olarak modelleyememiştir. Bu bağlamda kabul edilebilir seviyeye ulaşamamıştır. Sanayi bölgesinde 2024 yılında düşüş yaşandığı görülmektedir. Bunun nedeni çoklu bant korelasyonunu dikkate almamasından kaynaklandığı düşünülmektedir.

KNN algoritmasında ise, 2018 yılına bakıldığında yol ve sanayi bölgesi sınıfları 70-30 oranı sonuçlarına göre en yüksek üretici doğruluğunu vermiştir. Yeşil alan sınıfında ise 80-20 oranı ile elde edilen üretici doğruluklarının daha başarılı olduğu

görülmektedir. 2018 ve 2024 yıllarında üretici doğruluk oranları %95'in üzerinde olduğu tespit edilmiştir. Boş alan sınıfı da hem 2021 hem de 2024 yıllarında %95'in üzerinde bir üretici doğruluk oranına ulaşmıştır. 2018 yılı, diğer yıllara göre düşük kalsa da her iki oranda da %90'ın üzerinde başarı elde ederek, bazı sınıfları geride bırakmıştır. Tarım alanı 80-20 oranı sonuçlarına göre 2021 yılında, diğer yıl ve veri oranlarına göre en düşük üretici doğruluğu oranına sahiptir. Sanayi bölgesi sınıfı ise tüm yıllarda ve hem 80-20 veri oranında hem de 70-30 veri oranında da çok yüksek sonuçlar elde etmiştir. Bu bağlamda sanayi bölgesi başarılı bir şekilde sınıflandırılmıştır. Tablo 4.15'te KNN algoritmasına ait doğruluk sonuçları bulunmaktadır.

Tablo 4.15: KNN algoritmasına ait doğruluk sonuçları

VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%70- %30	Yeşil Alan	86.15	78.87	0.82	65.12	78.87	0.71	98.39	85.92	0.92
	Yerleşim Alanı	30.54	82.26	0.45	35.00	67.74	0.46	36.97	70.97	0.49
	Yol	97.56	67.80	0.78	95.92	79.66	0.87	97.78	74.58	0.85
	Boş Alan	91.72	80.73	0.86	96.00	87.50	0.92	95.45	91.15	0.93
	Tarım Alanı	91.98	88.26	0.90	92.02	88.66	0.90	96.23	93.12	0.95
	Sanayi Bölgesi	100.00	98.97	0.99	99.48	97.94	0.99	98.45	98.45	0.98
VERİLER		2018			2021			2024		
Veri Oranı	Sınıflar	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score	Ü.D.(%)	K.D.(%)	F1score
%80- %20	Yeşil Alan	96.83	85.92	0.90	79.03	69.01	0.73	98.55	95.77	0.96
	Yerleşim Alanı	24.75	80.65	0.38	28.85	72.58	0.41	44.23	74.19	0.55
	Yol	89.80	74.58	0.81	97.83	76.27	0.86	100.00	86.44	0.92
	Boş Alan	93.38	75.87	0.84	95.65	80.21	0.87	96.36	92.01	0.94
	Tarım Alanı	92.92	90.28	0.91	87.31	94.74	0.91	97.11	95.14	0.96
	Sanayi Bölgesi	100.00	96.39	0.98	99.48	99.48	0.99	99.48	98.97	0.99

Tablo 4.15'e göre, eğitim oranının artması genellikle doğruluk oranlarının da arttırdığını göstermektedir. Yine de bazı sınıflardaki spektral benzerlik olduğu için, eğitim verisinin artması bu sınıflarda işe yaramamıştır.

F1score değerleri incelendiğinde, yeşil alan sınıfında 80-20 oranı yüksek sonuçlar vermiştir. 2021'de düşüş meydana gelmiştir. Bu düşüşün nedeni bu yılda spektral özelliğin artmasından kaynaklandığı düşünülmektedir. Yerleşim alanı sınıfında değerler her yıl artmasına rağmen, her iki veri oranında da düşük sonuçlar elde edilmiştir. Yine de veri oranındaki artış, heterojen yerleşim alanı sınıfını iyi temsil etmiştir. Yol sınıfında iki veri oranında belirgin bir fark olduğu gözlemlenmiştir. 80-20 oranında, eğitim verisi fazla olduğu için, diğer orana göre yüksek sonuçlar vermiş ve her yıl bu değerler artmıştır.

Boş alan sınıfı incelendiğinde yüksek F1score değerleri verdiği görülmektedir. Bu sınıf spektral olarak homojen bir yapıya sahip olduğu için, algoritma başarılı bir

performans göstermiştir. Tarım alanı sınıfı, 80-20 oranında oldukça iyi bir başarı elde etmiştir. Sonuçlara bakıldığında değerlerin yüksek ve istikrarlı olduğu görülmektedir. Bu durum her iki veri oranı için de geçerlidir. Sanayi bölgesi sınıfına bakıldığında, her iki veri oranında da çok yüksek değerlere ulaşılmıştır. KNN algoritması hem 70-30 oranında hem de 80-20 oranında, spektral çeşitliliği fazla olan bu sınıfı daha iyi temsil ettiği görülmektedir.

Aşağıdaki tabloda ise her iki veri oranlarına ve üç farklı yıla ait genel doğruluk oranı ve kappa değerleri verilmiştir.

Tablo 4.16: %70-%30 ve %80-%20 veri oranlarına ve üç farklı yıla ait genel doğruluk ve kappa değerleri

Veri Oranları	Algoritmalar	2018		2021		2024	
		Genel Doğruluk	Kappa Değeri	Genel Doğruluk	Kappa Değeri	Genel Doğruluk	Kappa Değeri
%70-%30	DVM-Polinom	87%	0.81	89%	0.85	93%	0.90
	DVM-Lineer	86%	0.80	88%	0.83	93%	0.90
	KNN	85%	0.79	88%	0.83	81%	0.87
	Rastgele Orman	85%	0.80	83%	0.86	89%	0.85
	Naive Bayes	73%	0.63	74%	0.64	73%	0.62
Veri Oranları	Algoritmalar	2018		2021		2024	
		Genel Doğruluk	Kappa Değeri	Genel Doğruluk	Kappa Değeri	Genel Doğruluk	Kappa Değeri
%80-%20	DVM-Polinom	89%	0.85	90%	0.85	96%	0.94
	DVM-Lineer	86%	0.80	91%	0.87	95%	0.93
	KNN	83%	0.77	85%	0.79	93%	0.90
	Rastgele Orman	83%	0.78	83%	0.77	89%	0.85
	Naive Bayes	72%	0.61	76%	0.66	74%	0.63

Genel doğruluk oranı sınıflandırmanın genel başarısını gösterir ve sadece doğru sınıflandırılan pikselleri baz alır. Kappa değeri ise, rastlantısal doğruluk payını da dikkate alır. Algoritma performanslarını bu doğruluk payına göre değerlendirir. Kappa değeri, 0-1 arasında bir değer alır. Sonuç 1'e yaklaştıkça sınıflandırma doğruluğunun güvenilir olduğu anlamına gelir. Genel olarak, 0.60 üzerindeki değerler kabul edilebilir durumda iken, 0.70 ve üzerindeki değerler çok güçlü olarak kabul edilmektedir. 0.60'ın altında kalan değerler ise çok zayıf olarak kabul edilmektedir (Landis ve Koch, 1977).

Tablo 4.16 incelendiğinde, DVM-Polinom algoritması her iki veri oranında da en yüksek genel doğruluk oranı ve kappa değerini vermiştir. Yıl bazında bakıldığında her yıl genel doğruluk ve kappa değerleri artarak devam etmiştir. Her iki veri oranında bu durum görülmektedir. Eğitim verisi %70'ten %80'e çıkarıldığında algoritmanın genel doğruluk değerleri artmıştır. 2021 yılında ise genel doğruluk artmasına rağmen, kappa değeri sabit kalmıştır. 2024 yılına bakıldığında, 80-20 veri oranı ile gerçekleştirilen çalışmada %96 genel doğruluk, 0.94 kappa değerine ulaşarak en yüksek değerlere sahip algoritma olmuştur.

DVM-lineer algoritması ile yapılan çalışmada ise, her iki veri oranında da yüksek performans göstermiştir. Eğitim verisi arttırıldığında, 2018 yılındaki değerler sabit kalmış, 2021 ve 2024 yıllarında bu değerler artmıştır. Bu bilgiler doğrultusunda DVM-Polinom'dan sonra en yüksek sonuç veren algoritma olduğu görülmektedir.


KNN algoritması veri oranlarına karşı dalgalı bir performans göstermiştir. Eğitim verisi arttırıldığında 2018 ve 2021 yıllarında genel doğruluk oranı ve kappa değerlerinde düşüş meydana gelmiştir. 2024 yılında ise bu oranlar büyük sıçrama yapmıştır.

Rastgele orman algoritması orta düzeyde bir performans göstermiş ancak bu performansını istikrarlı bir şekilde korumuştur. Elde edilen veriler, veri oranlarındaki değişikliğin bu algoritmayı çok fazla etkilemediğini göstermektedir.


Naive Bayes algoritması ise her iki veri oranında da en düşük sonucu veren algoritma unvanına sahip olmuştur. Algoritma, hem 80-20 veri oranı hem de 70-30 veri oranı ile yapılan çalışmada, neredeyse aynı sonuçları vermiştir. Naive Bayes algoritması, tüm öznitelikleri birbirinden bağımsız olarak varsayar. Olasılık hesaplamalarını buna göre gerçekleştirir. Sentinel-2 uydu görüntüsündeki bantlar arasında yüksek bir korelasyon bulunmaktadır. Bu yüzden sınıflar arasındaki ayrım gücünü azaltmış ve hatalı sonuçların elde edilmesine neden olmuştur. Ayrıca, çalışma alanında bulunan sınıfların spektral benzerlikleri, algoritmanın modelleme konusunda yetersiz kalmasına sebep olmuştur. Bu bağlamda algoritma, öznitelik arası bağımlılıkları göz ardı ettiği için ve karmaşık sınıfları ayırt etmede zorlandığı için kappa değerleri düşük sonuç vermiştir.

Sonuç olarak DVM-Polinom, DVM-lineer, RO ve KNN algoritmaları 0.70'in üzerinde bir kappa değerlerine sahip oldukları için, sınıflandırma doğruluğu açısından güvenilir durumdadırlar. Ancak Naive Bayes algoritması 0.60-0.70 arasında bir değer almıştır. Bu yüzden çok güçlü olmasa da kabul edilebilir bir değere ulaşmıştır.

Çalışma kapsamında elde edilen sonuç görselleri aşağıda verilmiştir. Şekil 4.12'de %70 eğitim verisi - %30 test verisi ile elde edilen sonuç görüntüleri, Şekil 4.13'te ise %80 eğitim verisi- %20 test verisi ile elde edilen sonuç görüntüleri yer almaktadır.



Şekil 4.12: %70 eğitim verisi %30 test verisi oranları ile elde edilen sonuç görüntüler



Şekil 4.13: %80 eğitim verisi %20 test verisi oranları ile elde edilen sonuç görüntüler

Şekil 4.12 ve Şekil 4.13 incelendiğinde çoğunlukla her sınıfın doğru sınıflandırıldığı görülmektedir. Ancak bazı bölgelerde, her iki veri oranı sonucu oluşan görüntülerde sınıfların birbirine karıştığı görülmektedir. Naive Bayes algoritması ile yapılan çalışmada yol sınıfı, sanayi bölgesi sınıfı ile bazı bölgelerde karışmıştır. Bu durum 2018, 2021 ve 2024

sonuçlarında da görülmektedir. Buna benzer şekilde KNN algoritması ile yapılan çalışmada yerleşim alanı sınıfı, boş alan sınıfı ile karışmıştır.

Sanayi bölgesi sınıfının ise neredeyse tüm algoritmalar ile yapılan çalışmada yol sınıfı ile karıştığı görülmektedir. Bunun başlıca nedenlerinden biri sınıflar arasındaki spektral benzerliktir. Örneğin Sanayi bölgesinde yer alan bazı yapıların spektral özellikleri ile yol sınıfı ile benzerlik gösterdiği için sınıflandırma aşamasında algoritmalar, pikselleri ayıramayıp karışıklığa neden olmuştur.

Tarım alanı sınıfı ise bazı bölgelerde boş alan ile karışırken, bazı bölgelerde ise yeşil alan ile karıştığı görülmektedir. Buna yine sınıfların spektral benzerliği sebep olmaktadır. Ayrıca kullanılan uydu görüntüsünün mekânsal çözünürlüğünün düşük olması, sınıfların birbirine yakın olduğu ve spektral özelliği belirgin olmayan bölgelerde piksellerin karışmasına neden olmuştur.

Eğitim verisi arttırıldığında görüntülerdeki bazı bölgelerde iyileşmeler olduğu görülmektedir. Örneğin DVM algoritmasının her iki Kernel fonksiyonları ile yapılan çalışmada bu durum belirgin bir şekilde görülmektedir. Özellikle DVM-Polinom algoritmasına ait 2018 yılı görsellerinde bu farklılık net bir şekilde fark edilmektedir. Naive Bayes algoritmasında, eğitim verisi arttırılmasına rağmen gözle görülür bir değişikliğin olmadığı gözlemlenmiştir. KNN algoritmasında ise yine belirgin değişiklikler görülmektedir. Rastgele Orman algoritmasına bakıldığında bu iyileşmeler, diğer algoritmalarla göre çok belirgin değildir. Özellikle DVM algoritması ile karşılaştırıldığında, iyileşmeler Rastgele Orman algoritmasında daha az olarak gözlemlenmektedir.

Sonuç görselleri incelendiğinde, sınıflandırma sonucunda genel doğruluk oranları yüksek çıkmasına rağmen, piksel karışıklıkları olduğu gözlemlenmiştir. Bu durum, makine öğrenmesi algoritmalarının, genel performansını ifade eden metriklerle, sonuç görselleri arasında her zaman uyumlu olmayacağını göstermektedir. Genel doğruluk oranı, sınıflandırma sonucunda oluşan doğru sınıflandırılan piksellerin toplamının, tüm piksel sayısına oranıdır. Yani sınıflandırıcının genel başarısını gösterir. Bu bağlamda bu oran, hangi sınıflarda piksel karışıklığı yaşandığını göstermez. Özellikle spektral benzerlik olan sınıflarda piksellerin yanlış sınıflandırılması, genel doğruluk oranının yüksek olmasına rağmen mümkün olmaktadır.

Yıllara göre yapılan sınıflandırma işleminin sonuçları karşılaştırıldığında, çalışma alanında gözle görülür bir şekilde AK/AÖ değişimi gözlemlenmektedir. Şekil 4.14 ve Şekil 4.15' bu değişim grafik olarak gösterilmiştir.



Şekil 4.14: %80-%20 veri oranına göre elde edilen zamansal değişim grafikleri a) DVM-Lineer b) DVM-Polinom c) Naive Bayes d) Rastgele Orman e) K-En Yakın Komşu f) Tüm algoritmaların ortak eğilimi

Şekil 4.14 incelendiğinde, DVM-Lineer algoritması ile yapılan çalışmada sınıflar arasında dalgalanmalar mevcuttur. Yeşil alanlar 2018 yılında 2039.87 ha iken, 2021 yılına gelindiğinde 2473.95 ha'ya kadar yükseldiği görülmektedir. 2024 yılında ise 1754.38 ha'ya kadar gerilemiştir. Yerleşim alanı, 2018'de 2409.23 ha kadar alana sahip iken, 2021'de 1775.40'ha'ya kadar gerilemiş, 2024'te 2601.41 ha'ya yükselmiştir. Yol sınıfında da aynı şekilde, çalışma alanında kapladığı alan 2021 yılında düşüş yaşarken, 2024 yılında bu alan miktarı yükselişe geçmiştir.

Boş alan sınıfı ise, 2018'de 10414,59 ha gibi bir alan kaplarken, 2021 yılında bu alan 11610.20 ha'ya çıkmış, 2024'te ise 10794.88 ha'ya gerilemiştir. Tarım alanlarının, 2018 yılında 3215.82 ha bir alan kapladığı görülmektedir. 2021 yılına gelindiğinde bu alan miktarı artmış, 2024 yılında ise tekrar düşüşe geçmiştir. Sanayi bölgesi ise 2018'den 2024'e kadar sürekli artış göstermiştir. Genel olarak DVM-Lineer algoritması lineer karar sınırları yapısı nedeniyle karmaşık sınıflarda tutarsızlık gösterirken, homojen sınıflarda ise daha istikrarlı bir sonuç vermiştir.

DVM-Polinom algoritmasının zamansal analiz sonuçları incelendiğinde, yeşil alan sınıfı 2018'de 1678.24 ha iken 2021'de 2891.94 ha'ya yükselmiş, 2024 yılında ise 1701.84 ha'ya gerilemiştir. Yerleşim alanı 2018'de 2116.42 ha iken 2021'de 2088.23 ha'ya gerilemiş, 2024'te ise 2315.61 ha'ya çıkarak bölgede bir artış gözlemlenmiştir. Yol sınıfında 2018'de 4772.42 ha iken, 2021'de 3128.97 ha'ya gerilemiş, 2024'te ise 4256.82 ha'ya yükselmiştir. Boş alanlar 2018'de 10,654.52 ha iken 2021'de 11,620.63 ha'ya çıkmış, 2024 yılında 10,724.38 ha'ya gerileyerek 2018 seviyesinde ki ilk haline yaklaşmıştır. Tarım alanı ise 2018'de 4051.76 ha iken 2021'de 3626.97 ha'ya, 2024'te ise 3347.52 ha'ya düşmüştür. Sanayi bölgesi 2018'de 1018.34 ha iken 2021'de 934.94 ha'ya küçük bir gerileme yaşamış, 2024'te ise 1945.52 ha'ya ulaşarak yaklaşık iki katına çıkmıştır. Genel olarak DVM-Polinom algoritması, doğrusal olmayan karar sınırlarını modelleme özelliği sayesinde özellikle sanayi ve yerleşim alanlarında daha tutarlı sonuçlar üretmiş, ancak yeşil alan ve tarım sınıflarında belirgin dalgalanmaların olduğu tespit edilmiştir.

Naive Bayes algoritmasının incelendiğinde, sınıflar arasında belirgin dalgalanmalar meydana gelmiştir. Yeşil alan 2018'de 3621.27 ha iken 2021'de 1472.92 ha'ya düşmüş, 2024'te 1926.87 ha'ya yükselmiştir. Yerleşim alanı 2018'de 1697.98 ha iken 2021'de 1746.32 ha ile artış göstermiş, 2024 yılında ise 899.10 ha'ya gerileyerek önemli bir azalma olmuştur. Yol sınıfı 2018'de 6037.72 ha iken 2021'de 6532.88 ha'ya çıkmış, 2024'te ise 5655.55 ha'ya düşmüştür. Boş alanlar 2018'de 7996.33 ha iken 2021'de 10,830.44 ha'ya yükseldiği görülürken, 2024'te 10,136.33 ha'ya gerileyerek kısmen azalmıştır.

Tarım alanı 2018'de 3768.23 ha iken 2021'de 2312.19 ha'ya düşmüş, 2024'te ise 4012.99 ha'ya çıkmıştır. Sanayi bölgesi ise 2018'de 1165.40 ha, 2021'de 1364.65 ha ve 2024'te 1404.87 ha olarak sürekli artış kaydetmiştir. Bu sonuçlar, Naive Bayes algoritmasının öznitelikler arasındaki bağımlılığı göz ardı etmesi nedeniyle özellikle heterojen sınıflarda (yeşil alan, yerleşim, yol, tarım) istikrarsız sonuçlar verdiğini, buna

karşın homojen sınıflarda (boş alan, sanayi) daha kararlı sonuçlar verdiğini ortaya koymaktadır.

RO algoritmasının zamansal analiz sonuçlarına göre, yeşil alan 2018'de 1539.73 ha, 2021'de 1163.93 ha, 2024'te 1579.93 ha olarak kaydedilmiştir. Yerleşim alanı 2018'de 3734.02 ha iken 2021'de 7175.88 ha'ya yükselmiş, 2024 yılında ise 4914.05 ha olarak kaydedilmiş ve genel olarak artış eğilimi göstermiştir. Yol sınıfı 2018'de 3978.44 ha iken 2021'de 2969.67 ha'ya düşmüş, 2024 yılında 3459.25 ha ile kısmi bir artış göstermiştir. Boş alan 2018'de 9180.65 ha iken 2021'de 8884.17 ha'ya düşmüş, 2024'te ise 9414.66 ha'ya yükselmiştir.

Tarım alanı 2018'de 5035.99 ha iken 2021'de 2651.20 ha'ya gerilemiş ve 2024 yılında 2639.90 ha ile 2021'deki değere yakın bir değer kaydetmiştir. Sanayi bölgesi ise sürekli artış eğilimi göstermiş. Bu bulgular, RO algoritmasının sanayi ve yerleşim sınıflarında güçlü sonuçlar ürettiğini göstermektedir. Bunun temel nedeni, algoritmanın çok sayıda karar ağacı ile karmaşık sınıfları modelleyebilmesine rağmen, spektral benzerliğe sahip sınıflarda, yanlış sınıflandırmalara daha yatkın olmasıdır.

KNN algoritmasının zamansal analiz sonuçlarına bakıldığında, sınıflar arasında farklı eğilimler tespit edilmiştir. Yeşil alan 2018'de 1766.07 ha iken 2021'de 1559.74 ha'ya gerilemiş, 2024 yılında ise 1479.58 ha olarak kaydedilmiştir. Yerleşim alanı ise 2018'de 4011.63 ha iken 2021'de 5551.82 ha'ya yükselmiş, 2024 yılında 4076.28 ha'ya gerilemiştir. Yol sınıfı 2018'de 4499.67 ha olarak belirlenmiş, 2021'de 3219.10 ha'ya düşmüş ve 2024 yılında 3692.77 ha ile kısmi bir toparlanma göstermiştir. Boş alan 2018'de 8261.87 ha iken 2021'de 9769.84 ha'ya yükselmiş, 2024 yılında ise 9518.66 ha ile yüksek seviyesini korumuştur.

Tarım alanı 2018'de 4989.50 ha iken 2021'de 2675.44 ha'ya gerilemiş, 2024 yılında 3192.19 ha ile kısmi bir artış göstermiştir. Sanayi bölgesi ise sürekli artış eğilimi sergilemiş; 2018'de 762.94 ha iken 2021'de 1515.76 ha'ya, 2024 yılında ise 2332.21 ha'ya yükselmiştir. Bu sonuçlar, KNN algoritmasının özellikle yerleşim ve sanayi bölgelerini ayırt ederken güçlü performans sergilediğini, ancak spektral olarak benzer sınıflarda daha fazla hata yapabildiğini göstermektedir. Bunun nedeni ise, KNN algoritmasının örneklerin komşuluk ilişkilerini esas alarak sınıflandırma yapmasıdır.



Şekil 4.15: %70-%30 veri oranına göre elde edilen zamansal değişim grafikleri a) DVM-Lineer b) DVM-Polinom c) K-En Yakın Komşu d) Naive Bayes e) Rastgele Orman f) Tüm algoritmaların ortak eğilimi

Şekil 4.15'teki verilere göre, DVM-Lineer algoritmasının zamansal analizi incelendiğinde, sınıflar arasında belirgin bir değişimlerin olduğu görülmektedir. Yeşil alan 2018'de 2201.71 ha seviyesinde iken, 2021'de 2703.55 ha'ya yükselmiş ve 2024 yılında ise 1754.24 ha'ya düşmüştür. Yerleşim alanı 2018'de 1960.26 ha iken 2021'de 2091.75 ha ile artış göstermiş, 2024 yılında ise 2469.51 ha ile alan miktarı artmaya devam etmiştir. Yol sınıfı 2018'de 4519.84 ha olarak hesaplanmış, 2021'de 2784.49 ha'ya düşmüş, 2024 yılında ise 3846.66 ha'ya kadar yükselmiştir. Boş alan sınıfı ise

2018'de 10,776.19 ha iken 2021'de 12,115.79 ha'ya yükselmiş, 2024'te ise 11,235.15 ha olarak kaydedilmiştir.

Tarım alanı 2018'de 3370.92 ha iken 2021'de 3169.01 ha'ya gerilemiş, 2024 yılında 2939.62 ha ile düşüşe geçmiştir. Sanayi bölgesi ise 2018'de 1462.76 ha iken 2021'de 1427.10 ha ile düşüşe geçmiştir, 2024 yılında ise 2046.50 ha ile belirgin bir artış görülmektedir. Sonuçlar, DVM-Lineer karar sınırlarını yalnızca doğrusal şekilde ayırabilmesi, bu sınıflardaki dalgalanmaların temel nedeni olarak değerlendirilebilir.

DVM-Polinom algoritmasının sonuçları incelendiğinde, yeşil alan 2018'de 2174.06 ha olarak kaydedilirken, 2021'de 2909.08 ha'ya yükselmiş, 2024 yılında ise 1700.28 ha'ya kadar gerilemiştir. Yerleşim alanı 2018'de 1661.46 ha'ya, 2021'de 1966.05 ha'ya, 2024'te ise 2138.19 ha'ya ulaşarak sürekli artış sergilemiştir. Yol sınıfı 2018'de 4642.18 ha iken 2021'de 2787.17 ha'ya kadar düşmüş, 2024 yılında ise 4006.65 ha ile tekrar yükselişe geçmiştir. Boş alan 2018'de 10,621.50 ha iken 2021'de 12,270.01 ha'ya çıkmış, 2024 yılında ise 11,075.44 ha'ya gerilemiştir.

Tarım alanı 2018'de 3732.38 ha iken 2021'de 3373.53 ha'ya kadar gerilemiş, 2024 yılında 3299.14 ha ile düşüşüne devam etmiştir. Sanayi bölgesi ise 2018'de 1460.11 ha iken 2021'de 985.85 ha'ya düşmüş, 2024 yılında ise 2071.98 ha ile belirgin bir artış göstermiştir. Genel olarak, DVM-Polinom algoritması yerleşim alanı, sanayi bölgesi gibi yapay yüzeyleri güçlü ve kolay biçimde ayırt edebilmiş, ancak tarım ve yeşil alan gibi doğal sınıflarda ise yıllara göre belirgin dalgalanmalar tespit edilmiştir. Bu durum, algoritmanın esnek yapısının avantajlarını gösterirken, spektral benzerliklerin yoğun olduğu yıllarda sınıf karışıklığının arttığını göstermektedir.

RO algoritmasının sonuçlarına göre, sınıflar arasında gözle görülür farklılıklar tespit edilmiştir. Yeşil alan 2018'de 1788.85 ha iken 2021'de 1654.93 ha'ya, 2024 yılında ise 1506.02 ha'ya düşmüştür. Yerleşim alanı 2018'de 3276.83 ha olarak kaydedilmiş, 2021'de 7295.26 ha'ya yükselmiş ve 2024 yılında 5346.29 ha'ya kadar düşse de 2018'e kıyasla artış eğilimini korumuştur. Yol sınıfı 2018'de 3699.38 ha iken 2021'de 2525.07 ha'ya düşmüş, 2024 yılında ise 3072.95 ha'ya yükselmiştir.

Boş alan 2018'de 9816.87 ha iken 2021'de 9283.62 ha'ya düşmüş, 2024 yılında ise 9715.54 ha'ya çıkarak neredeyse 2018 seviyesine yaklaştığı görülmektedir. Tarım alanı 2018'de 4814.62 ha iken 2021'de 2211.51 ha'ya ciddi bir düşüş göstermiş, 2024 yılında ise 2293.61 ha'ya yükselse de 2018'e göre düşük kalmıştır. Sanayi bölgesi ise sürekli artış eğilimi göstermiştir. 2018'de 895.14 ha iken 2021'de 1321.31 ha'ya, 2024 yılında ise 2357.28 ha'ya yükselmiştir.

Genel olarak, RO algoritması yerleşim alanı, sanayi bölgesi gibi sınıflarda diğer sınıflara göre güçlü sınıflandırma sonuçları verirken, yeşil alan ve tarım alanındaki azalmaların ve yol sınıfında dalgalanmaların olduğu görülmüştür. Algoritmanın karar ağaçlarına dayalı yapısı, özellikle spektral benzerliklerin yüksek olduğu sınıflarda karışıklıklara yol açtığı gözlemlenmiştir.

Naive Bayes algoritmasının zamansal analiz sonuçları incelendiğinde, sınıflar arasında belirgin farklılıklar meydana gelmiştir. Yeşil alan 2018'de 3874.88 ha olarak hesaplanırken, 2021'de 1526.80 ha'ya ciddi bir düşüş göstermiş, 2024 yılında ise 1907.68 ha'ya yükselse de başlangıç seviyesinin altında kalmıştır. Yerleşim alanı 2018'de 1590.53 ha iken 2021'de 1888.30 ha'ya yükselmiş, 2024 yılında ise 786.76 ha'ya düşmüştür.

Yol sınıfı 2018'de 6060.54 ha iken 2021'de 6430.65 ha'ya yükselmiş, 2024 yılında 5715.91 ha ile kısmi bir azalış göstermiştir. Boş alan ise 2018'de 8219.28 ha iken 2021'de 10,482.68 ha'ya çıkmış ve 2024 yılında 10,505.21 ha ile yüksek seviyede kalmıştır. Tarım alanı 2018'de 3363.41 ha iken 2021'de 2523.54 ha'ya düşmüş, 2024 yılında ise 3628.33 ha ile artış göstermiştir. Sanayi bölgesi ise 2018'de 1176.99 ha iken 2021'de 1406.22 ha'ya yükselmiş, 2024 yılında 1459.32 ha'ya çıkarak kademeli bir artış eğilimi göstermiştir.

Sonuçlar incelendiğinde, Naive Bayes algoritmasının sınıflandırma sonuçlarında tutarsızlıklar göze çarpmaktadır. Algoritmanın öznitelikler arasındaki bağımsızlık varsayımı, spektral olarak benzer sınıflarda (örneğin yeşil alan, tarım alanı, yerleşim alanı) dalgalanmalara yol açmıştır. Bu nedenle Naive Bayes'in, homojen olmayan kentsel alanlarda sınıflandırma başarısı sınırlı kalmıştır.

KNN algoritması ile elde edilen sonuçlar incelendiğinde, yeşil alan 2018'de 1874.47 ha iken 2021'de 1774.23 ha'ya düşmüş, 2024 yılında ise 1467.98 ha'ya gerilemiştir. Yerleşim alanı 2018'de 3740.73 ha iken 2021'de 5681.99 ha'ya yükselmiş, 2024 yılında ise 4256.24 ha'ya gerilemiştir. Yol sınıfı 2018'de 4488.63 ha iken 2021'de 2784.82 ha'ya düşmüş, 2024 yılında ise 3330.67 ha'ya yükselmiştir. Boş alan 2018'de 8803.69 ha iken 2021'de 10,159.63 ha'ya çıkmış, 2024 yılında ise 9868.31 ha ile yüksek seviyesini korumuştur.

Tarım alanı 2018'de 4466.85 ha iken 2021'de 2365.58 ha'ya ciddi bir düşüş göstermiş, 2024 yılında ise 2969.28 ha ile artışa geçmiştir. Sanayi bölgesi ise sürekli artış göstermiş; 2018'de 917.31 ha iken 2021'de 1525.44 ha'ya, 2024 yılında ise 2399.20 ha'ya kadar yükselmiştir. KNN algoritması, sanayi ve yerleşim alanlarında güçlü performans gösterse de yeşil alan ve tarım alanlarında azalmaların meydana geldiği görülmektedir. Bu durum, algoritmanın komşuluk temelli yapısının spektral benzerlikler karşısında hata payını artırmasından kaynaklanmaktadır. KNN, yüksek veri yoğunluğunda daha istikrarlı sonuçlar

üretmekle birlikte, sınıflar arası geçişlerin fazla olduğu heterojen kentsel alanlarda dalgalı sonuçlar ortaya koyabilmektedir.

Her iki veri oranı sonuçlarına göre, tüm algoritmaların ortak eğilimi incelendiğinde zamansal olarak arazi üzerinde değişmelerin olduğu net bir şekilde görülmektedir. 2018-2024 yılları arasındaki bir süreçte, kullanılan algoritmaların genelinde yeşil alan ve tarım alanı miktarlarında bir azalış tespit edilmiştir. Kentsel yayılma, sanayileşme ve spektral benzerlikten kaynaklı olarak sınıflandırma karışıklıkları bu azalmanın sebebi olabilir. Sanayi ve yerleşim alanlarında 2021 yılında bir artış olduğu görülmektedir. 2024 yılında bazı algoritmalarda düşüş yaşansa bile, uzun vadede bu bölgelerin büyüme eğiliminde olduğu görülmektedir. Yol sınıfında ise dalgalı bir seyir izlendiği gözlemlenmiştir. Boş alan sınıfı ise genelde yüksek seviyelerde kalmayı başarmıştır.

Zamansal analiz sonuçları incelendiğinde, kentsel alanlardaki ve sanayi bölgelerindeki artışın yıllar içerisinde belirgin hale geldiği, doğal alanların ise (yeşil alan, tarım alanı) giderek azaldığı tespit edilmiştir.

4.3. Tartışma

Çalışmada RO, DVM-Lineer, DVM-Polinom, Naive Bayes ve KNN makine öğrenimi algoritmaları kullanılarak, üç farklı yıla ait (2018, 2021, 2024) Sentinel-2A uydu görüntüleri sınıflandırılmıştır. Sınıflandırma sürecinde ilk önce %70 eğitim verisi %30 test verisi kullanılmış, ardından bu oran değiştirilerek %80 eğitim verisi %30 test verisi oranları ile çalışma yapılmıştır. Her iki veri oranları ile elde edilen sonuçlar karşılaştırılarak analiz edilmiştir. Elde edilen bulgulara göre DVM algoritmasının her iki yöntemde de en yüksek genel doğruluk değerine ulaştığı görülmektedir. Örneğin 2024 yılına ait sonuçlarda DVM-Polinom algoritması %93 genel doğruluk, 0.90 kappa değerine sahiptir. Eğitim verisi %80'e çıkarıldığında bu değerler sırasıyla %96, 0.94 olarak bulunmuştur. Benzer şekilde DVM-Lineer algoritması da 2024 yılında %95 genel doğruluk sergilemiştir. Bu değerler Literatürde de vurgulandığı gibi DVM algoritmalarının sınıflandırma çalışmalarında üstün performans göstermesiyle örtüşmektedir.

KNN algoritması yeterli eğitim verisi sağlandığında iyi performans göstermiştir. Eğitim verisi %70'ten %80'e çıkarıldığında, özellikle 2024 yılında yüksek bir genel doğruluğa ulaşmıştır. (%93). Bu artış, algoritmanın bellek tabanlı yöntem ile çalışması nedeniyle veri örnek sayılarına duyarlı olduğunu göstermektedir. Komşuluk tabanlı sınıflandırmaya dayandığı için karar sınırlarını isabetli belirlemiş ve performansını yükseltmiştir. Öte yandan Naive Bayes algoritmasının performansı oldukça düşüktür.

Naive Bayes ile elde edilen sonuçlar hiçbir yılda ve her iki veri oranında da %80'e ulaşamamıştır. Benzer spektral özellik taşıyan sınıflarda ciddi hatalar yapmıştır (tarım alanı, yeşil alan gibi). Bu bulgu, algoritmanın karışık arazi örtüsü sınıflandırma çalışmalarında güvenilir olmadığını gösterir.

Çalışmada kullanılan veri miktarındaki değişiklik, algoritmaların performanslarına etkisi açıkça görülmektedir. Eğitim verisi arttırıldığında, belirgin doğruluk artışı kaydedilmiştir. KNN ve DVM bu durumun bir örneğidir. Örneğin; 2024 yılında, %70 eğitim verisi ile DVM-Polinom algoritmasının genel doğruluk oranı %93 iken, %80 eğitim oranı ile bu değer %96'ya çıkmıştır. KNN algoritmasında ise bu değerler %70 eğitim için %91, %80 eğitim için ise %93 olarak bulunmuştur. RO algoritmasında ise, eğitim verisinin arttırılmasıyla tutarlılık sağlansa da belirgin bir yükseliş görülmemektedir. Bu durum, algoritmanın belli bir veri büyüklüğüne ulaştıktan sonra, hata oranının eğitim verisindeki değişiklikten ziyade sınıf ayrışabilirliğiyle belirlendiğini düşündürmektedir.

Naive Bayes algoritması her iki veri oranları arasındaki fark minimaldir. Bu da algoritmanın performansının oldukça düşük ve ek veri ile bile sınırlı kaldığını göstermektedir. Bu algoritma her bir özneteliği diğerinden bağımsız kabul ederek hesaplamalar yapar. Bu yüzden spektral açıdan birbirine benzeyen sınıflarda ciddi hatalar yapabilmektedir. Bu bağlamda bu algoritmanın karmaşık sınıfların yoğun olduğu bölgelerde tercih edilmemesi gerektiği düşünülmektedir.

Literatür incelendiğinde yapılan bazı çalışmalarda DVM algoritması, diğer algoritmalarla göre yüksek performans sağladığı görülmektedir. Örneğin; Oturanç (2024) yaptığı çalışmada, DVM algoritmasının %89 genel doğruluk oranıyla diğer algoritmalarla üstünlük sağladığını vurgulamıştır. Aynı zamanda Oturanç, NDVI gibi indekslerle sınıflandırma doğruluklarını arttırmayı hedeflemiştir. Aynı şekilde Qian ve arkadaşları 2015 yılında yaptıkları bir çalışmada DVM algoritmasının %92'lik bir genel doğruluk oranıyla yüksek performans sağladığını aktarmışlardır. Ayrıca bu çalışmalarda veri kümelerinin oranları belirtilmemiştir.

Basheer ve arkadaşları (2022) da yaptıkları çalışmada DVM algoritmasının daha bir performans gösterdiğini vurgulamışlardır. Metin (2022) ise üç farklı uydu görüntüsü (Göktürk-2, Sentinel-2 Landsat-8) kullanmış ve Göktürk-2 verileri üzerinden yaptığı çalışmanın sonuçlarına göre, DVM algoritması daha iyi sonuç vermiştir.

Yapılan tez çalışmasında ise, indeksler kullanılmadan hem 80-20 veri oranı hem de 70-30 veri oranı kullanılmış ve DVM algoritmasının, özellikle polinom çekirdek

fonksiyonu algoritması (70-30 veri oranında %93 genel doğruluk, 80-20 veri oranında %96 genel doğruluk), diğer algoritmalara göre başarılı bir sonuç verdiği gözlemlenmiştir. Bu bulgu, literatürde DVM'nin üstünlüğünü desteklemekte ve farklı veri oranlarının da sınıflandırma doğruluğunun başarısı üzerinde önemli bir etkiye sahip olduğunu göstermektedir.

Öte yandan literatüre bakıldığında genellikle RO algoritmasının daha iyi sonuçlar verdiği görülmektedir. Danacioğlu (2023) yaptığı çalışmada Sentinel-2 verisi kullanmış ve en iyi sonucu RO algoritmasının verdiğini belirtmiştir. Ayrıca tek bir tarih (2022), yardımcı indeksler ve tek bir veri oranı kullanarak (70-30) bu sonuca ulaşmıştır. Cui ve arkadaşları Landsat uydu verileri kullanmış ve eğitim örneklerini otomatik olarak üreterek, RO algoritmasının daha iyi performans gösterdiklerini vurgulamışlardır.

Aynı şekilde Shetty (2019) GEE üzerinden yaptığı çalışmada 70-30 veri oranları kullanarak, Landsat uydu verisi üzerinden elde ettiği sonuçlara göre RO algoritması ön plana çıkmıştır. Arpitha ve arkadaşları ise 2015-2021 arası yıllara ait Sentinel-2 uydu verisi üzerinden bir çalışma yürütmüş ve en iyi sonucu veren algoritmanın RO algoritması olduğunu tespit etmişlerdir. Bir başka çalışma olan Talukdar ve arkadaşlarının (2020) yaptıkları çalışmada ise yine Landsat uydusu kullanılmış ve RO algoritmasının performansı daha başarılı olmuştur.

Tez çalışması kapsamında Sentinel-2 verileri kullanılmış ve 70-30 ve 80-20 veri oranları birlikte kullanılmış, sonuçları karşılaştırılmıştır. F1 score, kappa değeri ve genel doğruluk gibi metriklerin analizleri ayrıntılı bir şekilde yapılmıştır. Aynı zamanda yardımcı indeksler kullanılmamıştır. Elde edilen sonuçlara göre DVM algoritması, RO algoritmasını geride bırakmıştır.

Dzullhijjah ve arkadaşları 2025 yılında yaptıkları bir çalışmada %80 eğitim verisi %20 test verisi kullanarak RO algoritmasının daha iyi bir sonuç verdiğini gözlemlemişlerdir. Yapılan bu çalışma orman alanlarında gerçekleştirilmiştir. Tez çalışmamızda ise hem 80-20 hem de 70-30 oranında veri kümeleri birlikte kullanılmış ve karşılaştırmalı analizi yapılmıştır. Ayrıca sınıflandırma çalışması kentsel bölgeler üzerinde yürütülmüştür. Sonuçlara göre DVM algoritmasının başarısı RO'yu geride bırakmıştır. Bu bağlamda kentsel alanlarda DVM algoritmasının kentsel bölgelerde daha avantajlı olabildiği gözlemlenmiştir.

Veri kümelerini %70 eğitim verisi %30 test verisi olarak belirleyen Loukika ve arkadaşları (2021), yaptıkları çalışmada en yüksek sonucu RO algoritmasının verdiğini

vurgulamışlardır. Ayrıca NDVI ve NDWI gibi indeksleri kullanarak sınıflandırma doğruluklarını arttırmayı hedeflemişlerdir. Aynı şekilde Kovarnik ve Janova (2025) da 70-30 veri oranları ile RO algoritmasının daha iyi sonuç verdiğini tespit etmişlerdir. Çalışmamızda ise indeksler yerine B5, B8, B11 bantları kullanılmıştır. 70-30 ve 80-20 veri oranları birlikte kullanılarak elde edilen sonuçlara göre indeksler kullanılmadan da yüksek sonuçlara ulaşabileceğini göstermektedir. Ayrıca eğitim verisi arttırıldığı halde RO algoritması, DVM'ye göre geride kaldığı görülmüştür. Bu durum, marjin temelli çalışan DVM'nin daha etkin karar sınırları oluşturmaya bağlanabilir. Ayrıca küçük veri setlerinde daha kararlı sonuçlar üretmesi bir avantaj sağlamaktadır.

Jamil ve Bayram (2018), UltraCam-X hava kamerası ile DVM, YSA, RO algoritmalarını kullanmıştır. Bu doğrultuda elde edilen verilere göre YSA'nın daha iyi performans gösterdiği tespit edilmiştir. Aynı şekilde Kiraç (2021), yaptığı çalışmada UltraCam-X hava kamerası kullanmış ve YSA algoritmasının daha başarılı olduğunu tespit etmiştir. Tez çalışmamızda ise Sentinel-2 uydu verileri tercih edilmiş ve sadece makine öğrenmesi algoritmaları kullanılmıştır. Sonuçlara göre DVM algoritmasının, özellikle polinom çekirdek fonksiyonunun, daha iyi performans gösterdiği gözlemlenmiştir. Bu durum, veri türü ile algoritma başarısı arasındaki uyumun, sınıflandırma performansını etkilediğini göstermektedir.

Zafer ve ark. (2024) ise, Landsat uydu verileri kullanarak bir çalışma yürütmüşler ve bu çalışmanın sonucunda RO algoritmasının DVM'ye göre daha iyi bir performans gösterdiğini vurgulamışlardır. Buna karşılık tez çalışmamızda Sentinel-2 uydu verileri kullanılmış ve DVM algoritmasının, RO'dan daha iyi sonuçlar verdiği tespit edilmiştir. Bu durum, kullanılan uydu görüntülerinin mekânsal çözünürlüğü ve spektral bant çeşitliliği gibi özelliklerin, sınıflandırma başarısında etkili olduğunu düşündürmektedir.

Tunca ve Köksal ise 2021 yılında bitki türlerinin sınıflandırmasına yönelik yaptıkları çalışmada Sentinel-2 uydu verisi kullanmışlardır. Yapılan çalışmada RO algoritmasının daha başarılı olduğunu vurgulamışlardır. Tek yıl ve tek veri oranı (70-30) odaklı bu çalışmadan farklı olarak, tez çalışmamız üç farklı yıl ve iki farklı veri oranı (70-30 ve 80-20) ve çoklu algoritmalar üzerinden kapsamlı bir araştırma ortaya koymuştur. Sonuçlar ise DVM algoritmasının RO algoritmasına göre daha başarılı olduğu yönündedir.

Yalçın tarafından 2022 yılında gerçekleştirilen çalışmada, Sentinel-2 uydu görüntüleri ile AK/AÖ sınıflandırması yapılmış ve bu kapsamda denetimsiz K-means ve denetimli KNN algoritması kullanılmıştır. Çalışmada 50-50 veri oranı kullanılarak, en

iyi performansı KNN algoritmasının gösterdiği tespit edilmiştir. Tez çalışmasında ise aynı uydu verisi kullanılmış ve KNN'in yanı sıra DVM, RO ve Naive Bayes algoritmaları da kullanılarak, daha kapsamlı bir karşılaştırma ortaya konulmuştur. Ayrıca 70-30 ve 80-20 oranlarının birlikte değerlendirilmesi, üç farklı yılın analizi, F1 score ve kappa gibi metriklerin kullanılması, çalışmamızı Yalçın'ın çalışmasından ayıran unsurlardandır. Bu yönleri ile tez çalışması, yöntemsel çeşitliliği ve zamansal karşılaştırmaları ile literatüre katkı sunmaktadır.

Guizani ve arkadaşları, 2025 yılında yaptıkları çalışmada üç farklı yıla ait uydu görüntüleri ile arazi çalışması yapmışlardır. Veri kümelerini 70-30 olarak tanımlamışlardır. Çalışma kapsamında en yüksek sonucu DVM algoritması vermiştir. Bu çalışmadan farklı olarak tez çalışmamızda, hem 70-30, hem de 80-20 veri oranı birlikte kullanılmıştır. Kullanılan her iki veri oranı sonuçlarına göre DVM algoritması en iyi sonucu vermiştir. Bu bağlamda tez çalışması, literatüre hem çeşitlilik hem de ayrıntılı analiz açısından katkı sağlamaktadır.

Sonuç olarak tez çalışması, tek bir uydu görüntüsünün kullanılması, çok yıllık karşılaştırmalı analizi, arazi üzerindeki zamansal değişim analizi, iki farklı eğitim ve test oranlarının birlikte kullanılarak değerlendirilmesi, NDVI gibi indeksleri kullanmaksızın yüksek sonuçlara ulaşılması, doğruluk analizinde sadece genel doğruluk, üretici doğruluğu değil, bunun yanı sıra kappa katsayısı, F1 score gibi metriklerin de kullanılması literatüre hem uygulama hem de metodolojik olarak katkı sağlamaktadır.

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında 10 m mekânsal çözünürlüğe sahip, ESA tarafından geliştirilen Sentinel-2A uydu görüntüleri üzerinden AK/AÖ sınıflandırma çalışması gerçekleştirilmiştir. Bu doğrultuda makine öğrenmesi algoritmalarından RO, Naive Bayes, KNN ve DVM algoritmaları kullanılmıştır. Çalışma alanı için yeşil alan, yerleşim alanı, boş alan, tarım alanı ve sanayi bölgesi olmak üzere toplam altı sınıf belirlenmiştir. Ayrıca 3 farklı tarihe (2018, 2021 ve 2024) ait uydu görüntüleri üzerinden sınıflandırma işlemi yapılarak, arazi üzerindeki değişimler de analiz edilmiştir.

Uydu görüntüleri GEE platformuna aktarıldıktan sonra, JavaScript kodlama dili ile gerekli kodlar yazılarak, sınıflandırma işlemi yapılmıştır. Sınıflandırma sürecinde toplam 1209 adet piksel elde edilmiştir. İşlem sonucunda temin edilen sonuç görüntüleri ArcGIS programına aktararak, görselleştirme ve haritalama adımları uygulanmıştır.

Çalışma kapsamında kullanılan her bir algoritma hem %70 eğitim verisi - %30 test verisi hem de %80 eğitim verisi - %20 test verisi ile değerlendirilmiştir. Elde edilen bulgulara göre, genel doğruluk ve kappa katsayısı değerleri bakımından en iyi performansı gösteren DVM-Polinom algoritması olmuştur. DVM-Lineer algoritması yüksek sonuç verse de ikinci sırada yer almıştır. RO algoritması, literatürde sıkça yüksek doğruluk oranları ile karşımıza çıksa da, bu çalışmada DVM'nin gerisinde kalmıştır.

KNN ve Naive Bayes algoritmalarının bazı sınıflarda kararsız kalarak, piksel karışıklarına neden olduğu gözlemlenmiştir. Bu doğrultuda, DVM-Polinom algoritması, Sentinel-2A verileri ile gerçekleştirilen AK/AÖ sınıflandırma çalışmalarında en uygun algoritma olarak öne çıkmıştır. Üç farklı yıla ait görüntülerin zamansal olarak karşılaştırılması, arazi üzerindeki değişimleri net bir şekilde ortaya koymuştur. Bu bağlamda, tez çalışması hem yöntemsel hem de zamansal olarak literatüre katkı sağlamaktadır.

Sonuç görselleri (Şekil 4.12 ve Şekil 4.13) incelendiğinde ise bazı bölgelerde karışıklıkların olduğu görülmektedir. Bu sınıf karışıklığının temel nedeni, farklı sınıfların spektral özelliklerinin birbirine oldukça benzer değerlere sahip olmasıdır. Ayrıca Sentinel-2 uydu görüntüsünün 10m mekânsal çözünürlüğü de karışıklığı arttıran bir unsur olarak kabul edilebilir. Dolayısıyla hem spektral yansımaların benzerlikleri hem de mekânsal çözünürlüğün sınırlılığı bu karışıklığa neden olmaktadır.

Sonuç olarak; tez kapsamında yapılan çalışmada, UA verileri ile arazi kullanım değişimlerinin incelenmesi ve izlenmesinde makine öğrenmesi algoritmalarının etkinliğini ortaya koymaktadır. Zamansal analizden elde edilen sonuçlar, çalışma alanında kentsel bölgenin ve sanayi bölgesinin son yıllarda artış gösterdiğini, buna karşılık doğal alanların giderek azaldığını ortaya koymaktadır. Bu sonuçlar, sınıflandırma çalışmasında kullanılan algoritmaların karşılaştırmalı performansını ortaya koymakta ve arazi üzerindeki değişimin nicel olarak değerlendirilmesine katkı sağlamaktadır.

Gelecekteki çalışmalarda, daha fazla sınıf detayı ile daha uzun zaman serileri ile analizler yapılabilir. Derin öğrenme tabanlı yaklaşımlarla geleneksel yöntemler karşılaştırılıp, performanslarda iyileşme sağlanabilir. Özellikle Convolutional Neural Networks (Evrişimli Sinir Ağları-CNN) veya Recurrent Neural Networks (Tekrarlayan Sinir Ağları-RNN) gibi modellerin kullanımı, karmaşık sınıf geçişlerinde iyileşmeler sağlayabilir. Ayrıca farklı veri setlerinin kullanımı (Göktürk-2 gibi) ile sınıflandırma doğruluğunu arttırabilir.

KAYNAKLAR

- Akar, Ö., ve Görmüş, E. T. 2019. Göktürk-2 Ve Hyperion EO-1 Uydu Görüntülerinden Rastgele Orman Sınıflandırıcısı Ve Destek Vektör Makineleri İle Arazi Kullanım Haritalarının Üretilmesi. *Geomatik Dergisi*. DOI: 10.29128/geomatik.476668
- Algancı, U., Coşkun, H. G., Eriş, E., Ağırlioğlu, N., Cıgızoglu, K., Yılmaz, L. ve Toprak, F. 2010. Akım Ölçümleri Olmayan Akarsu Havzalarında Hidroelektrik Potansiyelin Belirlenmesine Yönelik Uzaktan Algılama Ve CBS İle Hidrolojik Modelleme. *Jeodezi ve Jeoinformasyon Dergisi*, (101).
- Algancı, U. Efe, E. 2023. Çok zamanlı Sentinel 2 uydu görüntüleri ve makine öğrenmesi tabanlı algoritmalar ile arazi örtüsü değişiminin belirlenmesi, *Geomatik*, DOI: 10.29128/geomatik.1092838
- Al-Karkhi, M., 2019, Nesne Ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması: Baqubah Şehri Örneği, Yüksek Lisans Tezi, *Fen Bilimler Enstitüsü*, Kayseri.
- Alkan, Ş. 2020. Assessment of Water Quality And Aquatic Diversity of An Open-Pit Gold Mine Area Using Random Forest Algorithm With Google Earth Engine, M.Sc. Thesis, *Graduate School Of Science Engineering And Technology*, İstanbul.
- Arıkan, D., Yıldız, F. 2023, Sentinel-2 Uydu Görüntülerinde Destek Vektör Makinesi ve Rastgele Orman Algoritmaları Kullanılarak Piksel Tabanlı Arazi Sınıflandırması. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*.
- Arpitha, M., Ahmed, S., ve Harishnaika, N. 2023. Land use and land cover classification using machine learning algorithms in google earth engine. *Earth Science Informatics*, DOI: 10.1007/s12145-023-01073-w
- Bakdemir, M. 2024. Python ile Makine Öğrenmesi Algoritmalarını Kullanarak Rüzgar Santralinin Elektrik Üretim Tahmini, Yüksek Lisans Tezi, *Fen Bilimleri Enstitüsü*, Ordu
- Basheer, S., Wang, X., Farooque, A.A., Nawaz, R.A., Liu, K., Adekanmbi, T., Liu, S. 2022. Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing* DOI: 10.3390/rs14194978
- Belgiu, M. ve Dragut, L. 2016 Random forest in remote sensing: A review of applications and future directions, *ISPRS Journal of Photogrammetry and Remote Sensing*, DOI: 10.1016/j.isprsjprs.2016.01.011.
- Bellvert, J. Pamies-Sans, M. Casadesus, J. ve Girona. J. 2025. Evaluating the impact of drought and water restrictions on agricultural production in irrigated areas through crop water productivity functions and a remote sensing-based evapotranspiration model, *Agricultural Water Management*, DOI: 10.1016/j.agwat.2025.109319
- Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, DOI: 10.1016/j.isprsjprs.2009.06.004

- Bozduman, Ş. 2021. Mersin İli Arazi Kullanımı ve Arazi Örtüsü Çalışması için Makine Öğrenmesi ile Görüntü Sınıflandırması, *International Geoinformatics Student Symposium (IGSS)*.
- Breiman L. Random forests. *Machine Learning* 2001. 45(1): 5-32.
- Bulut, S. ve Günlü, A. 2016. Arazi Kullanım Sınıfları İçin Farklı Kontrollü Sınıflandırma Algoritmalarının Karşılaştırılması. *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, DOI: 10.17475/kastorman.289762
- Chipman, J.W., Kiefer R.W., Lillesand T., 2015. Remote Sensing and Interpretation, 7th Edition, Prof. Dr. Kaan Şevki Kavak, Palme Yayın Evi, Ankara
- Cortes, C. 1995. Support-Vector Networks. *Machine learning*.
- Çetin, M. 2020, Göktürk-1 Uydusunun Sınıflandırma Kapasitesinin Alternatif Uydu Görüntü Verileri İle Karşılaştırılması, Yüksek Lisans Tezi, *Fen Bilimler Enstitüsü*, Zonguldak
- Cui, Y., Yang, G., Zhou, Y., Zhao, C., Pan, Y., Gu, X. ve Sun, Q., 2023. AGTML: A novel approach to land cover classification by integrating automatic generation of training samples and machine learning algorithms on Google Earth Engine, *Ecological Indicators*, DOI: 10.1016/j.ecolind.2023.110904
- Çoban, H. O. Gündoğdu, Ş. 2020, Orman alanlarındaki değişimlerin CBS tabanlı belirlenmesi: Çamsu Orman İşletme Şefliği örneği. *Turkish Journal of Forestry*, DOI: 10.18182/tjf.693465
- Çölkesen, İ., 2009, Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması Ve Analizi, Yüksek Lisans Tezi, *Gebze Yüksek Teknoloji Enstitüsü*, Gebze
- Danacıoğlu, Ş. 2023. Arazi Örtüsü/Kullanımı Haritalamasında Farklı Makine Öğrenmesi Algoritmalarının Değerlendirilmesi: İzmir İli Örneği. *Türk Coğrafya Dergisi*, DOI: 10.17211/tcd.1296893
- Demiroz, A., & Yildiz, F. 2021. Investigation of the dynamic behavior of soils of Konya Organized Industrial Zone by equivalent linear analysis method, *Selcuk University Journal of Engineering Sciences*.
- Dong, J., Xiao, X., Menarguez, M. A., Zhang, G., Qin, Y., Thau, D., Moore III, B. 2016. Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine. *Remote Sensing of Environment*, 185, 142-154.
- Dzulhijjah, D.A., Kusrini & Martinez-Bejar, Rodrigo. 2025. Comparative Analysis of Machine Learning Models for Sentinel-2 based Classification of the Bornean Heath Forest, Engineering, *Technology & Applied Science Research*, DOI: 10.48084/etasr.10173

- Erbay, M. 2018. Uzaktan Algılama Teknolojilerinin Arkeoloji Alanında Kullanımı Ve Müze Bilim Alanına Yaptığı Katkıları. *Istanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 17(33), 61-75.
- ESA, 2024. Introducing Sentinel-2 [Ziyaret Tarihi: 21.02.2025], https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2/Introducing_Sentinel-2#:~:text=Sentinel%2D2%20carries%20an%20innovative,provides%20unprecedented%20views%20of%20Earth
- Fang, R. 2023. Application Of Deep Learning To Land Cover Classification: Practical Issues And Strategies, MS Thesis, *Massachusetts Institute of Technology*, Massachusetts.
- Flanagan, D., 2020. JavaScript The DEfinitive Guide, 7th Edition, O'Reilly Media, Sebastopol, CA.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, DOI: 10.1016/j.rse.2017.06.031
- Guizani, D., Tamas, J., Pasztor, D. & Nagy, A. 2025. Refining land cover classification and change detection for urban water management using comparative machine learning approach, *Environmental Challenges*, DOI: 10.1016/j.envc.2025.101118
- Gülçin, D. 2018. Arazi Kullanımlarının Sınıflandırılmasında Piksel Ve Obje Tabanlı Sınıflandırmanın Karşılaştırılması. *Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi*, DOI: 10.25308/aduziraat.423782
- He, K., Dong, J., Ma, H., Cai, Y., Feng, R., Dong, Y. & Wang, L. 2025. Remote Sensing Image Interpretation of Geological Lithology Via a Sensitive Feature Self-Aggregation Deep Fusion Network, *International Journal of Applied Earth Observation and Geoinformation*, DOI: 10.1016/j.jag.2025.104384
- Hosseiny, B., Abdi, A.M., Jamali, S. 2022. Urban land use and land cover classification with interpretable machine learning – A case study using Sentinel-2 and auxiliary Data, *Remote Sensing Applications: Society and Environment*, DOI: 10.1016/j.rsase.2022.100843
- Jamil, A., Bayram, B. 2018. Tree Species Extraction And Land Use/Cover Classification From High-Resolution Digital Orthophoto Maps. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, DOI: 10.1109/JSTARS.2017.2756864.
- Jamil, A., Bayram, B., & Seker, D. Z. 2019. Mapping Hazelnut Trees From High Resolution Digital Orthophoto Maps: A Quantitative Comparison Of An Object And A Pixel Based Approaches. *Feb-Fresenius Environmental Bulletin*, 561.
- Kappas, M. ve Thanh Noi, P., 2017. Comparison Of Random Forest, K-Nearest Neighbor, And Support Vector Machine Classifiers For Land Cover Classification Using Sentinel-2 Imagery. *Sensors*. DOI: 10.3390/s18010018

- Khatami, R. Mountrakis, G. Ve Stehman, S.V., 2016, A Meta-Analysis Of Remote Sensing Research On Supervised Pixel-Based Land-Cover Image Classification Processes: General Guidelines For Practitioners And Future Research, *Remote Sensing Of Environment*. DOI: 10.1016/j.rse.2016.02.028
- Kıbrıs, M.E, 2022. Makine Öğrenimi Ve Uzaktan Algılama Verileri İle Arazi Kullanımındaki Değişikliklerin Analizi: Ankara İli Yenimahalle İlçesi Arazi Kullanımındaki Değişim, DOI: 10.15659/uzalcbs2022.12941
- Kıraç. F., 2021. Arazi Örtüsü Sınıflandırması İçin Makine Öğrenmesi Yaklaşımı, Yüksek Lisans Tezi, *Lisansüstü Eğitim Enstitüsü*, İstanbul
- Kovarnik, R., ve Janova, J. 2025. Validation of sentinel 2 based machine learning models for Czech National Forest Inventory, *Ecological Informatics*, DOI: 10.1016/j.ecoinf.2025.103133
- Landis, J.R. ve KOch, G.G., 1977. An Application of Hierarchical Kappa-Type Statistics in the Assessment of Majority Agreement among Multiple Observers. *Biometrics*. DOI: 10.2307/2529786
- Loukika, K.N., Keesara, V.R. Sridhar, V. 2021. Analysis of Land Use and Land Cover Using Machine Learning Algorithms on Google Earth Engine for Munneru River Basin, India, *Sustainability*, DOI: 10.3390/su132413758
- Lu, D., & Weng, Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International journal of remote sensing*, 28(5), 823-870.
- Makineci, H. B. 2024. Investigation of burned areas with multiplatform remote sensing data on the Rhodes 2023 forest fires. *Ain Shams Engineering Journal*, 15(10), 102949.
- Metlek, S. ve Kayaalp, K. 2020. Makine Öğrenmesinde Teoriden Örnek Matlab Uygulamalarına Kadar Destek Vektör Makineleri, *İksad Yayınevi*, Ankara.
- Metin B., 2022, Göktürk 2 Uydu Verilerinin Arazi Örtüsü Ve Kullanımının Uzaktan Algılama Ve Makine Öğrenmesi Yöntemleri İle Tespitinin Araştırılması, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü
- Norzaee, S., Kermani, M., Ghorbanian, A., Yunesian, M., Shahsavani, A., Farzadkia, M., & Kalantary, R. R. 2024. Spatiotemporal Estimation of Black Carbon Concentration in Tehran Using Aerosol Optical Depth Remote Sensing Data and Meteorological Parameters: Health Risk Assessment and Relationship with Green Spaces. *Sustainable Cities and Society*, 117, 105986.

- Nguyen T.T., Doan T., M., Tomppo., McRoberts R., E., 2020. Land Use/Land Cover Mapping Using Multitemporal Sentinel-2 Imagery and Four Classification Methods-A Case Study From Dak Nong, Vietnam, *Remote Sensing*, DOI: 10.3390/rs12091367
- Oturanç, S. Y., 2025. Uydu Görüntüleri Kullanarak Makine Öğrenme Yöntemleri ile Arazi Kullanımı ve Arazi Örtüsünün Belirlenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* , DOI: 10.35234/fumbd.1469767
- Pahlevan, N., Schott, J. R., ve Zibordi, G. 2017. Sentinel-2 MSI data processing for aquatic science applications. *Remote Sensing of Environment*, DOI: 10.1016/j.rse.2017.08.033
- Phan, T.N., Kuch, V. ve Lehnert, L.W. 2020. Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition, *Remote Sensing*, DOI: 10.3390/rs12152411
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V.R., Murayama, Y. ve Ranagalage, M. 2020. Sentinel-2 Data for Land Cover/Use Mapping: A Review, *Remote Sensing*, DOI: 10.3390/rs12142291
- Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L. 2015. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. *Remote Sensing*, DOI:/10.3390/rs70100153
- Ram, A.K., Yadav, N.K., Kandel, P.N., Mondol, S., Pandav, B., Natarajan, L., Subedi, N., Naha, D., Reddy, C.S., Lamichhane, B.R., 2021. Tracking forest loss and fragmentation between 1930 and 2020 in Asian elephant (*Elephas maximus*) range in Nepal. *Sci. Rep.* DOI: 10.1038/s41598-021-98327-8.
- Richards, J.A. ve Jia, X. 2006. Remote Sensing Digital Image Analysis: An Introduction 4th Edition, Springer-Verlag, Germany, DOI:10.1007/3-540-29711-1
- Sağlam, G. 2024. Kentsel Gelişimin İzlenmesi Amacıyla Optik İnsansız Hava Aracı Görüntülerinin Makine Öğrenme Algoritmalarıyla Sınıflandırılması Üzerine Araştırma, Doktora Tezi, *Fen Bilimler Enstitüsü*, Zonguldak.
- Saylan, İ.H. ve Çömert, R. 2019. Sentinel-2A ürünlerinin yanmış orman alanlarının haritalanmasındaki başarının araştırılması, *Türkiye Uzaktan Algılama Dergisi*, 8–15, 2019.
- Shetty, S. 2019. Analysis Of Machine Learning Classifiers For LULC Classification On Google Earth Engine, Master's Thesis, *University Of Twente*, Hollanda
- Talukdar, S., Singha, P., Mahato, S., Pal, S., Liou, Y. A., & Rahman, A. 2020. Land-use land-cover classification by machine learning classifiers for satellite observations—A review. *Remote sensing*, 12(7), 1135.

- Taşcı, E., & Onan, A. (2016). K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. *Akademik Bilişim*, 1(1), 4-18.
- Tunca, E., ve Köksal, E. S., 2021. Determination of Some Plant Species from Sentinel 2 Satellite Images by Machine Learning. *ÇOMÜ Ziraat Fakültesi Dergisi*, DOI: 10.33202/comuagri.842202
- TÜİK, 2024. [Ziyaret Tarihi: 20.04.2025], <https://data.tuik.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-Sistemi-Sonuclari-2024-53783>
- URL-1, [Ziyaret Tarihi: 25.07.2025], <https://wiki.netcad.com.tr/pages/viewpage.action?pageId=217394092>
- URL-2, [Ziyaret Tarihi: 17.09.2025], <https://veri.mcbu.edu.tr/article-detail/12>
- URL-3, [Ziyaret Tarihi: 20.04.2025], <https://konya.tarimorman.gov.tr/Link/16/E-Kutuphane>
- Üstüner, M., ve Balık Şanlı, F., 2017. LANDSAT-8 Uydu Görüntüsü ile Arazi Örtüsü Sınıflandırmasında Makine Öğrenme Algoritmalarının Kullanımı, 16. *TÜRKİYE HARİTA BİLİMSEL VE TEKNİK KURULTAYI* (ss.1-3).
- Üstüner, M. 2013. Destek Vektör Makineleri Yöntemi İle Arazi Kullanımı Sınıflandırılmasında Kernel Fonksiyonlarına Ait Karşılaştırmalı Parametre Duyarlık Analizi: Rapideye Ve Spot Örneği, Yüksek Lisans Tezi, *Fen Bilimler Enstitüsü*, İstanbul.
- Wang, Q., Shi, W., Li, Z., Atkinson, P.M. 2016. Fusion of sentinel-2 images. *Remote Sensing of Environment*, DOI: 10.1016/j.rse.2016.10.030.
- Wang, L., Wang, J., Qin., F. 2021. Feature Fusion Approach for Temporal Land Use Mapping in Complex Agriculture Areas. *Remote Sensing*, DOI: 10.3390/rs13132517
- Xiong, J., Thenkabail, P. S., Tilton, J. C., Gumma, M. K., Teluguntla, P., Oliphant, A., . . . Gorelick, N. 2017. Nominal 30-m cropland extent map of continental Africa by integrating pixel-based and object-based algorithms using Sentinel-2 and Landsat-8 data on Google Earth Engine. *Remote Sensing*, 9(10), 1065
- Yalçın, D. 2022, Arazi Kullanımı Ve Arazi Örtüsü Sınıflandırmasında Sentinel-2 Görüntülerinin Analizi, Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, Çanakkale
- Yılmaz, O.S., Oruç, M.S., Ateş, A.M., Gülgen, F, 2021. Orman Yangın Şiddetinin Google Earth Engine ve Coğrafi Bilgi Sistemleri Kullanarak Analizi: Hatay-Belen Örneği, *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, DOI: 10.21597/jist.817900

- Yiğit, A., ve Uysal, M. 2019. Afet yönetiminde uzaktan algılamanın kullanımı. In *İdRc 2019 International Disaster & Resilience Congress* (pp. 26-28).
- Yousif, S.R., Shneen, W.F., 2015. Land use/cover change detection of Kufa City, central part of Iraq using remote sensing and GIS techniques. *Theoret. Appl. Sci.* 11, 70–81.
- You, N., Dong, J., Huang, J., Du, G., Zhang, G., He, Y., Yang, T., Di, Y., Xiao, X., 2021. The 10-m crop type maps in Northeast China during 2017–2019. *Sci. Data*, DOI: 10.1038/s41597-021-00827-9
- Zafar, Z., Sajid Mehmood, M., Shiyan, Z., Zubair, M., Sajjad, M., Yaochen, Q., 2023. Fostering deep learning approaches to evaluate the impact of urbanization on vegetation and future prospects. *Ecol. Ind.* DOI: 10.1016/j.ecolind.2022.109788
- Zafar, Z., Zbuair, M., Zha, Y., Fahd, S., Nadeem, A.A. 2024. Performance assessment of machine learning algorithms for mapping of land use/land cover using remote sensing data, *The Egyptian Journal of Remote Sensing and Space Sciences*, DOI: 10.1016/j.ejrs.2024.03.003
- Zhang, H. 2004. The optimality of naive Bayes. *AAAI Conference on Artificial Intelligence*, 1(2), 3–9.
- Zhoe, Z., Islam, F., Waseem, L. 2024. Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification, *Rangeland Ecology & Management*, DOI: 10.1016/j.rama.2023.10.007