YILDIZ TEKNİK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

BİTKİ ÖRTÜSÜ ALANLARINDA MEVSİMSEL ETKİLERİN SENTİNEL-1 SAR VE SENTİNEL-2 OPTİK UYDU GÖRÜNTÜLERİ İLE İZLENMESİ

Ahmet Batuhan POLAT

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı

Danışman

Prof. Dr. Füsun BALIK ŞANLI

Haziran, 2022

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

BİTKİ ÖRTÜSÜ ALANLARINDA MEVSİMSEL ETKİLERİN SENTİNEL-1 SAR VE SENTİNEL-2 OPTİK UYDU GÖRÜNTÜLERİ İLE İZLENMESİ

Ahmet Batuhan POLAT tarafından hazırlanan tez çalışması 22/06/2022 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Füsun BALIK ŞANLI Yıldız Teknik Üniversitesi Danışman

Jüri Üyeleri

Prof. Dr. Füsun BALIK ŞANLI, Danışman Yıldız Teknik Üniversitesi Dr. Öğr. Üye. Uğur ACAR, Üye Yıldız Teknik Üniversitesi

Doç. Dr. Filiz BEKTAŞ BALÇIK, Üye

İstanbul Teknik Üniversitesi

Danışmanım Prof. Dr. Füsun BALIK ŞANLI sorumluluğunda tarafımca hazırlanan Bitki Örtüsü Alanlarında Mevsimsel Etkilerin Sentinel-1 SAR ve Sentinel-2 Optik Uydu Görüntüleri ile İzlenmesi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Ahmet Batuhan POLAT

İmza

Aileme

ve

sevdiklerime

İlk olarak bugün sahip olduğum kişiliği borçlu olduğum, beni bu günlere getiren ve asla haklarını ödeyemeyeceğim aileme; lisans eğitimim ile başlayan birlikteliğimizde akademik hayata başlamak için beni teşvik eden ve her zaman arkamda duran danışmanım Prof. Dr. Füsun BALIK ŞANLI'ya; başladığım akademik hayatımda doğrularımı ve yanlışlarımı bana gösterip daha iyi bir akademisyen olmam için tecrübelerini aktaran Doç. Dr. Özgün AKÇAY'a; bugüne kadar dersime giren ve kendi vizyonları ile beni etkileyen tüm öğretmen ve akademisyenlere; son olarak da ilk günden beri en yakın arkadaşım, sırdaşım, yol arkadaşım olan Ayşe UZUN'a teşekkürü borç bilirim.

Ahmet Batuhan POLAT

| SİMG | E LÍS | resi | vii |
|-------|--------|---|------|
| KISA | LTMA | LİSTESİ | viii |
| ŞEKİ | L LİST | 'ESİ | ix |
| TABL | .0 LİS | TESİ | X |
| ÖZEI | r – | | xi |
| ABST | RACT | | xiii |
| 1 GİR | ŧţş | | 1 |
| 1.1 | Litera | tür Özeti | 1 |
| 1.2 | Tezin | Amacı | 6 |
| 1.3 | Hipote | ez | 7 |
| | | | |
| 2 ÇAI | LIŞMA | ALANI VE VERİ SETİ | 8 |
| 2.1 | Çalışn | na Alanı | |
| 2.2 | Kullar | ulan Veri seti | 9 |
| 3 UY(| GULAN | ИА | 13 |
| 3.1 | Metod | loloji | |
| | 3.1.1 | Veri Ön İşleme | |
| | 3.1.2 | Nesne Tabanlı Sınıflandırma | 14 |
| | 3.1.3 | Görüntü Segmentasyonu | 15 |
| | 3.1.4 | Sınıfların ve Eğitim Verilerinin Belirlenmesi | 17 |
| | 3.1.5 | Sınıflandırma Algoritmaları ve Uygulama Yöntemi | |
| | 3.1.6 | Doğruluk Değerlendirmesi | 19 |
| 3.2 | Bulgu | lar ve Tartışma | |
| | 3.2.1 | Sınıflandırma Sonuçları | |
| | 3.2.2 | Tartışma | |
| | | | |

4 SONUÇ VE ÖNERİLER

37

| 4.1 Sonuç ve Öneriler | |
|---------------------------|----|
| KAYNAKÇA | 39 |
| TEZDEN ÜRETİLMİŞ YAYINLAR | 55 |



κKappa(κ) Katsayısıσ0Sigma Nought



KISALTMA LİSTESİ

| CART | Karar Ağacı Öğrenmesi |
|------|---|
| CNN | Evrişimli Sinir Ağları |
| DD | Düşey-Düşey |
| DVM | Destek Vektör Makineleri |
| DY | Düşey-Yatay |
| ESA | Avrupa Uzay Ajansı |
| EYK | K-En Yakın Komşuluk |
| GB | Gradyent Arttırma |
| GRD | Ground Range Detected |
| LDA | Lineer Diskriminant Analizi |
| LR | Lojistik Regresyon |
| MLP | Çoklu Katman Algılayıcı |
| NDVI | Normalize Edilmiş Fark Bitki Örtüsü İndeksi |
| RO | Rastgele Orman Algoritması |
| SAR | Sentetik Açıklıklı Radar |
| XGB | Ekstrem Gradyent Arttırma |
| YD | Yatay-Düşey |
| YSA | Yapay Sinir Ağları |
| YY | Yatay-Yatay |

ŞEKİL LİSTESİ

| Şekil 2.1 | Çalışma alanı |
|------------|--|
| Şekil 2.2 | Test alanı 12 |
| Şekil 3.1 | Verilerin ön işleme adımları14 |
| Şekil 3.2 | Segmentlere ayrılmış görüntü 16 |
| Şekil 3.3 | Sınıflandırma iş akışı 19 |
| Şekil 3.4 | NDVI eklenmiş birleştirilmiş görüntülerin aylara göre genel doğrulukları 23 |
| Şekil 3.5 | NDVI eklenmemiş birleştirilmiş görüntülerin aylara göre genel doğrulukları 23 |
| Şekil 3.6 | NDVI eklenmiş optik görüntülerin aylara göre genel doğrulukları 23 |
| Şekil 3.7 | NDVI eklenmemiş optik görüntülerin aylara göre genel doğrulukları |
| Şekil 3.8 | SAR görüntülerinin aylara göre genel doğrulukları |
| Şekil 3.9 | a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında DVM yöntemi sonucu elde edilen sınıflandırma görüntüleri |
| Şekil 3.10 | a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında Optik+SAR görüntülerin üç farklı yöntemle sınıflandırılması sonucu elde edilen sonuç görüntüleri 28 |
| Şekil 3.11 | a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında Optik+SAR+NDVI görüntülerin üç farklı yöntemle sınıflandırılması sonucu elde edilen sonuç görüntüleri |
| Şekil 3.12 | a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında Optik+SAR+NDVI görüntülerin test alanında üç farklı yöntemle sınıflandırılması sonucu elde edilen sonuç görüntüleri |
| Şekil 3.13 | Çalışma ve test alanı için elde edilen sınıflandırma doğruluklarındaki farklar (DVM_V, RO_V ve EYK_V doğrulama sınıflandırmalarıdır) |

TABLO LÍSTESÍ

| Tablo 2.1 Sentinel-1 görüntü özellikleri | 10 |
|--|--------------|
| Tablo 2.2 Sentinel-2 görüntü özellikleri | 10 |
| Tablo 2.3 Görüntü alım tarihleri | 11 |
| Tablo 3.1 Parametreler için farklı senaryolarla elde edilen sınıflandırma doğrulukl | arı 16 |
| Tablo 3.2 Görüntülerdeki eğitim örnekleri sayıları | 17 |
| Tablo 3.3 Sınıflandırma genel doğrulukları ve Kappa(κ) değerleri | 20 |
| Tablo 3.4 Arttırılmış eğitim örnekleri | 25 |
| Tablo 3.5 Arttırılmış eğitim örnekleri ile yapılan sınıflandırma genel doğrulukları Kappa(κ) değerleri | ve 25 |
| Tablo 3.6 Test alanında yapılan sınıflandırma genel doğrulukları ve Kappa(κ) değ | erleri 29 |
| Tablo 3.7 Geçmişte yapılan benzer çalışmalardaki sonuçlar ve farklılıklar | 32 |

Bitki Örtüsü Alanlarında Mevsimsel Etkilerin Sentinel-1 SAR ve Sentinel-2 Optik Uydu Görüntüleri ile İzlenmesi

Ahmet Batuhan POLAT

Harita Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Füsun BALIK ŞANLI

Dünyadaki son yılların en büyük tehlikesi, iklim değişikliklerine sebep olan küresel ısınmadır. Küresel ısınmanın yarattığı sonuçlardan birçok doğal kaynak etkilenmektedir. Doğal kaynakların doğru analizi ve zamansal olarak izlenmesi için arazi örtüsü haritalaması için sınıflandırma büyük önem taşımaktadır. Bu çalışmada, bir sene içinde eşit aralıklarla farklı mevsimlerde elde edilen Sentetik Açıklıklı Radar (SAR) ve Optik uydu görüntüleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi için optik ve SAR verilerinin birleştirilmesinin yanı sıra, yalnızca optik ve SAR görüntüleri de ayrı olarak sınıflandırma işlemine tabi tutulmuştur. Böylelikle SAR ve optik görüntülerinin birleştirilmesinin sınıflandırma doğruluğuna olan etkisi incelenmiştir. Ayrıca bir bitki indeksi olan Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI, Normalised Difference Vegetation Index) görüntü verilerine eklenmiş olup bitki örtüsünün yoğun bulunduğu bölge için mevsimsel değişimlere bağlı olarak doğruluğa olan etkisi incelenmiştir. Sınıflandırma için nesne tabanlı yaklaşım kullanılmış olup, üç farklı sınıflandırma algoritması kullanılmıştır. Bunlar Destek Vektör Makineleri (DVM), Rastgele Orman Algoritması (RO) ve K-En Yakın Komşuluk (EYK) algoritmasıdır. Son olarak sınıflandırma için kullanılan eğitim örnekleri sayısı arttırılmış ve doğruluğa olan

etkisi çalışmada ortaya konulmuştur. En düşük genel sınıflandırma doğruluğu, yalnızca SAR görüntüleri kullanılarak yapılan sınıflandırma ile %40.46 olarak elde edilmiştir. En yüksek sınıflandırma doğruluğu ise, SAR ve optik uydu görüntülerinin birleştirilmesi ile elde edilen görüntünün sınıflandırılması sonucu %95.90 olarak bulunmuştur. Ayrıca yapılan sınıflandırmaları doğrulamak için yeni bir test alanında sınıflandırmalar yapılmıştır. Bulunan test sonuçları, ana sınıflandırma sonuçları ile tutarlı olmuştur. Yapılan çalışmada arazi örtüsündeki zamansal değişime bağlı sınıflandırma doğruluğunun kullanılan girdi verileri ile ilişkisi de incelenmiştir. Böylelikle, korunması gereken doğal kaynakların mevsimsel etkileri dikkate alarak yüksek doğruluk ile izlenmesi için ihtiyaç duyulan veri kaynakları ve makine öğrenmesi yöntemleri ortaya konulmuştur.

Anahtar Kelimeler: Sentetik açıklıklı radar, optik görüntü, çoklu-sensör görüntü kombinasyonu, arazi örtüsü değişimi, nesne tabanlı sınıflandırma

YILDIZ TEKNİK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

Monitoring Seasonal Effects in Vegetation Areas with Sentinel-1 SAR and Sentinel-2 Optic Satellite Images

Ahmet Batuhan POLAT

Department of Geomatics Engineering

Master of Engineering Thesis

Supervisor: Prof. Dr. Füsun BALIK ŞANLI

The greatest danger of recent years in the world is global warming that causes climate change. Many natural resources are affected by the consequences of global warming. Classification for land cover mapping is of great importance for accurate analysis and temporal monitoring of natural resources. In this study, the classification process was carried out using four Synthetic Aperture Radar (SAR) and optical satellite images obtained in different seasons at equal intervals within a year. In addition to combining optical and SAR data for classification, single optical and SAR images have been classified separately. Thus, the effect of combining SAR and optical images on classification accuracy was examined. Moreover, the Normalized Difference Vegetation Index (NDVI), which is a plant index, was added to the image data and the seasonal effect on accuracy was examined for the region with dense vegetation. In classification, three different object-oriented classification algorithms Support Vector Machines (SVM), Random Forest Algorithm (RF), and K-Nearest Neighbors algorithm (kNN) were used. Finally, the number of training examples used for classification was increased and its effect on accuracy was revealed in the study. The lowest overall classification accuracy was found to be 40.46% with classification using single SAR images while the highest classification accuracy was found to be 95.90% as a result of the classification of the image obtained by combined SAR and optical satellite images. In this study, the relationship between the classification accuracy due to the temporal change in the land cover and the input data usage was also examined. Furthermore, an additional testing area was considered to validate the method and consistent results were obtained in that area as well. As a result, high accurate monitoring of the natural resources has been discussed taking into account to the data sources, machine learning methods and the seasonal effects.

Keywords: Synthetic aperture radar, optical image, multi-sensor image combination, land cover change, object-based classification



YILDIZ TECHNICAL UNIVERSITY GRADUATE SCHOOL OF SCIENCE AND ENGINEERING

1.1 Literatür Özeti

İstanbul gibi büyük nüfuslu metropol şehirlerde, su ve bitki örtüsü gibi doğal kaynakların korunması ve devamlılığının sağlanması çözülmesi gereken önemli bir sorundur. Bu kaynakların değişiminin izlenmesi ve bu alanda çalışmaların yürütülebilmesi için arazi kullanımı ve arazi örtüsü haritalaması büyük bir etkiye sahiptir. Yeryüzünde meydana gelen değişimler, sürdürülebilir kalkınma ve geçim sistemleri için değerli bilgiler içerip, aynı zamanda yer yüzeyinin biyokimyasal döngüsünün ve atmosferik gazların takibi içinde gerekli olan katkıyı sağlar [1]. Arazi kullanımı ve arazi değişimi dinamik bir olaydır, birçok faktörden zamanla etkilenir [2]. Başlıca kullanım alanlarında tarımsal gelişmeler, kentsel arazi gelişimi, büyük orman tahribatları ve hidrolojik analizler bulunmaktadır [3], [4]. Arazi kullanımının analizi ve değişimi, tarıma ve hidrolojik kullanıma olan etkisinin incelenmesi için tahminler yapılmasını sağlar [5], [6]. Arazi örtüsü değişimi ve kullanımı ile ilgili yapılan farklı çalışmalarda kentsel büyüme ve arazi değişiminin arasındaki ilişki incelenebilir [7].

Uzaktan algılama, aynı bölgeden sık geçmesi ve arazi örtüsüne geniş bir kapsama alanı sağlamasından dolayı arazi kullanımı haritalanmasında çok sık kullanılan bir yöntemdir [8], [9]. Uzaktan algılama aktif ve pasif sistemler olmak üzere ikiye ayrılır. Pasif sistemlerde bulunan optik uydular, algılama yapabilmek için dış bir enerji kaynağına ihtiyaç duyarken aktif sistemlerde bulunan radar uyduları, kendi ürettikleri mikrodalga sinyallerini yeryüzüne yollayarak bu dalgaların geri yansıması sonucu, alıcılarında algılama işlemini gerçekleştirirler. Arazi kullanımı haritalaması için optik ve radar uydularından elde edilen görüntülerle birçok çalışma gerçekleşmiştir. 2012 yılında Hansen ve Loveland, Landsat uydu görüntülerini kullanarak geniş bir alanda arazi örtüsü değişimini göstermiştir [10]. 2016 yılında Topaloğlu ve arkadaşları, Landsat-8 ve Sentinel-2 gibi farklı optik uyduların aynı bölgede doğruluklarının karşılaştırılması yapılmış ve arazi kullanımı haritalamasında kullanılabilirliğini araştırmıştır [11]. Uydu görüntülerinde mekânsal ve zamansal çözünürlüğünün arttığı son yıllarda, Avrupa Uzay Ajansı (ESA)'nın ücretsiz olarak görüntülerini sunduğu Sentinel-1 ve Sentinel-2

uyduları, bu uyduların görüntüleri ile birçok çalışmanın yapılmasına ve literatüre eklenmesine olanak sağlamıştır [12]–[20].

Algılayıcıların farklı spektral ve mekânsal özelliklere sahip olması, görüntü yorumlamayı kolaylaştırmaktadır [21]. Optik ve radar görüntüleri algılanacak nesnenin farklı özelliklerine odaklandığından birlikte kullanılmaları nesne hakkında daha yüksek bilgi çıkarımı yapmamızı sağlar. Optik veriler algılanacak nesnenin kimyasal, fiziksel ve biyolojik özelliklerine daha duyarlıyken, radar verileri ise nesnenin şekil, doku, yapısal ve dielektrik özelliklerine daha duyarlıdır [22]. Görüntü alım polarizasyonları, Sentetik Açıklıklı Radar (SAR) görüntüleri için önemli bir özelliktir. Birçok SAR sistemi, mikrodalga enerjisini yatay (Y) veya düşey (D) polarize olacak şekilde iletmek üzere tasarlanmıştır. Ayrıca dalga boyunun iletiminde YY, YD, DD, DY olmak üzere dört farklı polarizasyon şekliyle geri algılanabilir. SAR sistemleri, radar görüntü ölçümlerinin çok önemli bileşenleri olan bir (tek polarizasyonlu), iki (çift polarizasyonlu) veya dört (tam polarizasyonlu) kombinasyona sahip olabilir. Polarimetrik verilerin arazi kullanımı/örtüsünün tespitinde bilgi çıkarımı için tamamlayıcı bilgiler sağladığını kanıtlayan çalışmalar literatürde bulunmaktadır [23]–[25]. Ayrıca Açıksarı ve Akçay, 2018 yılında yaptığı çalışmada düşey ve yatay polarizasyonun bir arada kullanımının sınıflandırma doğruluğunu arttırdığını gözlemlemiştir [26].

Görüntü birleştirme, iki ya da daha fazla görüntünün tek bir görüntüde birleştirilmesidir. Görüntü birleştirmenin amacı temel olarak farklı görüntülerden alınan ve o görüntülere özgü olan bilgileri birbirleriyle bütünleştirmektir. Görüntü birleştirme işlemi multispektral ve pankromatik görüntülere uygulanıp pan keskinleştirilmiş görüntü elde edilebileceği gibi farklı multispektral ve radar görüntülerine de uygulanıp görüntülerin farklı bilgilerinin birleştirilmesini sağlar. Yapılan önceki çalışmalarda optik ve radar verisinin birleştirildiği verilerin her iki verinin de algılama özelliklerini kullanıp, analiz ve sınıflandırmalarda daha yüksek doğruluklar elde edilmesini sağlamıştır [27]–[29]. Üretilen sonucun doğruluğunun artmasına rağmen, radar ve optik görüntülerin birleştirilmesinin belirli zorlukları vardır. Bu zorlukların temel sebebi iki verideki farklı olan geometrik ve radyometrik özelliklerdir [30].

Çalışmanın amacına göre, bazı zamanlar yalnızca varsayılan bantların sınıflandırmada kullanılması yer yüzeyindeki farklı piksellerin doğru sınıflara atanmamasına sebep olabilir. Bu sınırlandırmanın önüne geçilebilmek için, yer yüzeyinin farklı karakteristik özelliklerinin ayırt edilebilirliği arttırılması amaçlanır. Bu amaçla farklı bant

kombinasyonları matematiksel formüllerle birleştirilir ve indeksler elde edilir. Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), bitki örtüsünün ayırt edilebilirliğini arttırmak için en yaygın şekilde kullanılan yöntemdir [31]. Kırmızı ve Yakın Kızıl Ötesi Bandın birlikte hesaplanmasıyla elde edilmektedir ve sınıflandırmada kullanıldığında doğruluğu arttırdığı çalışmalarda gösterilmiştir [32]–[34]. SAR ve optik verinin, NDVI katmanı ile birleştirilip sınıflandırma doğruluğuna olan etkisi farklı çalışmalarda gösterilmiştir [35]–[38].

Son yirmi yıldır, sınıflandırma için nesne tabanlı yaklaşımlar sıklıkla kullanılmaktadır. Uygulama türüne bağlı olarak nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha başarılı sonuçlar alındığı literatürde belirli çalışmalarla gösterilmiştir [39]–[43]. Bu çalışma kapsamında sınıflandırma yöntemleri olarak geleneksel makine öğrenmesi yöntemleri kullanılmıştır. Makine öğrenmesi, insan zekasını taklit etmek için tasarlanmış ve çevredeki ortamdan öğrenme işlemini gerçekleştiren bir hesaplama algoritmasıdır [44]. Görüntü segmentasyonunu iyileştirmek için, arazideki doğal habitatın potansiyel değişimini tahmin etmek için, arazi kullanımı ve arazi değişimi sınıflandırması gibi uzaktan algılama uygulamalarında makine öğrenmesi yöntemleri sık sık kullanılmaktadır [45]–[48]. Ayrıca taşkın risk analizi, orman yangını haritalaması gibi doğal afet olaylarında da makine öğrenmesi yöntemlerinin kullanılabilirliği yapılan çalışmalarla gösterilmiştir. [49], [50].

Geleneksel makine öğrenmesi yöntemlerini denetimli ve denetimsiz olacak şekilde iki farklı kategoride tanımlamak mümkündür. Uzaktan algılamada kullanılan denetimli makine öğrenmesi yöntemlerine örnek olarak Destek Vektör Makineleri (DVM), Rastgele Orman (RO), K-En Yakın Komşuluk (EYK), Sinir Ağları (NN), Naive Bayes (NB), Yapay Sinir Ağları (YSA) vb. verilebilir [51]–[53]. Uzaktan algılama uygulamalarında kullanılan denetimsiz makine öğrenmesi yöntemlerine ise örnek olarak Temel Bileşen Analizi (TBA), K-Ortalama Modeli, ISODATA, Kümeleme Analizi vb. verilebilir [54]–[56]. Geçmiş yıllarda yapılmış olan ve geleneksel makine öğrenmesi yöntemlerini karşılaştıran çalışmalara bakıldığında, sınıflandırma genel doğruluklarında RO ve DVM'nin diğer yöntemlere göre üstünlüğü göze çarpmaktadır [57]–[60].

Geleneksel makine öğrenme yöntemleri her ne kadar başarılı sonuçlar veriyor gibi gözükse de yüksek performanslı sistemlerin oluşturulabilmesiyle daha yüksek boyutlu veri setlerinde çalışma imkânı bulunmuş ve öğrenme işini daha karmaşık katmanlarla gerçekleştiren derin öğrenme kavramı ortaya çıkmıştır [61]. Derin öğrenme yöntemlerinin gelişmesiyle daha karmaşık modeller görüntüler üzerinde de uygulanmaya başlanmış ve görüntü yükseltmesi, görüntü tanıma, görüntü segmentasyonu, obje çıkarımı gibi farklı spesifik uygulamalarda kullanımı yaygınlaşmıştır [62]–[66]. Uzaktan algılama uygulamalarında olan kullanımlarına baktığımızda ise, yüksek çözünürlüklü uydu görüntülerinin yaygınlaşması ile arazi kullanımı sınıflandırması, bina çıkarımı ve segmentasyonu, vejetasyon haritalaması vb. uygulamalar için yüksek doğrulukta sonuçlar verdiği görülmektedir [67]-[72]. Zhang ve ekibinin (2018) yaptığı çalışmada Evrişimli Sinir Ağları (CNN) yardımıyla sınıflandırma işleminde nesne tabanlı ve piksel tabanlı olacak şekilde sınıflandırmış ve geleneksel DVM ile karşılaştırmıştır. Yapılan karşılaştırma sonucu DVM'nin piksel tabanlı CNN'e karşı bir üstünlüğü söz konusuyken nesne tabanlı CNN karşısında ise daha düşük sonuç almaktadır. Wang vd.'nin 2021 yılında yaptığı çalışmada ise, farklı veri setleri ile DVM ve CNN öğrenme yöntemlerini karşılaştırmıştır. Yapılan sınıflandırmalar sonucunda öğrenme işlemini gerçekleştirmek için büyük data set kullandığında CNN daha yüksek doğruluk verirken, küçük data set kullandığında ise DVM daha yüksek doğruluk vermiştir. Dolayısıyla kullanılacak olan öğrenme yönteminin elde olan veri setine göre değişebilirliğini çalışmasında vurgulamıştır [73]. Farklı derin öğrenme yöntemlerine baktığımızda ise, Abdollahi vd.'nin [74] bu konuda yaptığı tarama çalışmasında tamamen evrişimli ağlar (FCN), çekişmeli üretici ağ (GAN) ve farklı CNN modelleri incelenmiştir. Bu incelemeler sonucu derin öğrenme tekniklerinin yüksek çözünürlüklü farklı uzaktan algılama görüntülerindeki obje çıkarımında birbirlerine göre üstünlükleri analiz edilmiş ve literatüre eklenmiştir.

Literatürdeki konu ile alakalı geçmiş çalışmalara bakıldığında, Liu vd. tarafından 2015 yılında yapılan çalışmada, 1 yıllık periyotta eşit aralıklarla alınan Landsat-8 optik uydu görüntülerinde yalnızca RO yöntemi kullanılarak arazi sınıflandırması yapılmıştır. Elde edilen sonuçlara göre kış sezonunda daha yüksek genel doğruluğa ulaşılmıştır [75]. Çalışmada yalnızca optik görüntüler kullanıldığı için herhangi bir birleştirme etkisinden bahsedemeyiz. Clerici vd. (2017) yaptığı çalışmada ise, arazi örtüsü haritalamasında geleneksel makine öğrenmesi yöntemleri olan DVM, RO ve EYK kullanılarak bir sınıflandırma gerçekleştirilmiştir. Sınıflandırmada sırasıyla SAR,optik ve birleştirilmiş görüntüler kullanıldığı tespit edilmiştir [28]. Çalışma kapsamında arttırılan eğitim örnekleri sayısının ve mevsimsel farklılıkların sınıflandırmaya olan etkisi incelenmemiş yalnızca tek bir tarih

üzerinden sonuçlar elde edilmiştir. Noi ve Kappas (2018), Sentinel-2 optik görüntüsünün performansını DVM, RO ve EYK sınıflandırma yöntemleriyle karşılaştırmış ve en yüksek doğruluğun DVM sınıflandırma yöntemiyle elde edildiğini ortaya koymuştur [76]. Çalışmalarında sadece tek bir tarihe ait görseller kullanılmış, bu nedenle mevsimsel etkilerin sınıflandırmaya etkisi sunulmamıştır. Ayrıca sadece optik görüntüyü kullanmışlar ve SAR verilerinin optik görüntüye olan katkısı analiz edilmemiştir. 2019 yılında Sun vd. tarafından yapılan çalışmada, optik ve radar görüntüleri kullanılarak tarım alanlarındaki ekim ve hasat zamanındaki sınıflandırma farklılıkları geleneksel makine öğrenmesi yöntemleri ile incelenmektedir [77]. Yine aynı çalışmada görüntülere doku, spektral ve indeks bilgileri tanımlandığında sınıflandırmaya yapacakları etki incelenmiş ve sonuç olarak ürünlerin büyüme zamanlarında daha yüksek doğruluklu sınıflandırma sonuçları elde etmişlerdir. En yüksek genel doğruluk RO yöntemi ile radar ve optik görüntülerin birleştirilmesi sonucu oluşan görüntüden elde edilmiştir. Bu çalışma kapsamında eğitim örneklerinin arttırımının sınıflandırmaya olan etkisi incelenmemiştir. Ayrıca yalnızca ekim ve hasat zamanı arasında geçen zamanda alınan görüntüler ile yapılan bir çalışma olması sebebiyle mevsimsel etkilerden tam olarak söz etmek mümkün değildir. Hudait ve Padel'in 2022 yılında yayımladığı çalışmasında ise tarım alanlarının sınıflandırılması için EYK ve RO yöntemlerini karşılaştırmışlar ve birçok farklı tarım ürününe sahip olan bölgede doğru bir sınıflandırma yapmayı hedeflemişlerdir. Sonuç olarak RO yönteminin EYK yöntemine göre daha üstün olduğu vurgulanmıştır [78]. Fakat yapılan çalışmada yalnızca optik görüntülerin kullanımından dolayı radar görüntülerinin sınıflandırmaya olan etkileri incelenememiş, dolayısıyla bu açıdan bir karşılaştırma gerçekleştirilememiştir.

Şu ana kadar anlatılan yöntemler yalnızca geleneksel makine öğrenmesi yöntemlerini kendi aralarında karşılaştırmaktaydı. Jozdani vd. (2019) yaptığı çalışmada ise, derin öğrenme ve makine öğrenmesi yöntemleri ile nesne tabanlı sınıflandırma işlemi yüksekmekânsal çözünürlüklü uydu görüntülerine uygulanmıştır [79]. Farklı derin öğrenme mimarileri ve makine öğrenmesi algoritmaları kullanılan çalışmada, çoklu katman algılayıcı (MLP) modelinin en yüksek doğruluğa ulaştığını tespit etmişlerdir. Fakat DVM, Gradyent Arttırma (GB) ve Ekstrem Gradyent Arttırma (XGB) gibi makine öğrenmesi yöntemleri ile arasında büyük bir sınıflandırma doğruluğu farkı olmadığını belirtmişlerdir. Ayrıca derin öğrenme modeli olan CNN ağları ve nesne tabanlı görüntü analizinin birlikte uygulandığında diğer sınıflandırma yöntemlerine göre bir avantaj sunmadığı ve bu modellerin hala gelişmesi gerektiğini çalışmada vurgulanmıştır. 2021 yılında Adrian vd. tarafından gerçekleştirilen çalışmada ise optik ve SAR görüntülerinin birleştirilmesiyle oluşan birleştirilmiş görüntüyü farklı modellerin oluşturduğu derin öğrenme yöntemleriyle ve geleneksel makine öğrenmesi yöntemi olan RO ile sınıflandırmıştır [80]. Sonuçlara bakıldığında, geleneksel yöntem olan RO'nın bazı modellere göre çok yüksek doğrulukta sonuç verdiğini saptamıştır. En yüksek sonuç derin öğrenme yöntemleri ile elde edilmiş olsa da bu tarz bir uygulama için büyük bir veri seti ve uzun zaman alan sinir ağı eğitimleri gerekmektedir. Ayrıca yapılan çalışmada arazi sınıflandırmasındaki zamansal değişimler vurgulanmamış ve bunların sınıflandırmaya olan etkileri analiz edilmemiştir. 2022 yılında Adagbasa vd. tarafından yapılan çalışmada ise, derin öğrenme yöntemleri ve geleneksel makine öğrenmesi yöntemlerinin vejetasyon bölgelerinin türsel olarak sınıflandırmada başarısını araştırmaktadır [81]. Ayrıca Karar Ağacı Öğrenmesi (CART), Lojistik Regresyon (LR), Lineer Diskriminant Analizi (LDA) gibi farklı makine öğrenmesi yöntemlerini de kullanmışlardır. Radar ve optik görüntülerin bir arada kullanıldığı çalışmada, MLP modeli ile yapılan sınıflandırma en yüksek sonucu vermiştir. Hemen arkasından RO küçük bir fark ile gelmektedir. Bu çalışmada da derin öğrenme yöntemlerinin doğruluğunun gün geçtikçe arttığı vurgulanmış fakat önceki belirtilen çalışmalardaki gibi bu sınıflandırmalar için belli model oluşturma ve sınıflandırma süresi gerektiğinden bahsetmektedir.

1.2 Tezin Amacı

Geçmişte yapılan çalışmalara bakıldığında literatürün belli kısımlarında eksikler bulunmaktadır. Yapılan çalışmalarda ayrı ayrı farklı problemlere odaklansalar da bu çalışma kapsamında yapıldığı gibi ortak belirlenen problemlerin birlikte incelendiği bir uygulama gerçekleştirilmemiştir. Örneğin yüksek oranda vejetasyon alanı içeren bölgelerde bir zaman içerisinde eşit aralıklarla elde edilmiş radar ve optik görüntülerin birleştirilmesiyle mevsimsel bir analiz gerçekleştirilmemiştir. Bazı çalışmalarda mevsimsel değişikliklerin analizinden bahsedilebilirken [75], [76] analizleri yalnızca optik görüntü üzerinden ve tek bir makine öğrenmesi yöntemi kullanarak gerçekleştirmişlerdir. Dolayısıyla farklı makine öğrenmesi yöntemlerini ve SAR görüntülerinin sınıflandırmaya olan etkisini incelememişlerdir.

Bu çalışmanın amacı, bir sene boyunca olabildiğince aynı aralıkta alınan optik ve SAR görüntülerinin birleştirilmesi ile arazi örtüsünün üç farklı sınıflandırma yöntemi ile sınıflandırılması ve mevsimsel değişimlerin bu sınıflandırmalara olan etkilerinin araştırılmasıdır. Ayrıca bitki örtüsünün daha iyi ayırt edilebilmesi için ham olan birleştirilmiş ve optik veriye, NDVI katmanı eklenerek karşılaştırılması amaçlanmıştır. Sınıflandırma için DVM, RO ve EYK yöntemleri ile beraber nesne tabanlı sınıflandırma yaklaşımı kullanılmıştır. Ayrıca çalışmada, eğitim örnekleri olarak belirlenen alanların sayıca artmasının, farklı sınıflandırma yöntemlerine olan etkisi çalışmada ortaya konulmuştur. Böylelikle mevsimsel değişimlerin arazi üzerinde oluşturduğu etkilerin, bitki örtüsünün yoğun olduğu bölgelerde daha doğru haritalama yapılabilmesi için farklı yöntemlerle incelendiği örnek bir çalışma olması amaçlanmıştır.

1.3 Hipotez

SAR ve optik görüntülerinin birbirleri ile uyumu olması için olabildiğince yakın tarihlerde görüntü alınmaya çalışılmıştır. Nesne tabanlı sınıflandırma uygulayabilmek için görüntülerin segmentlere ayrılması gerekmektedir. Bu işlem kapsamında tüm görüntülere segmentasyon işlemi gerçekleştirilmiştir. Farklı geometrik ve radyometrik özelliklere sahip olan SAR ve optik görüntülerinin segmentlere ayrılırken de belirgin farklara sahip olması beklenmektedir. Segmentasyon işlemi gerçekleştikten sonra uygulanacak olan nesne tabanlı sınıflandırma, farklı makine öğrenmesi yöntemleri olan DVM, RO ve EYK ile görüntülere uygulanmıştır. SAR ve optik görüntülerinin birleştirilmesi kapsamında yoğun bitki örtüsünün bulunduğu alanda NDVI bilgisinin bu görüntülere eklenmesinin sınıflandırma doğruluğuna olan etkisi incelenmiştir. Son adım olarak sınıflandırma yöntemlerini uygulayabilmek için görüntülerden elde edilen eğitim veri sayıları arttırılmış ve bu artışın doğruluğa olan etkisi belirlenmiştir. Tez kapsamında yapılan çalışmalar "Yoğun bitki örtüsünün bulunduğu alanlarda, radar ve optik görüntülerinin birleştirilmesi ile elde edilen uydu görüntülerinde uygulanan sınıflandırma işleminde mevsimsel farklılıkların doğruluğa etkisi vardır ve görüntülere ekstra eklenen bitki indeksi ile eğitim verisi sayısının artması doğruluk analizlerinde farklı sonuçlar alınmasını sağlayacaktır." hipotezi üzerine inşa edilmiştir.

2.1 Çalışma Alanı

Çalışma alanı olarak, Türkiye'nin en büyük şehri olan İstanbul'un kuzeyinde bulunan Eyüpsultan ilçesindeki orman, bina ve sulak alanlarını kapsayan bir bölge seçilmiştir. Bölge yaklaşık olarak 682 km²dir. Türkiye'de, İstanbul gibi büyük şehirlerde halihazırda büyük bir nüfus bulunmaktadır. İstanbul'un son sayımlara göre resmi nüfusu 15.5 milyondur [82]. 2011 yılında yapılan çalışmada, 2023 yılına gelindiğinde şehrin nüfusunun 20 milyonu aşacağı öngörülmektedir [83]. Bu şehirlerin sürekli yeni göç almasından dolayı şehirlerde olumsuz gelişmeler yaşanmaktadır [84]. Bu sebeple arazi örtüsünün doğru haritalanması ve şehir planlaması İstanbul gibi büyük şehirler için büyük önem taşımaktadır [85]. Seçilen bölge, %84 oranında vejetasyon alanı içermesiyle birlikte NDVI katman bilgisinin test edilmesine olanak sağlamaktadır. Önceden yapılan çalışmalarda ormanlık alanlarda NDVI bilgisi, yangın olabilecek alanların önceden tespit edilebilmesi ve su stresinin hesabı için kullanılmıştır [86], [87]. Ayrıca bölgedeki su kaynaklarının yıl içinde mevsimsel olarak seviyesinin değişmesi, bölgenin seçilmesi için diğer bir ana unsurdur. Böylelikle mevsimsel değişimlerin arazi üzerindeki değişimi daha net bir sekilde incelenebilmektedir. Kentsel alan ve ormanlık alanın birlikte olduğu bölge, kent içindeki küçük yeşil alanlarında ormanlık alandan ayrı tespit edilebilmesinin test edilmesi için uygun bir bölgedir. Şekil 2.1'de çalışma alanı gösterilmiştir.



Şekil 2.1 Çalışma alanı

2.2 Kullanılan Veri seti

Çalışmada kullanılan optik ve SAR verileri, ESA'nın ücretsiz olarak sağladığı Sentinel-1 SAR ve Sentinel-2 optik uydu görüntüleridir. Son zamanlarda, Sentinel uyduları, yüksek mekansal ve spektral çözünürlükleri nedeniyle sıklıkla kullanılmaktadır. Ayrıca yüksek zamansal çözünürlükleri sayesinde bu uydular aynı bölgeden sık aralıklarla geçerek arazi değişiminin izlenmesini kolaylaştırır [88].

Sentinel-1 uydusu, 2014 yılında yörüngeye fırlatılan bir radar uydusudur. Radar uydularının en büyük avantajı, görüntü alımını gece gündüz gerçekleştirebilmeleri ve atmosferik koşullardan etkilenmemeleridir [89]. Sentinel-1, C-bandına sahip dört farklı görüntüleme modunda, tekli veya çift polarizasyon olacak şekilde SAR görüntülerini görüntülemeyi sağlar [90]. Ayrıca 5 m'ye kadar mekansal çözünürlük, 400 km'ye kadar kapsama alanına sahiptir ve aynı bölgeden kısa süre içerisinde tekrardan geçmektedir [91]. Sentinel-1, kısa sürede aynı bölgeden geçiş yapmasından dolayı, farklı uygulama alanlarında uzun süre gözlem gerektiren bölge analizleri için sık olarak kullanılmaktadır [92]–[94].

Sentinel-2 uydusu, 2014 yılında yörüngeye fırlatılan bir optik uydudur. Sentinel-2, 13 spektral banda sahip multispektral bir uydu sistemidir. Bantların mekansal çözünürlüğü 10 m ile 60 m arasında değişmekle beraber, 290 km'lik bir kapsama alanına sahiptir ve aynı bölgeden kısa süre içerisinde tekrar geçmektedir [91]. Sentinel-2 optik uydusunun, yörüngeye önceki yıllarda fırlatılmış optik uydulara göre avantajı, daha yüksek mekansal çözünürlük sunması ve daha fazla spektral bant aralığına sahip olmasıdır [95]. Tablo 2.1 ve Tablo 2.2'de Sentinel-1 ve Sentinel-2 uydularından alınan görüntülerin teknik özellikleri verilmiştir.

| Yörünge | Alçalan, Yükselen | |
|------------------|--------------------------------|--|
| Görüntüleme Modu | IW | |
| Dalga Boyu | C-Bant (5,4 GHz) | |
| Polarizasyon | Çift (DD,DY) | |
| İşlenen Veri | Level 1(Ground Range Detected) | |

| Tablo 2.1 Sentinel-1 görü | intü özellikleri |
|---------------------------|------------------|
|---------------------------|------------------|

| Bantlar | Merkez Dalga Boyu(nm) | Bant Genişliği(nm) | Mekansal Çözünürlük (m) |
|--|--------------------------|-----------------------|----------------------------|
| Bant 1 – Kıyı Aerosolü | 0.443 | 20 | 60 |
| Bant 2 – Mavi | 0.490 | 65 | 10 |
| Bant 3 – Yeşil | 0.560 | 35 | 10 |
| Bant 4 – Kırmızı | 0.665 | 30 | 10 |
| Bant 5 - Bitki örtüsü kırmızı kenar | 0.705 | 15 | 20 |

Tablo 2.2 Sentinel-2 görüntü özellikleri

| Bant 6 - Bitki örtüsü kırmızı | 0.740 | 15 | 20 |
|-------------------------------|-------|-----|----|
| kenar | | | |
| Bant 7 - Bitki örtüsü kırmızı | 0.783 | 20 | 20 |
| kenar | | | |
| Bant 8 – Yakın Kızılötesi | 0.842 | 115 | 10 |
| (NIR) | | | |
| Bant 8A - Bitki örtüsü | 0.865 | 20 | 20 |
| kırmızı kenar | | | |
| Bant 9 – Su buharı | 0.945 | 20 | 60 |
| Bant 10 – Kısadalga | 1.375 | 30 | 60 |
| Kızılötesi (SWIR)- Sirüs | | | |
| Bant 11 - Kısadalga | 1.610 | 90 | 20 |
| Kızılötesi (SWIR) | | | |
| Bant 12 - Kısadalga | 2.190 | 180 | 20 |
| Kızılötesi (SWIR) | | | |

Çalışmada dört Sentinel-1 SAR ve dört Sentinel-2 optik görüntüsü kullanılmıştır. Görseller mümkün olduğunca eşit mevsimsel aralıklarla ve birbirine en yakın tarihlerde seçilmiştir (Tablo 2.3). Optik verilerde daha doğru sonuç alabilmek için bulut kapsama oranı %5'in altında olan görüntüler seçilmiştir. Ayrıca sınıflandırmaların doğruluklarını test etmek amacıyla çalışma alanı ile benzer arazi özelliklerine sahip yeni bir test alanı seçilmiştir. Kullanılan uydu görüntüleri aynı tarihlerden seçilmiştir. Doğrulama için seçilen yeni test alanı Şekil 2.2'de gösterilmektedir.

| Tablo 2.3 Görüntü alım tarihle | ri |
|--------------------------------|----|
|--------------------------------|----|

| Sentinel-1 SAR Görüntüsü | Sentinel-2 Optik Görüntü |
|--------------------------|--------------------------|
| 3 Şubat 2020 | 2 Şubat 2020 |

| 9 Mayıs 2020 | 9 Mayıs 2020 |
|----------------|----------------|
| 2 Ağustos 2020 | 2 Ağustos 2020 |
| 1 Ekim 2020 | 4 Ekim 2020 |



Şekil 2.2 Test alanı

3.1 Metodoloji

Çalışma için elde edilen görüntülerin sınıflandırılması için nesne tabanlı yaklaşım kullanılmıştır. Görüntülerin ham veri olmasından dolayı sınıflandırmaya tabi tutulmaları için belli işlemlerden geçmeleri gerekmektedir. Buna veri ön işlemesi denir. Daha sonra elde edilen görüntüler, nesne tabanlı yaklaşımla sınıflandırma yapılması için segmentlere ayrılmıştır. Oluşturulan segmentler ile eğitim örnekleri alınmış ve sınıflandırma işlemi gerçekleştirilmiştir.

3.1.1 Veri Ön İşleme

Elde edilen ham optik uydu görüntüleri, atmosfer üstü yansımaların elde edildiği Sentinel-2 Level 1C görüntüleridir. Sınıflandırma işleminde görüntüleri kullanabilmek için optik uydu görüntülerinin atmosfer altı yansımalardan elde edilen Level-2A görüntülerine dönüştürülmesi gerekmektedir. Sentinel-2 optik görüntülerinin atmosferik etkilerini gidermek için, ESA'nın ücretsiz olarak sunduğu SNAP yazılımındaki Sen2Cor modülü kullanılmıştır. Sen2Cor modülü, Level 1C görüntülerini girdi verisi olarak alıp, atmosferik ve arazi düzenlemesini gerçekleştirir ve Level 2A görüntüsü elde edilmesini sağlar [96]. Level 2A görüntüleri elde edildikten sonra, görüntüdeki tüm bantların mekansal çözünürlüğünün aynı olması için yeniden örnekleme işlemi gerçekleştirilmiştir. Bilineer enterpolasyon metodu kullanılarak yapılan yeniden örnekleme işlemi gilemiyle tüm bantların mekansal çözünürlüğü 10 m'ye örneklenmiştir. Elde edilen görüntünün, UTM 35N, WGS84 projeksiyonuna dönüşümü gerçekleştirilmiştir ve son işlem olarak uydu görüntüsünden, sadece çalışmanın yapılacağı alan kesilip, yalnızca sınıflandırma işlemi için kullanılacak bantlar görüntüden alınmıştır.

SAR görüntüleri, Sentinel-1 Ground Range Detected (GRD) görüntüleri olarak elde edilmiştir. İlk olarak DD ve DY polarizasyona sahip görüntülerin yörünge bilgileri güncellenmiştir. Yörünge parametreleri, görüntünün geometrik olarak daha doğru konumlanması için önemlidir. Bu işlemden sonra görüntülerde termal gürültü giderme işlemi gerçekleştirilmiştir. Daha sonra SAR görüntülerinin çerçeve kenarlarında oluşabilen gürültüleri gidermek için kenar gürültü giderme filtresi uygulanmıştır. Ali ve arkadaşları, 2018 yılında çerçeve kenarlarında olan gürültülerin, temiz ve tutarlı bir geri saçılımı engellediğini söylemiştir [97]. Daha sonra görüntü, Sigma Nought (σ 0) kalibrasyonu ile kalibre edilmiştir. SAR görüntülerinde, hedef nesneden geri saçılan mikrodalgaların birbirleriyle karışması sonucu benekler oluşur [98]. Benek etkisinin giderilebilmesi için, Refined Lee metodu kullanılmıştır. Son olarak görüntülerin arazi düzeltmesi işlemi yapılmış ve geometrik olarak konumunun UTM 35N, WGS84 projeksiyonuna dönüşümü gerçekleştirilmiştir. Ayrıca arazi düzeltmesi işlemi yapılırken pikseller yeniden örnekleme metodu ile 10 m'ye örneklenmiştir.

Optik ve SAR görüntüleri bu ön işleme adımlarından sonra kullanıma hazır hale gelmiştir. Son adım olarak veriler birleştirilmiştir. Şekil 3.1'de veri ön işlemesi yapılırken kullanılan iş akışı verilmiştir.



Şekil 3.1 Verilerin ön işleme adımları

3.1.2 Nesne Tabanlı Sınıflandırma

Uzaktan algılamada, ortorektifiye edilmiş bir uydu görüntüsünün kontrollü arazi örtüsü sınıflandırması için en başarılı yöntemlerden biri nesne tabanlı sınıflandırmadır. Sınıflandırma tekniği, dünya yüzeyindeki ayrılabilir nesnelerin tespit edilmesini sağlar ve arazi kullanım değişimi ve arazi örtüsü haritalama çalışmalarında yaygın olarak kullanılır. Bu çalışmada, sınıflandırma işlemleri için pikselleri gruplandırarak bir görüntüdeki segmentleri oluşturan ve bu segmentler aracılığıyla sınıflandırma işlemini gerçekleştiren nesne tabanlı sınıflandırma tekniği uygulanmıştır. Görüntü segmentasyonu, bir görüntüyü mekansal olarak sürekli, ayrık ve homojen bölgelere ayırma işlemidir [99]. Nesne tabanlı görüntüleme, piksel tabanlı görüntülemeye göre görüntüdeki ayrıntı düzeyini azaltır, görüntü karmaşıklığını azaltır ve mekansal ayrıntıların azalmasını sağlar [100]. Ayrıca, oluşturulan nesnelerin sınırlarının gerçek dünyadaki sınırlarına daha çok benzemesi beklenir [101].

3.1.3 Görüntü Segmentasyonu

Nesne tabanlı sınıflandırma gerçekleştirebilmek için, görüntünün öncelikle segmentlere ayrılması gerekir. Baatz ve Schäpe, segmentasyon işlemini, görüntünün yalnızca homojen veya homojene yakın alanlara bölündüğünde anlamlı nesneleri oluşturduğunu söylemiştir [102]. Segmentasyon işlemleri, genel olarak kenar/sınır bazlı ya da alan bazlı olarak gerçekleştirilir [103]. Bir diğer yaygın kullanılan segmentasyon yöntemi ise, piksel tabanlı segmentasyon olan eşik tabanlı(threshold) segmentasyondur [104]. Yapılan çalışmada, nesne tabanlı sınıflandırma uygulaması için eCognition yazılımı kullanılmıştır. Segmentasyon yöntemi olarak çoklu çözünürlük(multi-resolution) yöntemi kullanılmıştır. Çoklu çözünürlük segmentasyon yöntemi alan bazlı bir segmentasyondur. Kavzoğlu ve Tonbul, 2017 yılında yaptıkları çalışmada, çoklu çözünürlük segmentasyon yönteminin, kenar bazlı segmentasyon yöntemine göre daha yüksek doğrulukta sonuç verdiğini göstermiştir [105]. Görüntü segmentasyonundaki temel zorluk, segmentlere ayırmak için kullanılacak olan parametrelerin en uygun şekilde seçilmesidir [106].

Görüntü segmentasyonunda optimal parametrelerin seçimi için 7 farklı senaryoda tek bir sınıflandırma işlemi gerçekleştirilmiştir. Tablo 3.1'de uygun parametrelerin seçimi için uygulanan farklı senaryolar gösterilmiştir. Çalışmada, ölçek parametresi için 80, şekil parametresi için 0.3 ve yoğunluk parametresi için 0.9 değerleri ideal parametreler olarak seçilmiştir. Seçilen parametrelere uygun oluşturulan segmentler, Şekil 3.2'de gösterilmiştir.

| | | | Rastgele Or | rman Yöntemi |
|----------------------|----------------------|-------------------------|--------------------------|--------------|
| Ölçek Parametresi | Şekil Parametresi | Yoğunluk Parametresi | Genel Doğruluk (%) | Карра(к) |
| 40 | 0.3 | 0.9 | 95.40 | 0.916 |
| 80 | 0.3 | 0.9 | 95.90 | 0.925 |
| 120 | 0.3 | 0.9 | 93.06 | 0.873 |
| 80 | 0.1 | 0.9 | 95.22 | 0.912 |
| 80 | 0.3 | 1 | 95.26 | 0.914 |
| 80 | 0.3 | 0.5 | 95.16 | 0.912 |
| 80 | 0.6 | 0.9 | 93 | 0.871 |

 Tablo 3.1 Parametreler için farklı senaryolarla elde edilen sınıflandırma doğrulukları



Şekil 3.2 Segmentlere ayrılmış görüntü

3.1.4 Sınıfların ve Eğitim Verilerinin Belirlenmesi

Çalışma alanı görsel olarak incelendikten sonra orman, kentsel alan, yol, ikincil bitki örtüsü, su alanları ve çıplak toprak olmak üzere altı sınıf arazi örtüsü türü ele alınmıştır. Çalışma alanındaki yoğunluk orman sınıfından oluştuğu için diğer yeşil alanlar ikincil bitki örtüsü sınıfında değerlendirilmiştir. Sınıflandırma için gerekli eğitim örnekleri, segmentler üzerinden mevsimsel olarak toplanmıştır. Tablo 3.2, farklı görüntü veri setlerine dayalı olarak sınıflara ait eğitim örnekleri sayılarını göstermektedir. Tablo 3.2'in yol ve su alanları sütunlarında eğitim örnek sayılarının düşük olmasının sebebi, görüntüler segmentlere ayrılırken su alanları ve yol sınıflarının benzer pikselleri çok olduğu için az sayıda segmentte büyük alanlar olarak segmentasyon işlemi gerçekleşmiştir.

| | Orman | Kentsel Alan | Yol | İkincil Bitki Örtüsü | Su Alanları | Çıplak Toprak | Toplam |
|-------------------|-------|-----------------|-----|----------------------------|----------------|------------------|--------|
| Şubat 2020 | 96 | 27 | 8 | 25 | 7 | 12 | 175 |
| Mayıs 2020 | 84 | 24 | 4 | 11 | 7 | 13 | 143 |
| Ağustos 2020 | 80 | 23 | 8 | 11 | 4 | 15 | 141 |
| Ekim 2020 | 84 | 22 | 8 | 11 | 5 | 16 | 146 |

Tablo 3.2 Görüntülerdeki eğitim örnekleri sayıları

Kullanılan eğitim örneklerinin sayılarının farklılık göstermesinin bir başka sebebi ise, mevsimsel değişikliklere bağlı olarak arazi yapısında meydana gelen değişikliklerdir. Bir görüntüde yeşil alan olan bölge, diğer görüntüde çıplak toprak sınıfına ait olabilmektedir. Eğitim örneklerinin toplanmasından sonra, sınıflandırma adımına geçiş yapılmıştır.

3.1.5 Sınıflandırma Algoritmaları ve Uygulama Yöntemi

Çalışma için uygulanan nesne tabanlı sınıflandırmada kullanılan makine öğrenmesi algoritmaları sırasıyla DVM, RO ve EYK'tur.

Destek Vektör Makineleri, model yapısındaki belirsizliği azaltıp verileri en uygun şekilde birbirlerinden ayırmak için kullanılan denetimli bir öğrenme algoritmasıdır [107]. DVM'nin genel teorisi, farklı sınıflara ait eğitim örneklerini, örneklerin alındığı alanda maksimum marjı olan hiper düzlemi izleyerek ayırmaktır. Bu sebeple az sayıda eğitim örneği mevcut olsa bile yüksek boyutlu verileri işleyebilir [108]. DVM'yi diğer makine öğrenme yaklaşımlarından ayıran temel fark, doğrusal olmayan bir problemi doğrusal probleme dönüştürmek ve eşlemenin karmaşıklığını azaltmak için kernel fonksiyonlarını kullanmaktır [109]–[111].

Rastgele Orman yöntemi, bir dizi parametrik olmayan sınıflandırma ve karar ağaçlarından oluşan sınıflandırma tekniğidir [112]. RO yöntemini uygulamak için, iki parametrenin ayarlanması gerekir. Bunlar kullanılacak olan ağaç sayısı ve her bölünmedeki özelliklerin sayısıdır [113]. Karar ağacının eğitimi için, eğitim örneklerinin içinde tanımlanan özelliklere ait rastgele alt kümeler oluşturur. Yöntemin mantığı, oluşturulan ormanda bulunan her ağaç, her girdi verisini en uygun sınıfa atayacak olan oyu verir [114]. Liaw ve Wiener, kullanılacak olan ağaç sayısının artmasının, daha doğru sonuçlar vereceğini öne sürmüştür [115]. Son on yıl içerisinde birçok farklı uzaktan algılama uygulaması için RO yönteminin kullanıldığı literatürde gösterilmiştir [116]–[118].

En Yakın Komşuluk, ilk olarak 1967 yılında Cover ve Hart tarafından literatüre sunulmuştur [119]. Bir denetimli öğrenme metodu olan EYK, regresyon ve sınıflandırma için kullanılır. EYK yönteminin çalışma prensibi, bir k değişkeni için belirlenen değere göre hedef noktanın en yakın sınıflandırılmış noktalarına olan öklid mesafesini hesaplar ve en kısa mesafede olan komşu noktanın sınıfına atama yapılır [120], [121].

Yukarıda tanımlanan üç algoritmaya göre, 2020 yılı Şubat, Mayıs, Ağustos ve Ekim aylarında alınan görüntüler sınıflandırılmıştır. NDVI, verilerin ön işleme adımları tamamlandıktan sonra katman olarak optik ve birleştirilmiş veriye eklenmiştir. NDVI, bitki örtüsünün geçmişini, anlık gelişimini ve gelecekteki durumunun öngörülebilmesi için kullanılan güçlü bir analiz aracıdır [122]. Ayrıca, arazideki farklı bitki türlerinin birbirlerinden ayırt edilebilmeleri için kullanılabildikleri yapılan önceki çalışmalarda gösterilmiştir [123], [124]. NDVI hesaplamak için kullanılan bant formülleri şu şekilde verilebilir (3.1);

(3.1)

Her mevsimsel dönem için optik, SAR ve NDVI bilgisinin beş farklı kombinasyonu kullanılarak üç farklı sınıflandırma yöntemiyle sınıflandırma işlemi gerçekleştirilmiştir. Şekil 3.3'te sınıflandırılan veri setlerinin iş akışları gösterilmiştir.



Şekil 3.3 Sınıflandırma iş akışı

Eğitim örnek sayısının arttırılmasının sınıflandırma algoritmalarının üzerindeki etkisini incelemek için, tüm veriler üzerinde eğitim sayıları arttırılmış ve arttırılmış olan eğitim örnekleri ile yalnızca birleştirilmiş görüntüler için sınıflandırma işlemi uygulanmıştır.

3.1.6 Doğruluk Değerlendirmesi

Arazi değişiminin doğruluk değerlendirilmesinin yapılması, yalnızca sınıflandırma doğruluğunu değil sınıfların alan temsillerinin de analiz edilebilmesi için yapılması gereken bir işlemdir [125]. Sınıflandırma doğruluklarını analiz etmek için en sık kullanılan metrikler Genel Doğruluk, Kappa Katsayısı (κ), Kullanıcı Doğruluğu ve Üretici Doğruluğudur [126], [127]. Bu metrikler sınıflandırma sonucu her sınıfa atanan piksellerin birbirlerine göre oranlarına göre hesaplanmaktadır. Hata matrisi, hedef sınıflandırma sonucu oluşan görüntüde atanan tahmini piksellerin ve gerçek piksellerin oluşturduğu bir matristir. Genel doğruluk, diagonal hata matrisindeki doğru sınıfa atanınış olan piksel sayılarının toplam piksel sayısına bölünmesiyle elde edilir. Genel doğruluk ve κ elde etmek için gerekli formüller aşağıdaki gibidir (3.1),(3.2);

Genel Doğruluk =
$$\frac{\sum_{i=1,n} x_{ii}}{\sum_{i=1,n} \sum_{j=1,n} x_{ij}}$$
 (3.1)

$$\kappa = \frac{N\sum_{i=1}^{r} x_{ii} - \sum_{i=1}^{r} (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^{r} (x_{i+} * x_{+i})}$$
(3.2)

n sınıf sayısı, *i* sınıf numarası. Ayrıca, *N* toplam sınıflandırılmış piksel sayısıdır. Son olarak, x_{i+} ve x_{+i} sırasıyla *i*th satır ve sütunun tahmin edilen ve referans kabul edilen pikselleridir.

Bu çalışma kapsamında, genel doğruluk ve κ değerleri hesaplanmış olup sonuçlarda bu değerler analiz edilmiştir. Giriş kısmında verilen çalışmalara bakıldığında, doğruluk analizleri için bu çalışmalarda genel doğruluk ve κ değerleri kullanıldığı görülmektedir [28], [76]–[78]. Kullanılan her ayrı veri seti için eğitim örnekleri sabit tutulmuş olup örnek sayıları üzerinde yapılan bir değişikliğin doğruluk değerlerini etkilememesine dikkat edilmiştir. Çalışmanın ilk kısmı için 60 sınıflandırma ve sonucunda doğruluk analizi gerçekleştirilmiştir. İkinci kısmında ise eğitim örnek sayıları arttırılarak 12 ekstra sınıflandırma ve doğruluk analizi gerçekleştirilmiştir. Ayrıca test alanı için 24 ekstra sınıflandırma yapılarak çalışmanın güvenilirliği incelenmiştir.

3.2 Bulgular ve Tartışma

3.2.1 Sınıflandırma Sonuçları

Tüm veri setleri için elde edilen sınıflandırma sonuçları, doğruluk kriterleri olan Genel Doğruluk ve Kappa(κ) Değeri olarak Tablo 3.3'de gösterilmiştir.

| | Destek Vektör Makineleri | | Rastgele C | Irman | K-En Yakın Komşuluk | | |
|--------------------|-----------------------------|--------------------|-----------------------|--------------------|--------------------------|--------------------|--|
| Şubat 2020 | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Карра(к) Değeri | |
| SAR Görüntüsü | 54.16 | 0.033 | 81.66 | 0.734 | 84.93 | 0.773 | |
| Optik Görüntü | 89.18 | 0.837 | 88.10 | 0.824 | 93.09 | 0.896 | |
| Optik+NDVI Görüntü | 87.90 | 0.816 | 88.71 | 0.835 | 93.09 | 0.896 | |
| Optik+SAR Görüntü | 92.87 | 0.892 | 91.92 | 0.879 | 95.12 | 0.926 | |

Tablo 3.3 Sınıflandırma genel doğrulukları ve Kappa(κ) değerleri

| Optik+SAR+NDVI Görüntü | 91.29 | 0.869 | 95.90 | 0.924 | 95.12 | 0.926 |
|--|--|--------------------------------------|---|--|--|--------------------------------------|
| | Destek | Vektör | Rastgele O | rman | K-En Yakın | Komşuluk |
| | Maki | neleri | | | | |
| | Genel | Карра(к) | Genel | Карра(к) | Genel | Карра(к) |
| Mavıs 2020 | Doğruluk | Değeri | Doğruluk (%) | Değeri | Doğruluk | Değeri |
| | (%) | | | | (%) | |
| SAR Görüntüsü | 59.58 | 0.032 | 82.83 | 0.722 | 82.47 | 0.706 |
| Optik Görüntü | 88.96 | 0.822 | 90.47 | 0.843 | 89.34 | 0.822 |
| Optik+NDVI Görüntü | 93.57 | 0.892 | 91.18 | 0.855 | 89.34 | 0.822 |
| Optik+SAR Görüntü | 94.49 | 0.907 | 93.62 | 0.894 | 89.42 | 0.821 |
| Optik+SAR+NDVI | 93.87 | 0.897 | 93.09 | 0.885 | 89.42 | 0.821 |
| Görüntü | | | | | | |
| | Destek | Vektör | Rastgele O | rman | K-En Yakın | Komşuluk |
| | Maki | neleri | | | | |
| | Genel | Карра(к) | Genel | Карра(к) | Genel | Карра(к) |
| Ağustos 2020 | | | | | | |
| Ağustos 2020 | Doğruluk | Değeri | Doğruluk (%) | Değeri | Doğruluk | Değeri |
| | Doğruluk (%) | Değeri | Doğruluk (%) | Değeri | Doğruluk (%) | Değeri |
| SAR Görüntüsü | Doğruluk (%) 61.11 | Değeri 0.037 | Doğruluk (%) 85.91 | Değeri 0.752 | Doğruluk (%) 83.46 | Değeri 0.712 |
| SAR Görüntüsü Optik Görüntü | Doğruluk (%) 61.11 94.32 | Değeri 0.037 0.903 | Doğruluk (%) 85.91 88.95 | Değeri 0.752 0.811 | Doğruluk (%) 83.46 87.01 | Değeri 0.712 0.862 |
| SAR Görüntüsü Optik Görüntü Optik+NDVI Görüntü | Doğruluk (%) 61.11 94.32 94.20 | Değeri 0.037 0.903 0.901 | Doğruluk (%) 85.91 88.95 87.51 | Değeri 0.752 0.811 0.789 | Doğruluk (%) 83.46 87.01 | Değeri 0.712 0.862 0.862 |
| SAR Görüntüsü Optik Görüntü Optik+NDVI Görüntü Optik+SAR Görüntü | Doğruluk (%) 61.11 94.32 94.20 94.46 | Değeri 0.037 0.903 0.901 0.906 | Doğruluk (%) 85.91 88.95 87.51 94.74 | Değeri 0.752 0.811 0.789 0.910 | Doğruluk (%) 83.46 87.01 87.01 89.18 | Değeri 0.712 0.862 0.862 0.802 |
| SAR Görüntüsü Optik Görüntü Optik+NDVI Görüntü Optik+SAR Görüntü Optik+SAR+NDVI Görüntü | Doğruluk (%) 61.11 94.32 94.20 94.46 94.78 | Değeri 0.037 0.903 0.901 0.906 0.911 | Doğruluk (%) 85.91 88.95 87.51 94.74 94.11 | Değeri 0.752 0.811 0.789 0.910 0.900 | Doğruluk (%) 83.46 87.01 87.01 89.18 89.18 | Değeri 0.712 0.862 0.862 0.802 0.802 |

| | Destek Vektör Makineleri | | Rastgele Orman | | K-En Yakın Komşuluk | |
|---------------------------|-----------------------------|--------------------|-----------------------|--------------------|--------------------------|--------------------|
| Ekim 2020 | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri |
| SAR Görüntüsü | 40.46 | 0.013 | 78.98 | 0.711 | 79.51 | 0.716 |
| Optik Görüntü | 92.85 | 0.902 | 85.61 | 0.806 | 88.60 | 0.843 |
| Optik+NDVI Görüntü | 92.90 | 0.897 | 87.58 | 0.831 | 88.60 | 0.843 |
| Optik+SAR Görüntü | 93.22 | 0.903 | 93.70 | 0.909 | 89.11 | 0.843 |
| Optik+SAR+NDVI Görüntü | 94.67 | 0.923 | 93.55 | 0.907 | 89.11 | 0.843 |

Sınıflandırma sonuçlarına baktığımızda, ekim, ağustos ve mayıs ayları için en yüksek doğruluk veren sınıflandırma algoritmasının DVM olduğu görülmüştür. Yalnızca şubat ayında EYK yönteminin diğer sınıflandırma algoritmalarına göre daha yüksek doğrulukta sınıflandırma yaptığı incelenmiştir. Tüm sınıflandırmalar arasında en yüksek doğruluk %95.90 ile şubat ayı için yapılan ve NDVI bilgisi dahil olan birleştirilmiş görüntüde elde edilmiştir. En düşük doğruluk oranlarının dört ay içinde yalnızca SAR verisi kullanılarak yapılan sınıflandırmalardan elde edildiği görülmüştür. En düşük genel doğruluk %40.46 ile ekim ayı için yapılan SAR görüntüsünde DVM algoritması uygulandığında elde edilmiştir.

Elde edilen genel doğrulukların daha anlaşılır olması için grafik olarak gösterimi Şekil 3.4-3.9 arasında verilmiştir.



Şekil 3.4 NDVI eklenmiş birleştirilmiş görüntülerin aylara göre genel doğrulukları



Şekil 3.5 NDVI eklenmemiş birleştirilmiş görüntülerin aylara göre genel doğrulukları





Şekil 3.6 NDVI eklenmiş optik görüntülerin aylara göre genel doğrulukları

Şekil 3.7 NDVI eklenmemiş optik görüntülerin aylara göre genel doğrulukları



Şekil 3.8 SAR görüntülerinin aylara göre genel doğrulukları

Verilen şekillere göre, EYK yöntemi için tüm aylarda en yüksek doğruluk şubat ayında elde edilirken, DVM için yaz ve bahar aylarında daha yüksek genel doğruluklar elde edilmiştir. RO algoritması ise, zamansal veri setlerine bağlı olarak DVM ve EYK yöntemleri ile benzer sonuçlar üremesinden dolayı tutarsız olarak gözlemlenmiştir.

Çalışmanın son adımı olarak, eğitim örnek sayısının arttırılmasının sınıflandırma doğruluğuna olan etkisini incelemek için görüntülerden alınan eğitim örnek sayıları arttırılmıştır. Her arazi kullanımı sınıfı için arttırılan eğitim örnek sayısı Tablo 3.4'de verilmiştir.

| Eğitim Örnekleri (Arttırılmış) | Orman | Kentsel Alan | Yol | İkincil Bitki Örtüsü | Su Alanları | Çıplak Toprak | Toplam |
|-----------------------------------|-------|-----------------|-----|-------------------------|----------------|------------------|--------|
| Şubat 2020 | 104 | 30 | 8 | 28 | 7 | 12 | 189 |
| Mayıs 2020 | 117 | 28 | 4 | 12 | 7 | 14 | 182 |
| Ağustos 2020 | 89 | 28 | 10 | 15 | 5 | 16 | 163 |
| Ekim 2020 | 115 | 29 | 10 | 14 | 5 | 26 | 199 |

Tablo 3.4 Arttırılmış eğitim örnekleri

Arttırılan eğitim örnek sayılarının sınıflandırma genel doğruluğuna olan etkisi Tablo 3.5'te gösterilmiştir.

Tablo 3.5 Arttırılmış eğitim örnekleri ile yapılan sınıflandırma genel doğrulukları veKappa(κ) değerleri

| | Destek Makin | Destek Vektör Makineleri | | Rastgele Orman | | K-En Yakın Komşuluk | |
|---|--------------------------|-----------------------------|--------------------------|--------------------|--------------------------|---------------------|--|
| Şubat 2020 (Arttırılmış Eğitim Örnekleri) | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | |
| Optik+SAR+NDVI Görüntü | 94.73 | 0.904 | 96.65 | 0.939 | 96.57 | 0.937 | |
| | Destek Makin | Vektör neleri | Rastgele | Orman | K-En Yakın | Komşuluk | |
| Mayıs 2020 (Arttırılmış Eğitim Örnekleri) | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(ĸ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | |
| Optik+SAR+NDVI Görüntü | 94.15 | 0.901 | 93.55 | 0.892 | 89.03 | 0.814 | |

| | Destek Makin | Vektör neleri | Rastgele Orman | | K-En Yakın Komşuluk | |
|---|-----------------------------|--------------------|--------------------------|--------------------|--------------------------|--------------------|
| Ağustos 2020 (Arttırılmış Eğitim Örnekleri) | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(ĸ) Değeri |
| Optik+SAR+NDVI Görüntü | 95.63 | 0.925 | 95.05 | 0.916 | 90.53 | 0.838 |
| | Destek Vektör Makineleri | | Rastgele Orman | | K-En Yakın Komşuluk | |
| | | | | | | |
| Ekim 2020 (Arttırılmış Eğitim Örnekleri) | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri |

Arttırılmış eğitim örnekleri ile yapılan sınıflandırmalar sonucu, sınıflandırma genel doğruluklarında daha yüksek sonuçlar elde edilmiştir.



Şekil 3.9'da DVM yöntemi ile sınıflandırılmış tüm görüntüler yer almaktadır.

Şekil 3.9 a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında DVM yöntemi sonucu elde edilen sınıflandırma görüntüleri

Şekil 3.9'da gösterildiği gibi, nesne tabanlı sınıflandırma uygularken yalnızca SAR görüntülerini kullanmak dikkate değer sonuçlar vermemektedir. Tablo 3.2'deki sonuçlar göz önünde bulundurulduğunda, SAR görüntülerini sınıflandırırken DVM yöntemi diğer yöntemlere göre oldukça düşük doğruluklu sonuçlar üretmektedir. Ayrıca aynı şekilde,

ikincil bitki örtüsündeki şubat-mayıs arasındaki değişim kolaylıkla tespit edilebilmektedir.

Şekil 3.10 ve Şekil 3.11'de sırasıyla Optik+SAR ve Optik+SAR+NDVI görüntülerinin sınıflandırılması sonucu oluşan sonuç görüntüler gösterilmiştir.



Şekil 3.10 a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında Optik+SAR görüntülerin üç farklı yöntemle sınıflandırılması sonucu elde edilen sonuç görüntüleri





Yapılan sınıflandırmaları doğrulamak için Şekil 2.2'de verilen test alanında 24 yeni sınıflandırma gerçekleştirilmiştir. Bu aşamada, önceki sonuçlar dikkate alınarak yalnızca Optik+NDVI ve Optik+SAR+NDVI görüntüler sınıflandırmaya tabi tutulmuştur. Sınıflandırma sonuçları Tablo 3.6'da verilmiştir. Elde edilen yeni sonuçlara bakıldığında, test alanında yapılan sınıflandırmalar Tablo 3.3'te bulunan önceki sınıflandırmalar ile tutarlıdır. Bu da çalışmanın güvenilirliğini büyük ölçüde kanıtlamaktadır. Şekil 3.12 test alanında yapılan sınıflandırmalar sonucu oluşan arazi kullanımı haritalarını göstermektedir.

Tablo 3.6 Test alanında yapılan sınıflandırma genel doğrulukları ve Kappa(κ) değerleri

| | Destek Vektör Makineleri | | Rastgele Orman | | K-En Yakın Komşuluk | |
|---------------------------|-----------------------------|--------------------|-----------------------|--------------------|--------------------------|--------------------|
| Şubat 2020 | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri |
| Optik+NDVI Görüntü | 87.34 | 0.807 | 86.26 | 0.792 | 90.86 | 0.859 |
| Optik+SAR+NDVI Görüntü | 93.90 | 0.898 | 95.88 | 0.932 | 95.22 | 0.919 |
| | Destek Vektör Makineleri | | Rastgele Orman | | K-En Yakın Komşuluk | |
| Mayıs 2020 | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri |
| Optik+NDVI Görüntü | 95.19 | 0.933 | 94.39 | 0.922 | 92.96 | 0.902 |
| Optik+SAR+NDVI Görüntü | 96.77 | 0.955 | 94.14 | 0.918 | 93.31 | 0.907 |
| | Destek Maki | Vektör neleri | Rastgele O | Prman | K-En Yakın | Komşuluk |
| Ağustos 2020 | Genel Doğruluk (%) | Карра(к) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Карра(к) Değeri |
| Optik+NDVI Görüntü | 93.80 | 0.917 | 94.19 | 0.922 | 94.05 | 0.920 |
| Optik+SAR+NDVI Görüntü | 97.95 | 0.969 | 96.14 | 0.941 | 96.03 | 0.939 |

| | Destek Vektör Makineleri | | Rastgele Orman | | K-En Yakın Komşuluk | |
|---------------------------|-----------------------------|--------------------|-----------------------|--------------------|--------------------------|--------------------|
| Ekim 2020 | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(κ) Değeri | Genel Doğruluk (%) | Kappa(ĸ) Değeri |
| Optik+NDVI Görüntü | 96.02 | 0.935 | 94.50 | 0.910 | 95.30 | 0.922 |
| Optik+SAR+NDVI Görüntü | 98.57 | 0.976 | 97.58 | 0.959 | 96 | 0.933 |



Şekil 3.12 a)Şubat b)Mayıs c)Ağustos d)Ekim aylarında Optik+SAR+NDVI görüntülerin test alanında üç farklı yöntemle sınıflandırılması sonucu elde edilen sonuç görüntüleri

3.2.2 Tartışma

Çalışmanın güvenilirliği için yapılan 103 farklı sınıflandırma işlemi sonucunda belli genellemelere varılabilmiştir. Bu sınıflandırmalar kapsamında segmentasyon parametreleri belirlenmesi için 7, ana arazi sınıflandırması için 60, arttırılmış eğitim örneklerinin etkisini incelemek için 12 ve son olarak yapılan sınıflandırmaları test etmek amacıyla 24 farklı sınıflandırma yapılmıştır. Tüm görüntü veri setleri ele alındığında, Optik+SAR görüntülerinin daha yüksek genel doğrulukla sınıflandırıldığı sonucuna varılmıştır. Birleştirilmiş görüntüler için, optik görüntülere oranla %1.97lik bir ortalama doğruluk değeri artışı olmuştur. Ayrıca, sınıflandırma yöntemlerini karşılaştırdığımızda DVM yöntemi ile sınıflandırılan görüntülerde daha yüksek bir genel doğruluk elde ettiği gözlemlenmiştir. Yalnızca SAR görüntülerinin kullanılması, nesne tabanlı sınıflandırma için çok düşük seviyede genel doğruluğa sahip olmasına neden olduğu için yapılan ortalama doğruluk hesabına katılmamıştır. Tablo 3.7'de yapılan çalışma ile karşılaştırma yapabilmek amacıyla geçmişte yapılan benzer çalışmalar ele alınmıştır ve bu çalışmaların yapılan çalışmaya göre farklı yönleri irdelenmiştir.

| | Mevsimsel izleme | Veri seti | Arttırılmış örnek | Sınıflandırma yöntemi | Doğruluk |
|-------------------------------|---------------------|----------------|----------------------|--------------------------|---|
| Bu çalışma | 1 yıl boyunca | Optik+SAR+NDVI | Evet | DVM, RO, EYK | %95.90 RO yöntemi ile ana sınıflandırmada elde edilen en yüksek doğruluk, %96.65 RO yöntemi ile arttırılmış örnekler ile elde edilen en yüksek doğruluk |
| Liu vd., (2015)[75] | 1 yıl boyunca | Optical+NDVI | - | RO | %85.5 en yüksek doğruluk |
| Clerici vd., (2017)[28] | - | Optik+SAR+NDVI | - | DVM, RO, EYK | %88.75 DVM ile elde edilen en yüksek doğruluk |

Tablo 3.7 Geçmişte yapılan benzer çalışmalardaki sonuçlar ve farklılıklar

| Noi & Kappas, (2018)[76] | - | Optik görüntü | Evet | DVM, RO, EYK | %95.32 arttırılmış örnekler ile DVM yöntemi kullanılarak elde edilen en yüksek doğruluk |
|----------------------------------|-------------------------------------|----------------|------|---|---|
| Sun vd., (2019)[77] | Ekim ve hasat zamanı arasında | Optik+SAR+NDVI | - | DVM, RO, YSA | %93 RO yöntemiyle elde edilen en yüksek doğruluk |
| Hudait & Patel, (2022)[78] | | Optik+NDVI | | RO ve EYK | %97.22 RO yöntemiyle elde edilen en yüksek doğruluk |
| Jozdani vd., (2019)[79] | | Optik görüntü | | DVM, RO, GB, XGB, MLP, CNN | %96.55 MLP yöntemi ile elde edilen en yüksek doğruluk |
| Adrian vd., (2021)[80] | | Optik+SAR+NDVI | | RO, SegNet, U- Net, 3D U-Net | %99.2 3D U-Net modeli ile elde edilen en yüksek doğruluk |
| Adagbasa vd., (2022)[81] | - | Optik+NDVI | - | DVM, RO, EYK, LR, LDA, CART, MLP | %92 MLP yöntemi ile elde edilen en yüksek doğruluk |

Elde edilen bu sonuçlar literatürdeki birleştirilmiş görüntüler ile yapılan analizlerle uyumlu sonuçlar vermiştir [28], [77]. Ayrıca, çalışmalardaki genel doğrulukları incelediğimizde, DVM ile sınıflandırılan görüntülerin diğer sınıflandırmalara baskın olarak daha yüksek genel doğruluklar elde ettiğini görebiliriz. DVM yöntemi ile sınıflandırılan veri setlerindeki ortalama genel doğruluğun, sırasıyla RO ve EYK yöntemlerine göre %1.6 ve %2.6 fazla olduğu belirlenmiştir. Önceki çalışmalar da DVM ve RO'ın benzer sonuçlar verdiğini ve diğer sınıflandırıcılardan daha iyi performans gösterdiğini doğrulamaktadır [76], [78], [128], [129].

Yapılan çalışmayı ana hatlarıyla ayırdığımızda 4 farklı kategoride bulunan sonuçlar incelenmiştir. Bunlar sırasıyla mevsimsel izleme, veri seti, arttırılmış örnek ve

doğruluktur. Öncelikle bir çalışma alanını belli bir süre boyunca eşit aralıklarla olacak şekilde izleyerek sınıflandırmada olan farklılıklar incelenmiştir. Çalışmada en yüksek doğruluk ana sınıflandırmalarda şubat ayında %95.90 olarak elde edilmiştir. Liu ve arkadaşlarının yaptığı çalışmada da kış sezonunda en yüksek genel doğruluğa %85.5 ile ulaşılması, optik görüntülerin bu mevsimde daha yüksek doğrulukta sonuçlar verdiğini göstermektedir ve bulduğumuz sonuç ile tutarlıdır [75]. Ayrıca çalışma kapsamında en düşük doğruluk %40 ile yalnızca SAR görüntüsünün kullanıldığı sınıflandırmalar sonucu bu çalışmada bulunduğu gibi en düşük genel doğruluklara ulaşmışlardır [28], [77]. Çalışmanın sağladığı bir başka katkı eğitim örnek miktarının değişkenliğinin etkileridir. Bu analiz için arttırılan eğitim örnekleri ile sınıflandırma genel doğrulukları belirgin bir şekilde artış göstermiş, Noi ve Kappas'ın 2018 yılında yaptığı çalışmadaki

benzer tespitlere ulaşılmıştır [76]. Çalışmada elde edilen doğruluk, Noi ve Kappas (2018)'ın elde ettiği doğruluğa göre biraz daha yüksektir [76].

Şekil 3.13'te çalışma alanı ve test alanında gerçekleştirilen sınıflandırmalar arasındaki farklar verilmiştir. Şekilden yola çıkılarak iki farklı bölge için de tutarlı sınıflandırma sonuçları elde edildiği söylenebilmektedir.



Şekil 3.13 Çalışma ve test alanı için elde edilen sınıflandırma doğruluklarındaki farklar (DVM_V, RO_V ve EYK_V doğrulama sınıflandırmalarıdır)

çalışmalarda kullanılan derin modelleri Geçmişte yapılan öğrenme ile karşılaştırdığımızda ise gelişen sistem teknolojisi ile daha karmaşık ağ tasarımları yapılmakta ve yüksek sınıflandırma sonuçları elde edilmektedir. Benzer alanda yapılan çalışmaların bulgularına bakıldığında %92 ila %99.2 arasında değişen sınıflandırma doğrulukları elde edilmiştir [79]-[81]. Fakat bu çalışmaların ortak noktalarına bakıldığında geleneksel makine öğrenmesi yöntemlerinin küçük çalışma bölgeleri ve verisetleri için hala kullanılabilir olduğu vurgulanmaktadır. Çalışmamızda elde edilen sınıflandırma sonuçları Tablo 3.7'deki ilgili derin öğrenme yöntemleri ile yapılan benzer çalışmaların bazılarından üstündür [79], [81]. Ayrıca tüm derin öğrenme ve geleneksel makine öğrenmesi yöntemlerini karşılaştıran çalışmalara baktığımızda, derin öğrenme yöntemlerinin yüksek performans isteyen sistemlerde uygulanabileceğini, veri seti oluşturmak ve eğitim için ciddi sürelere ihtiyaç olduğundan bahsetmişlerdir [80], [81]. Bu sebeple bu çalışmanın amacını gerçekleştirebilmek için geleneksel makine öğrenmesi yöntemleri yeterli seviyede görülmüştür. Elde edilen sınıflandırma doğrulukları da mevsimsel izlemeyi yapabilmek için yeterli seviyede doğruluk sağlamışlardır.

4.1 Sonuç ve Öneriler

Bu çalışma kapsamında, bir yıl içerisinde olabildiğince farklı mevsimlerde ve eşit aralıklarda olacak şekilde SAR ve Optik görüntüleri elde edilip birleştirilmiştir. Daha sonra tüm görüntüler DVM, RO ve EYK yöntemleri kullanılarak sınıflandırılmıştır. Gerçekleştirilen sınıflandırmalar sonucu, farklı mevsimlerde alınan görüntülerin mevsimsel etkilerinin sınıflandırma algoritmalarına olan etkisi araştırılmıştır. Sınıflandırma yapılan görüntülere ekstra bir bitki endeksi olan NDVI verisinin eklenmesinin sınıflandırma doğruluğuna olan etkisi incelenmiştir. Ayrıca eğitim örnekleri olarak belirlenen alanların sayılarının arttırılmasının, sınıflandırma sonucuna doğrudan bir etkisi olup olmadığı, çalışma kapsamında gösterilmiştir.

Bu çalışma, arazi sınıflandırması yaparken sulak bölgelerdeki su seviyesi ve ağaçlardaki yaprak durumlarına göre farklı sınıflandırma yaklaşımları kullanılabileceğini göstermektedir. Bir bitki indeksi olan NDVI, mevsimsel değişikliklerin olduğu ve ağırlıklı olarak bitki örtüsü olan çalışma alanında, çevresel analizlerin daha iyi yapılabilmesi için sınıflandırma sonuçlarına katkıda bulunmaktadır.

Kış aylarında, bitkilerde bulunan klorofil seviyesinin azalmasından dolayı düşük NDVI değerleri algılanmaktadır. Bu sebeple ağırlıklı olarak bitki örtüsü bulunan çalışma alanında, özellikle kış ayları için NDVI bilgisinin ekstra olarak eklenmesinin sınıflandırma genel doğruluğuna doğrudan bir etkisi olmamıştır. Bu da bize, ağaçların yapraklarını döktüğü mevsimlerde NDVI verisinin bitki analizlerini yapmak için yeterli bir doğruluk sağlamayacağını göstermiştir. Ayrıca çalışma alanının genel bitki örtüsüne baktığımızda, sık ağaçlardan oluşan ormanlık bölge ve ikincil yeşil alan dediğimiz küçük çim bölgelerinden oluştuğunu gözlemlemekteyiz. Bu sebeple birbirinden çok farklı bitki türleri yoktur. Dolayısıyla NDVI bilgisinin sınıflandırma genel doğruluklarına doğrudan bir arttırıcı etki yapmamasının sebebi az sayıda olan farklı bitki türlerinin birbirlerinden ayırt edilmesinin kolay olmasıdır. Bu da bize NDVI bilgisinin, zengin bitki türleri çeşitliliği olan bölgelerde kullanılmasının daha doğru sınıflandırma sonuçları vereceğini göstermiştir.

EYK sınıflandırma algoritmasında, NDVI bilgisinin eklenmesinin, genel doğruluğa bir etkisi olmadığı çalışmada ortaya konulmuştur. Ayrıca yalnız SAR görüntülerinin, optik veriler gibi çoklu spektral bilgiye sahip olmaması ve SAR görüntülerindeki elimine edilemeyen gürültüler sebebiyle segmentlere doğru bir şekilde ayrılamadığı, bu sebeple de tek başına nesne tabanlı sınıflandırma uygulandığında yeterli bir sınıflandırma doğruluğu elde edilmediği görülmüştür. Son olarak, yalnızca eğitim örnek sayılarının arttırılmasının genel doğrulukları arttırdığı çalışmada gösterilmiştir.



- B. L. Turner II, D. Skole, S. Sanderson, G. Fischer, L. Fresco, and R. Leemans, "Land-Use and Land-Cover Change, Science/Research Plan," 1995.
- [2] E. F. Lambin *et al.*, "The causes of land-use and land-cover change: Moving beyond the myths," *Global Environmental Change*, vol. 11, no. 4, pp. 261–269, 2001, doi: 10.1016/S0959-3780(01)00007-3.
- K. K. Goldewijk, "Estimating global land use change over the past 300 years: The HYDE database," *Global Biogeochemical Cycles*, vol. 15, no. 2, pp. 417–433, 2001, doi: 10.1029/1999GB001232.
- [4] E. Moran and E. S. Brondizio, "Land-use change after deforestation in Amazonia," in *People and Pixels: Linking Remote Sensing and Social Science*, 1998, pp. 94–120.
- [5] L. J. Gordon, W. Steffen, B. F. Jönsson, C. Folke, M. Falkenmark, and Å. Johannessen,
 "Human modification of global water vapor flows from the land surface," *Proc Natl Acad Sci U S A*, vol. 102, no. 21, p. 7612, May 2005, doi: 10.1073/PNAS.0500208102.
- [6] X. Xu, B. R. Scanlon, K. Schilling, and A. Sun, "Relative importance of climate and land surface changes on hydrologic changes in the US Midwest since the 1930s: Implications for biofuel production," *Journal of Hydrology*, vol. 497, pp. 110–120, 2013, doi: 10.1016/J.JHYDROL.2013.05.041.
- [7] E. López, G. Bocco, M. Mendoza, and E. Duhau, "Predicting land-cover and land-use change in the urban fringe A case in Morelia city, Mexico," *Landscape and Urban Planning*, vol. 55, no. 4, pp. 271–285, Aug. 2001, doi: 10.1016/S0169-2046(01)00160-8.
- [8] R. E. Kennedy *et al.*, "Remote sensing change detection tools for natural resource managers: Understanding concepts and tradeoffs in the design of landscape monitoring projects," *Remote Sensing of Environment*, vol. 113, no. 7, pp. 1382–1396, Jul. 2009, doi: 10.1016/J.RSE.2008.07.018.
- T. Kuemmerle *et al.*, "Challenges and opportunities in mapping land use intensity globally," *Current Opinion in Environmental Sustainability*, vol. 5, no. 5, pp. 484–493, Oct. 2013, doi: 10.1016/J.COSUST.2013.06.002.

- [10] M. C. Hansen and T. R. Loveland, "A review of large area monitoring of land cover change using Landsat data," *Remote Sensing of Environment*, vol. 122, pp. 66–74, Jul. 2012, doi: 10.1016/J.RSE.2011.08.024.
- [11] R. Hale Topaloğlu, E. Sertel, and N. Musaoğlu, "Assessment of Classification Accuracies of SENTINEL-2 and LANDSAT-8 Data for Land Cover / Use Mapping," *ISPAr*, vol. 41B8, pp. 1055–1059, Jun. 2016, doi: 10.5194/ISPRS-ARCHIVES-XLI-B8-1055-2016.
- [12] M. Meroni *et al.*, "Comparing land surface phenology of major European crops as derived from SAR and multispectral data of Sentinel-1 and -2," *Remote Sensing of Environment*, vol. 253, p. 112232, Feb. 2021, doi: 10.1016/J.RSE.2020.112232.
- [13] J. Wang *et al.*, "Mapping sugarcane plantation dynamics in Guangxi, China, by time series Sentinel-1, Sentinel-2 and Landsat images," *AGUFM*, vol. 2020, pp. B030-08, 2020, Accessed: Oct. 06, 2021. [Online]. Available: https://ui.adsabs.harvard.edu/abs/2020AGUFMB030...08W/abstract
- [14] M. Belgiu and O. Csillik, "Sentinel-2 cropland mapping using pixel-based and objectbased time-weighted dynamic time warping analysis," *Remote Sensing of Environment*, vol. 204, pp. 509–523, Jan. 2018, doi: 10.1016/J.RSE.2017.10.005.
- [15] M. Immitzer, F. Vuolo, and C. Atzberger, "First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe," *Remote Sensing 2016, Vol. 8, Page 166*, vol. 8, no. 3, p. 166, Feb. 2016, doi: 10.3390/RS8030166.
- [16] N. Puletti, N. Puletti, F. Chianucci, and C. Castaldi, "Use of Sentinel-2 for forest classification in Mediterranean environments," *Annals of Silvicultural Research*, vol. 42, no. 1, pp. 32–38, Jun. 2018, doi: 10.12899/asr-1463.
- [17] S. Abdikan, F. B. Sanli, M. Ustuner, and F. Calò, "Land Cover Mapping Using Sentinel-1 SAR Data," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLI-B7, pp. 757–761, Jun. 2016, doi: 10.5194/ISPRS-ARCHIVES-XLI-B7-757-2016.
- [18] H. Balzter, B. Cole, C. Thiel, and C. Schmullius, "Mapping CORINE Land Cover from Sentinel-1A SAR and SRTM Digital Elevation Model Data using Random Forests," *Remote Sensing 2015, Vol. 7, Pages 14876-14898*, vol. 7, no. 11, pp. 14876–14898, Nov. 2015, doi: 10.3390/RS71114876.

- [19] D. Alena, H. Markus, M. Milutin, and W. Wolfgang, "Forest Area Derivation from Sentinel-1 Data," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3, pp. 227–233, Jun. 2016, doi: 10.5194/ISPRS-ANNALS-III-7-227-2016.
- [20] A. B. Polat and Ö. Akçay, "Rapid Flood Mapping with Sentinel-1 SAR Images: A Case Study of Maritsa River," in 2nd Intercontinental Geoinformation Days (IGD), May 2021, pp. 123–126.
- [21] J. Zhou, D. L. Civco, and J. A. Silander, "A wavelet transform method to merge Landsat TM and SPOT panchromatic data," *http://dx.doi.org/10.1080/014311698215973*, vol. 19, no. 4, pp. 743–757, 1998, doi: 10.1080/014311698215973.
- [22] L. de O. Pereira, C. da C. Freitas, S. J. S. Sant'Anna, D. Lu, and E. F. Moran, "Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon," *http://dx.doi.org/10.1080/15481603.2013.805589*, vol. 50, no. 3, pp. 301–321, Jul. 2013, doi: 10.1080/15481603.2013.805589.
- [23] K. S. Chen, W. P. Huang, D. H. Tsay, and F. Amar, "Classification of multifrequency polarimetric SAR imagery using a dynamic learning neural network," *IEEE Transactions* on Geoscience and Remote Sensing, vol. 34, no. 3, pp. 814–820, May 1996, doi: 10.1109/36.499786.
- [24] A. Gaber, F. Soliman, M. Koch, and F. El-Baz, "Using full-polarimetric SAR data to characterize the surface sediments in desert areas: A case study in El-Gallaba Plain, Egypt," *Remote Sensing of Environment*, vol. 162, pp. 11–28, Jun. 2015, doi: 10.1016/J.RSE.2015.01.024.
- [25] Y. Zhang, J. Zhang, X. Zhang, H. Wu, and M. Guo, "Land Cover Classification from Polarimetric SAR Data Based on Image Segmentation and Decision Trees," *http://dx.doi.org/10.1080/07038992.2015.1032901*, vol. 41, no. 1, pp. 40–50, 2015, doi: 10.1080/07038992.2015.1032901.
- [26] E. AÇIKSARI and Ö. AKÇAY, "İkili PolSAR Görüntülerinin Çok Zamanlı Ayrışma ve Kontrolsüz Sınıflandırma Analizi," *Çanakkale Onsekiz Mart Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, vol. 4, no. 2, pp. 69–87, Dec. 2018, doi: 10.28979/COMUFBED.418458.

- [27] N. Joshi *et al.*, "A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring," *Remote Sensing 2016, Vol. 8, Page 70*, vol. 8, no. 1, p. 70, Jan. 2016, doi: 10.3390/RS8010070.
- [28] N. Clerici, C. A. V. Calderón, and J. M. Posada, "Fusion of Sentinel-1A and Sentinel-2A data for land cover mapping: a case study in the lower Magdalena region, Colombia," *https://doi.org/10.1080/17445647.2017.1372316*, vol. 13, no. 2, pp. 718–726, Sep. 2017, doi: 10.1080/17445647.2017.1372316.
- [29] F. Bioresita, A. Puissant, A. Stumpf, and J.-P. Malet, "Fusion of Sentinel-1 and Sentinel-2 image time series for permanent and temporary surface water mapping," *https://doi.org/10.1080/01431161.2019.1624869*, vol. 40, no. 23, pp. 9026–9049, Dec. 2019, doi: 10.1080/01431161.2019.1624869.
- [30] M. Schmitt, F. Tupin, and X. X. Zhu, "Fusion of SAR and optical remote sensing data -Challenges and recent trends," *International Geoscience and Remote Sensing Symposium* (*IGARSS*), vol. 2017-July, pp. 5458–5461, Dec. 2017, doi: 10.1109/IGARSS.2017.8128239.
- [31] N. Pettorelli, W. F. Laurance, T. G. O'Brien, M. Wegmann, H. Nagendra, and W. Turner, "Satellite remote sensing for applied ecologists: opportunities and challenges," *Journal* of Applied Ecology, vol. 51, no. 4, pp. 839–848, Aug. 2014, doi: 10.1111/1365-2664.12261.
- [32] K. Jia, S. Liang, L. Zhang, X. Wei, Y. Yao, and X. Xie, "Forest cover classification using Landsat ETM+ data and time series MODIS NDVI data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 33, no. 1, pp. 32–38, 2014, doi: 10.1016/J.JAG.2014.04.015.
- [33] T. M. Lee and H. C. Yeh, "Applying remote sensing techniques to monitor shifting wetland vegetation: A case study of Danshui River estuary mangrove communities, Taiwan," *Ecological Engineering*, vol. 35, no. 4, pp. 487–496, Apr. 2009, doi: 10.1016/J.ECOLENG.2008.01.007.
- [34] A. Taufik, S. S. S. Ahmad, and A. Ahmad, "Classification of Landsat 8 Satellite Data Using NDVI Tresholds," *Journal of Telecommunication, Electronic and Computer Engineering*, 2016.

- [35] S. Mustak, G. Uday, B. Ramesh, and B. Praveen, "Evaluation of the performance of SAR and SAR-optical fused dataset for crop discrimination," *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives,* vol. 42, no. 3/W6, pp. 563–571, Jul. 2019, doi: 10.5194/ISPRS-ARCHIVES-XLII-3-W6-563-2019.
- [36] Y. Oguro, Y. Suga, S. Takeuchi, M. Ogawa, T. Konishi, and K. Tsuchiya, "Comparison of SAR and optical sensor data for monitoring of rice plant around Hiroshima," *Advances in Space Research*, vol. 28, no. 1, pp. 195–200, Jan. 2001, doi: 10.1016/S0273-1177(01)00345-3.
- [37] S. van Beijma, A. Comber, and A. Lamb, "Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data," *Remote Sensing of Environment*, vol. 149, pp. 118–129, 2014, doi: 10.1016/J.RSE.2014.04.010.
- [38] M. B. A. Gibril, S. A. Bakar, K. Yao, M. O. Idrees, and B. Pradhan, "Fusion of RADARSAT-2 and multispectral optical remote sensing data for LULC extraction in a tropical agricultural area," *http://dx.doi.org/10.1080/10106049.2016.1170893*, vol. 32, no. 7, pp. 735–748, Jul. 2016, doi: 10.1080/10106049.2016.1170893.
- [39] F. B. Şanlı, S. Abdikan, B. Bayram, M. T. Esetlili, and Y. Kurucu, "SAR ve Optik Uydu Görüntülerinden Nesne Tabanlı Sınıflandırma Tekniği Kullanarak Arazi Örtüsünün Belirlenmesi," in *III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, 2010, pp. 417–425. Accessed: Oct. 06, 2021. [Online]. Available: https://avesis.ege.edu.tr/yayin/9929c423-6ba4-48d6-afba-7a4cf984e13a/sar-ve-optikuydu-goruntulerinden-nesne-tabanli-siniflandirma-teknigi-kullanarak-arazi-ortusununbelirlenmesi
- [40] G. Willhauck, "Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos," in *XIX ISPRS congress*, 2000, pp. 35–42. Accessed: Oct. 06, 2021. [Online]. Available: https://www.researchgate.net/publication/281358162_Comparison_of_object_oriented_ classification_techniques_and_standard_image_analysis_for_the_use_of_change_detect ion_between_SPOT_multispectral_satellite_images_and_aerial_photos

- [41] M. S. Tehrany, B. Pradhan, and M. N. Jebuv, "A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery," *Geocarto International*, vol. 29, no. 4, pp. 351–369, 2014, doi: 10.1080/10106049.2013.768300.
- [42] R. C. Weih and N. D. Riggan, "The International Archives of the Photogrammetry," *Remote Sensing and Spatial Information Sciences*, 2010.
- [43] T. G. Whiteside, G. S. Boggs, and S. W. Maier, "Comparing object-based and pixel-based classifications for mapping savannas," *International Journal of Applied Earth Observation and Geoinformation*, vol. 13, no. 6, pp. 884–893, 2011, doi: 10.1016/J.JAG.2011.06.008.
- [44] I. el Naqa and M. J. Murphy, "What Is Machine Learning?," *Machine Learning in Radiation Oncology*, pp. 3–11, 2015, doi: 10.1007/978-3-319-18305-3_1.
- [45] A. E. Maxwell, T. A. Warner, and F. Fang, "Implementation of machine-learning classification in remote sensing: An applied review," *International Journal of Remote Sensing*, vol. 39, no. 9, pp. 2784–2817, May 2018, doi: 10.1080/01431161.2018.1433343/SUPPL_FILE/TRES_A_1433343_SM5998.ZIP.
- [46] T. Su, T. Liu, S. Zhang, Z. Qu, and R. Li, "Machine learning-assisted region merging for remote sensing image segmentation," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 168, pp. 89–123, Oct. 2020, doi: 10.1016/J.ISPRSJPRS.2020.07.017.
- [47] T. Hengl, M. G. Walsh, J. Sanderman, I. Wheeler, S. P. Harrison, and I. C. Prentice, "Global mapping of potential natural vegetation: An assessment of machine learning algorithms for estimating land potential," *PeerJ*, vol. 2018, no. 8, p. e5457, Aug. 2018, doi: 10.7717/PEERJ.5457/FIG-16.
- [48] V. K. Rana and T. M. Venkata Suryanarayana, "Performance evaluation of MLE, RF and SVM classification algorithms for watershed scale land use/land cover mapping using sentinel 2 bands," *Remote Sensing Applications: Society and Environment*, vol. 19, Aug. 2020, doi: 10.1016/J.RSASE.2020.100351.
- [49] H. Mojaddadi, B. Pradhan, H. Nampak, N. Ahmad, and A. H. bin Ghazali, "Ensemble machine-learning-based geospatial approach for flood risk assessment using multi-sensor remote-sensing data and GIS," *Geomatics, Natural Hazards and Risk*, vol. 8, no. 2, pp. 1080–1102, Dec. 2017, doi: 10.1080/19475705.2017.1294113.

- [50] M. Mohajane *et al.*, "Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area," *Ecological Indicators*, vol. 129, p. 107869, Oct. 2021, doi: 10.1016/J.ECOLIND.2021.107869.
- [51] M. Ustuner, F. B. Sanli, and B. Dixon, "Application of support vector machines for landuse classification using high-resolution rapideye images: A sensitivity analysis," *European Journal of Remote Sensing*, vol. 48, pp. 403–422, Nov. 2015, doi: 10.5721/EUJRS20154823.
- [52] R. B. Arango, I. Díaz, A. Campos, E. R. Canas, and E. F. Combarro, "Automatic arable land detection with supervised machine learning," *Earth Science Informatics*, vol. 9, no. 4, pp. 535–545, Nov. 2016, doi: 10.1007/S12145-016-0270-6/FIGURES/7.
- [53] P. Teluguntla *et al.*, "A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 144, pp. 325–340, Oct. 2018, doi: 10.1016/J.ISPRSJPRS.2018.07.017.
- [54] M. Fauvel, J. Chanussot, and J. A. Benediktsson, "Kernel principal component analysis for the classification of hyperspectral remote sensing data over urban areas," *Eurasip Journal on Advances in Signal Processing*, vol. 2009, 2009, doi: 10.1155/2009/783194.
- [55] S. Hafeez *et al.*, "Detection and Monitoring of Marine Pollution Using Remote Sensing Technologies," in *Monitoring of Marine Pollution*, IntechOpen, 2019. doi: 10.5772/intechopen.81657.
- [56] A. Ghosh, N. S. Mishra, and S. Ghosh, "Fuzzy clustering algorithms for unsupervised change detection in remote sensing images," *Information Sciences*, vol. 181, no. 4, pp. 699–715, Feb. 2011, doi: 10.1016/J.INS.2010.10.016.
- [57] D. C. Duro, S. E. Franklin, and M. G. Dubé, "A comparison of pixel-based and objectbased image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery," *Remote Sensing of Environment*, vol. 118, pp. 259–272, Mar. 2012, doi: 10.1016/J.RSE.2011.11.020.
- [58] S. Talukdar *et al.*, "Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review," *Remote Sensing 2020, Vol. 12, Page 1135*, vol. 12, no. 7, p. 1135, Apr. 2020, doi: 10.3390/RS12071135.

- [59] A. M. Abdi, "Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data," *GIScience and Remote Sensing*, vol. 57, no. 1, pp. 1–20, Jan. 2020, doi: 10.1080/15481603.2019.1650447/SUPPL_FILE/TGRS_A_1650447_SM9050.PDF.
- [60] A. E. Maxwell, T. A. Warner, M. P. Strager, J. F. Conley, and A. L. Sharp, "Assessing machine-learning algorithms and image- and lidar-derived variables for GEOBIA classification of mining and mine reclamation," *https://doi.org/10.1080/01431161.2014.1001086*, vol. 36, no. 4, pp. 954–978, Feb. 2015, doi: 10.1080/01431161.2014.1001086.
- [61] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature 2015 521:7553*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [62] M. Gharbi, J. Chen, J. T. Barron, S. W. Hasinoff, and F. Durand, "Deep bilateral learning for real-time image enhancement," *ACM Transactions on Graphics*, vol. 36, no. 4, 2017, doi: 10.1145/3072959.3073592.
- [63] M. Wu and L. Chen, "Image recognition based on deep learning," *Proceedings 2015 Chinese Automation Congress, CAC 2015*, pp. 542–546, Jan. 2016, doi: 10.1109/CAC.2015.7382560.
- [64] A. Abdollahi, B. Pradhan, N. Shukla, S. Chakraborty, and A. Alamri, "Multi-Object Segmentation in Complex Urban Scenes from High-Resolution Remote Sensing Data," *Remote Sensing 2021, Vol. 13, Page 3710*, vol. 13, no. 18, p. 3710, Sep. 2021, doi: 10.3390/RS13183710.
- [65] A. Abdollahi, B. Pradhan, G. Sharma, K. N. A. Maulud, and A. Alamri, "Improving Road Semantic Segmentation Using Generative Adversarial Network," *IEEE Access*, vol. 9, pp. 64381–64392, 2021, doi: 10.1109/ACCESS.2021.3075951.
- [66] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, "Object Detection with Deep Learning: A Review," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 30, no. 11, pp. 3212–3232, Nov. 2019, doi: 10.1109/TNNLS.2018.2876865.
- [67] P. Helber, B. Bischke, A. Dengel, and D. Borth, "EuroSAT: A Novel Dataset and Deep Learning Benchmark for Land Use and Land Cover Classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 12, no. 7, pp. 2217–2226, Aug. 2017, doi: 10.48550/arxiv.1709.00029.

- [68] B. Pradhan, H. A. H. Al-Najjar, M. I. Sameen, I. Tsang, and A. M. Alamri, "Unseen Land Cover Classification from High-Resolution Orthophotos Using Integration of Zero-Shot Learning and Convolutional Neural Networks," *Remote Sensing 2020, Vol. 12, Page* 1676, vol. 12, no. 10, p. 1676, May 2020, doi: 10.3390/RS12101676.
- [69] A. Abdollahi and B. Pradhan, "Urban Vegetation Mapping from Aerial Imagery Using Explainable AI (XAI)," Sensors 2021, Vol. 21, Page 4738, vol. 21, no. 14, p. 4738, Jul. 2021, doi: 10.3390/S21144738.
- [70] A. Abdollahi and B. Pradhan, "Integrating semantic edges and segmentation information for building extraction from aerial images using UNet," *Machine Learning with Applications*, vol. 6, p. 100194, Dec. 2021, doi: 10.1016/J.MLWA.2021.100194.
- [71] A. Abdollahi, B. Pradhan, and A. M. Alamri, "An ensemble architecture of deep convolutional Segnet and Unet networks for building semantic segmentation from highresolution aerial images," *https://doi.org/10.1080/10106049.2020.1856199*, 2020, doi: 10.1080/10106049.2020.1856199.
- [72] H. A. H. Al-Najjar *et al.*, "Land Cover Classification from fused DSM and UAV Images Using Convolutional Neural Networks," *Remote Sensing 2019, Vol. 11, Page 1461*, vol. 11, no. 12, p. 1461, Jun. 2019, doi: 10.3390/RS11121461.
- [73] P. Wang, E. Fan, and P. Wang, "Comparative analysis of image classification algorithms based on traditional machine learning and deep learning," *Pattern Recognition Letters*, vol. 141, pp. 61–67, Jan. 2021, doi: 10.1016/J.PATREC.2020.07.042.
- [74] A. Abdollahi, B. Pradhan, N. Shukla, S. Chakraborty, and A. Alamri, "Deep Learning Approaches Applied to Remote Sensing Datasets for Road Extraction: A State-Of-The-Art Review," *Remote Sensing 2020, Vol. 12, Page 1444*, vol. 12, no. 9, p. 1444, May 2020, doi: 10.3390/RS12091444.
- [75] J. Liu, J. Heiskanen, E. Aynekulu, and P. K. E. Pellikka, "Seasonal variation of land cover classification accuracy of Landsat 8 images in Burkina Faso," *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, vol. 40, no. 7W3, pp. 455–460, Apr. 2015, doi: 10.5194/ISPRSARCHIVES-XL-7-W3-455-2015.
- [76] P. T. Noi and M. Kappas, "Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2

Imagery," Sensors 2018, Vol. 18, Page 18, vol. 18, no. 1, p. 18, Dec. 2017, doi: 10.3390/S18010018.

- [77] C. Sun, Y. Bian, T. Zhou, and J. Pan, "Using of Multi-Source and Multi-Temporal Remote Sensing Data Improves Crop-Type Mapping in the Subtropical Agriculture Region," *Sensors 2019, Vol. 19, Page 2401*, vol. 19, no. 10, p. 2401, May 2019, doi: 10.3390/S19102401.
- [78] M. Hudait and P. P. Patel, "Crop-type mapping and acreage estimation in smallholding plots using Sentinel-2 images and machine learning algorithms: Some comparisons," *The Egyptian Journal of Remote Sensing and Space Science*, vol. 25, no. 1, pp. 147–156, Feb. 2022, doi: 10.1016/J.EJRS.2022.01.004.
- [79] S. E. Jozdani, B. A. Johnson, and D. Chen, "Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification," *Remote Sensing 2019, Vol. 11, Page 1713*, vol. 11, no. 14, p. 1713, Jul. 2019, doi: 10.3390/RS11141713.
- [80] J. Adrian, V. Sagan, and M. Maimaitijiang, "Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 175, pp. 215–235, May 2021, doi: 10.1016/J.ISPRSJPRS.2021.02.018.
- [81] E. G. Adagbasa, S. A. Adelabu, and T. W. Okello, "Application of deep learning with stratified K-fold for vegetation species discrimation in a protected mountainous region using Sentinel-2 image," *https://doi.org/10.1080/10106049.2019.1704070*, vol. 37, no. 1, pp. 142–162, 2019, doi: 10.1080/10106049.2019.1704070.
- [82] "Türkiye İstatistik Kurumu," 2021. https://www.tuik.gov.tr/ (accessed Sep. 28, 2021).
- [83] A. Tüneli İşletme İnşaat ve Yatırım AŞ, "Eurasia Tunnel Environmental and Social Impact Assessment Non Technical Summary (NTS) Final Draft," 2011, Accessed: Oct. 06, 2021. [Online]. Available: http://www.elcgroup.com.tr/PROJECTNO.P0106067http://www.erm.com
- [84] D. M. C. author and F. S. Erbek, "Analysis of urban growth using multi-temporal satellite data in Istanbul, Turkey," *http://dx.doi.org/10.1080/01431160512331316784*, vol. 26, no. 4, pp. 797–810, Feb. 2006, doi: 10.1080/01431160512331316784.

- [85] F. Calò, S. Abdikan, T. Görüm, A. Pepe, H. Kiliç, and F. B. Şanli, "The Space-Borne SBAS-DInSAR Technique as a Supporting Tool for Sustainable Urban Policies: The Case of Istanbul Megacity, Turkey," *Remote Sensing 2015, Vol. 7, Pages 16519-16536*, vol. 7, no. 12, pp. 16519–16536, Dec. 2015, doi: 10.3390/RS71215842.
- [86] E. Chuvieco *et al.*, "Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating," *Remote Sensing of Environment*, vol. 92, no. 3, pp. 322–331, Aug. 2004, doi: 10.1016/J.RSE.2004.01.019.
- [87] P. Illera, A. Fernandez, and J. A. Delgado, "Temporal evolution of the NDVI as an indicator of forest fire danger," *http://dx.doi.org/10.1080/01431169608949072*, vol. 17, no. 6, pp. 1093–1105, 2007, doi: 10.1080/01431169608949072.
- [88] L. Yan, D. P. Roy, H. Zhang, J. Li, and H. Huang, "An Automated Approach for Sub-Pixel Registration of Landsat-8 Operational Land Imager (OLI) and Sentinel-2 Multi Spectral Instrument (MSI) Imagery," *Remote Sensing 2016, Vol. 8, Page 520*, vol. 8, no. 6, p. 520, Jun. 2016, doi: 10.3390/RS8060520.
- [89] Y. Hara, R. G. Atkins, R. T. Shin, J. A. Kong, and S. H. Yueh, "Application of Neural Networks to Radar Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, no. 1, pp. 100–109, 1994, doi: 10.1109/36.285193.
- [90] R. Torres *et al.*, "GMES Sentinel-1 mission," *Remote Sensing of Environment*, vol. 120, pp. 9–24, May 2012, doi: 10.1016/J.RSE.2011.05.028.
- [91] European Space Agency, "Sentinel Online ESA Sentinel Online." https://sentinel.esa.int/web/sentinel/home (accessed Sep. 28, 2021).
- [92] J. Muro et al., "Short-Term Change Detection in Wetlands Using Sentinel-1 Time Series," Remote Sensing 2016, Vol. 8, Page 795, vol. 8, no. 10, p. 795, Sep. 2016, doi: 10.3390/RS8100795.
- [93] M. Hornáček *et al.*, "Potential for high resolution systematic global surface soil moisture retrieval via change detection using sentinel-1," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, no. 4, pp. 1303–1311, 2012, doi: 10.1109/JSTARS.2012.2190136.
- [94] P. Washaya, T. Balz, and B. Mohamadi, "Coherence Change-Detection with Sentinel-1 for Natural and Anthropogenic Disaster Monitoring in Urban Areas," *Remote Sensing* 2018, Vol. 10, Page 1026, vol. 10, no. 7, p. 1026, Jun. 2018, doi: 10.3390/RS10071026.

- [95] Q. Vanhellmont and K. Ruddick, "Acolite for Sentinel-2: Aquatic Applications of MSI Imagery," *ESASP*, vol. 740, p. 55, Aug. 2016, Accessed: Sep. 28, 2021. [Online]. Available: https://ui.adsabs.harvard.edu/abs/2016ESASP.740E..55V/abstract
- [96] U. Müller-Wilm, J. Louis, R. Richter, F. Gascon, and M. Niezette, "Sentinel-2 Level 2A Prototype Processor: Architecture, Algorithms And First Results," 2013, Accessed: Oct. 06, 2021. [Online]. Available: https://www.libradtran.org
- [97] I. Ali, S. Cao, V. Naeimi, C. Paulik, and W. Wagner, "Methods to Remove the Border Noise from Sentinel-1 Synthetic Aperture Radar Data: Implications and Importance for Time-Series Analysis," *IEEE Journal of Selected Topics in Applied Earth Observations* and Remote Sensing, vol. 11, no. 3, pp. 777–786, Mar. 2018, doi: 10.1109/JSTARS.2017.2787650.
- [98] J.-S. Lee, "Speckle Suppression And Analysis For Synthetic Aperture Radar Images," https://doi.org/10.1117/12.7973877, vol. 25, no. 5, pp. 636–643, May 1986, doi: 10.1117/12.7973877.
- [99] T. Blaschke, C. Burnett, and A. Pekkarinen, "Image Segmentation Methods for Objectbased Analysis and Classification," pp. 211–236, 2004, doi: 10.1007/978-1-4020-2560-0_12.
- T. Blaschke, S. Lang, and G. Hay, Object-based image analysis for remote sensing applications: Modeling reality dealing with complexity, vol. 0, no. 9783540770572.
 Springer Science and Business Media Deutschland GmbH, 2008. doi: 10.1007/978-3-540-77058-9_1.
- [101] U. C. Benz, P. Hofmann, G. Willhauck, I. Lingenfelder, and M. Heynen, "Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 58, no. 3–4, pp. 239–258, Jan. 2004, doi: 10.1016/J.ISPRSJPRS.2003.10.002.
- [102] M. Baatz and A. Schäpe, "Multiresolution Segmentation : an optimization approach for high quality multi-scale image segmentation," *Angew. Geogr. Info. verarbeitung, Wichmann-Verlag, Heidelberg*, 2000.
- [103] J. Freixenet, X. Muñoz, D. Raba, J. Martí, and X. Cufí, "Yet Another Survey on Image Segmentation: Region and Boundary Information Integration," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and*

Lecture Notes in Bioinformatics), vol. 2352, pp. 408–422, 2002, doi: 10.1007/3-540-47977-5_27.

- [104] J. Schiewe, "SEGMENTATION OF HIGH-RESOLUTION REMOTELY SENSED DATA - CONCEPTS, APPLICATIONS AND PROBLEMS," International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, pp. 380–385, 2002.
- [105] T. Kavzoğlu and H. Tonbul, "A Comparative Study of Segmentation Quality for Multi-resolution Segmentation and Watershed Transform," in *8th International Conference on Recent Advances in Space Technologies*, 2017, pp. 113–117. Accessed: Oct. 06, 2021.
 [Online]. Available: https://www.researchgate.net/publication/318851838_A_Comparative_Study_of_Segmentation_Quality_for_Multi-resolution_Segmentation_and_Watershed_Transform
- [106] M. D. Hossain and D. Chen, "Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 150, pp. 115–134, Apr. 2019, doi: 10.1016/J.ISPRSJPRS.2019.02.009.
- [107] G. Mountrakis, J. Im, and C. Ogole, "Support vector machines in remote sensing: A review," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 66, no. 3, pp. 247– 259, May 2011, doi: 10.1016/J.ISPRSJPRS.2010.11.001.
- [108] G. Cavallaro, M. Riedel, M. Richerzhagen, J. A. Benediktsson, and A. Plaza, "On Understanding Big Data Impacts in Remotely Sensed Image Classification Using Support Vector Machine Methods," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 10, pp. 4634–4646, Oct. 2015, doi: 10.1109/JSTARS.2015.2458855.
- [109] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "Training algorithm for optimal margin classifiers," *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, pp. 144–152, 1992, doi: 10.1145/130385.130401.
- [110] C. Huang, L. S. Davis, and J. R. G. Townshend, "An assessment of support vector machines for land cover classification," *https://doi.org/10.1080/01431160110040323*, vol. 23, no. 4, pp. 725–749, Feb. 2010, doi: 10.1080/01431160110040323.
- [111] A. Mathur and G. M. Foody, "Crop classification by support vector machine with intelligently selected training data for an operational application,"

http://dx.doi.org/10.1080/01431160701395203, vol. 29, no. 8, pp. 2227–2240, Apr. 2008, doi: 10.1080/01431160701395203.

- [112] R. Jhonnerie, V. P. Siregar, B. Nababan, L. B. Prasetyo, and S. Wouthuyzen, "Random Forest Classification for Mangrove Land Cover Mapping Using Landsat 5 TM and Alos Palsar Imageries," *Procedia Environmental Sciences*, vol. 24, pp. 215–221, 2015, doi: 10.1016/J.PROENV.2015.03.028.
- [113] L. Breiman, "Random Forests," *Machine Learning 2001 45:1*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [114] A. Chaudhary, S. Kolhe, and R. Kamal, "An improved random forest classifier for multiclass classification," *Information Processing in Agriculture*, vol. 3, no. 4, pp. 215–222, Dec. 2016, doi: 10.1016/J.INPA.2016.08.002.
- [115] A. Liaw and M. Wiener, "Classification and Regression by RandomForest," *R News*, pp. 18–22, 2001, Accessed: Oct. 06, 2021. [Online]. Available: https://www.researchgate.net/publication/228451484_Classification_and_Regression_b y_RandomForest
- [116] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, and J. P. Rigol-Sanchez, "An assessment of the effectiveness of a random forest classifier for land-cover classification," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 67, no. 1, pp. 93–104, Jan. 2012, doi: 10.1016/J.ISPRSJPRS.2011.11.002.
- [117] A. Stumpf and N. Kerle, "Object-oriented mapping of landslides using Random Forests," *Remote Sensing of Environment*, vol. 115, no. 10, pp. 2564–2577, Oct. 2011, doi: 10.1016/J.RSE.2011.05.013.
- [118] R. Çömert, D. K. Matci, and U. Avdan, "Object Based Burned Area Mapping with Random Forest Algorithm," *International Journal of Engineering and Geosciences*, vol. 4, no. 2, pp. 78–87, Jun. 2019, doi: 10.26833/IJEG.455595.
- [119] T. M. Cover and P. E. Hart, "Nearest Neighbor Pattern Classification," IEEE Transactions on Information Theory, vol. 13, no. 1, pp. 21–27, 1967, doi: 10.1109/TIT.1967.1053964.
- [120] G. D. Betrie, S. Tesfamariam, K. A. Morin, and R. Sadiq, "Predicting copper concentrations in acid mine drainage: a comparative analysis of five machine learning

techniques," *Environmental Monitoring and Assessment 2012 185:5*, vol. 185, no. 5, pp. 4171–4182, Sep. 2012, doi: 10.1007/S10661-012-2859-7.

- [121] S. A. Naghibi, M. Vafakhah, H. Hashemi, B. Pradhan, and S. J. Alavi, "Water Resources Management Through Flood Spreading Project Suitability Mapping Using Frequency Ratio, k-nearest Neighbours, and Random Forest Algorithms," *Natural Resources Research 2019 29:3*, vol. 29, no. 3, pp. 1915–1933, Aug. 2019, doi: 10.1007/S11053-019-09530-4.
- [122] X. Xing, C. Yan, Y. Jia, H. Jia, J. Lu, and G. Luo, "An Effective High Spatiotemporal Resolution NDVI Fusion Model Based on Histogram Clustering," *Remote Sensing 2020*, *Vol. 12, Page 3774*, vol. 12, no. 22, p. 3774, Nov. 2020, doi: 10.3390/RS12223774.
- [123] S. Pesaresi, A. Mancini, and S. Casavecchia, "Recognition and Characterization of Forest Plant Communities through Remote-Sensing NDVI Time Series," *Diversity 2020, Vol. 12, Page 313*, vol. 12, no. 8, p. 313, Aug. 2020, doi: 10.3390/D12080313.
- [124] C. A. da Silva Junior, M. R. Nanni, P. E. Teodoro, and G. F. C. Silva, "Vegetation indices for discrimination of soybean areas: A new approach," *Agronomy Journal*, vol. 109, no. 4, pp. 1331–1343, 2017, doi: 10.2134/AGRONJ2017.01.0003.
- [125] P. Olofsson, G. M. Foody, M. Herold, S. v. Stehman, C. E. Woodcock, and M. A. Wulder, "Good practices for estimating area and assessing accuracy of land change," *Remote Sensing of Environment*, vol. 148, pp. 42–57, May 2014, doi: 10.1016/J.RSE.2014.02.015.
- [126] R. G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data," *Remote Sensing of Environment*, vol. 37, no. 1, pp. 35–46, Jul. 1991, doi: 10.1016/0034-4257(91)90048-B.
- [127] R. G. Congalton and K. Green, "Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Second Edition," Assessing the Accuracy of Remotely Sensed Data, Dec. 2008, doi: 10.1201/9781420055139.
- [128] E. Adam, O. Mutanga, J. Odindi, and E. M. Abdel-Rahman, "Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers," *http://dx.doi.org/10.1080/01431161.2014.903435*, vol. 35, no. 10, pp. 3440–3458, 2014, doi: 10.1080/01431161.2014.903435.

[129] A. Ghosh and P. K. Joshi, "A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery," *International Journal of Applied Earth Observation and Geoinformation*, vol. 26, no. 1, pp. 298–311, Feb. 2014, doi: 10.1016/J.JAG.2013.08.011.



Makaleler

1. Polat, A.B., Akcay, O. & Balik Sanli, F. Monitoring seasonal effects in vegetation areas with Sentinel-1 SAR and Sentinel-2 optic satellite images. Arab J Geosci 15, 670 (2022). https://doi.org/10.1007/s12517-022-09947-x

Konferans Bildirileri

1. Polat, A. B., Akcay, O., and Balik Sanli, F.: Analysing Temporal Effects on Classification of SAR and Optical Images, EGU General Assembly 2021, online, 19–30 Apr 2021, EGU21-14386, https://doi.org/10.5194/egusphere-egu21-14386, 2021.