

Sentinel-2 Uydu Görüntülerinde Destek Vektör Makinesi ve Rastgele Orman Algoritmaları Kullanılarak Pksel Tabanlı Arazi Sınıflandırması

Duygu ARIKAN^{1*}, Ferruh YILDIZ²

^{1,2}Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, 42000, Konya

¹<https://orcid.org/0000-0001-9976-7479>

²<https://orcid.org/0000-0003-1248-8923>

*Sorumlu yazar: darikan@ktun.edu.tr

Araştırma Makalesi

Makale Tarihçesi:

Geliş tarihi: 30.05.2022

Kabul tarihi: 20.11.2022

Online Yayınlanma: 05.07.2023

Anahtar Kelimeler:

Destek vektör makineleri

Pksel tabanlı sınıflandırma

Rastgele orman

Sentinel-2 uydu verileri

ÖZ

Son yıllarda, uydu teknolojisinde hızlı gelişmeler yaşanmaktadır. Bu gelişmeler doğrultusunda uzaktan algılama alanında yapay zekâ, makine öğrenmesi gibi yeni ve farklı araştırma konularının ortaya çıkmasına sebep olmuştur. Yeryüzüne ait bilgilerin toplanmasında sınıflandırma yöntemleri sıkça kullanılmaktadır. Çünkü göl, nehir gibi sulak alanlar veya kentsel bölgeler, ekolojik denge için önemlidir. Uzaktan algılama sayesinde yeryüzündeki mevcut durumun tespiti, zamanla olan değişimin izlenmesi gerçekleştirilebilmektedir. Bu çalışmanın amacı Sentinel-2 MSI uydu verileri kullanılarak Konya ili merkezinde yer alan tarım arazilerinin bir kısmı sınıflandırılmıştır. Pksel tabanlı sınıflandırma yöntemi ve destek vektör makinesi (DVM) ve rastgele orman (RO) algoritmaları kullanılmıştır. Python dilinde kodlanmış algoritmalarından elde edilmiş sonuç ürünlerin genel doğrulukları karşılaştırılmış ve yorumlanmıştır. Yapılan çalışma sonucunda DVM algoritmasından elde edilen genel doğruluk değeri %96,7 iken, RO'da %86,67 ve kappa değerleri DVM ve RO algoritmaları için sırasıyla 0,9535 ve 0,8148 bulunmuştur.

Pixel-Based Land Classification Using Support Vector Machine and Random Forest Algorithms in Sentinel-2 Satellite Images

Research Article

Article History:

Received: 30.05.2022

Accepted: 20.11.2022

Published online: 05.07.2023

Keywords:

Support vector machine

Pixel based classification

Random forest

Sentinel-2 satellite data

ABSTRACT

In recent years, there have been rapid advances in satellite technology. In line with these developments, new and different research topics such as artificial intelligence and machine learning have emerged in the field of remote sensing. Classification methods are frequently used in collecting Earth information because wetlands such as lakes, rivers or urban areas are essential for the environment and ecological balance. It is possible to detect the current situation on the Earth with remote sensing and monitor change in time. The purpose of this study is to classify some of the agricultural lands in the city center of Konya using Sentinel-2 MSI satellite data. Pixel-based classification method and support vector machine (SVM) and random forest (RF) algorithms are used. The general accuracy of the resulting products obtained from algorithms coded in Python language was compared and interpreted. As a result of the study, the overall accuracy value obtained from the SVM algorithm was 96.7%, while the RF was 86.67% and the kappa values were 0.9535 and 0.8148 for the SVM and RF algorithms, respectively.

To Cite: Arıkan D., Yıldız F. Sentinel-2 Uydu Görüntülerinde Destek Vektör Makinesi ve Rastgele Orman Algoritmaları Kullanılarak Pksel Tabanlı Arazi Sınıflandırması. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2023; 6(2): 1243-1260.

1. Giriş

Uzaktan algılama uydularının kullanım alanlarının artması ve gelişen yapay zeka teknolojisiyle birlikte uydu görüntülerinde de önemli değişiklikler meydana getirmiştir. Uydular ilk olarak askeri amaçla kullanılmaya başlanmış ve daha sonraları meteorolojik bilgiler almak veya arazi örtüsü belirlemek gibi amaçlarla kullanılmıştır. Uydu teknolojisinin gelişmesiyle birlikte uzaktan algılamanın kullanımı ve uygulama alanı da artmıştır (Kaynak, 2017). Uzaktan algılamanın temelinde, nesnelere fiziksel temas olmadan, özel algılayıcı sistemler vasıtasıyla yeryüzü hakkında bilgileri toplama, inceleme ve yorumlama tekniği olarak ifade edilebilir (Çelik, 2015). Uzaktan algılama çalışmalarında yüksek konumsal çözünürlük olması, düşük maliyetli olması, hızlı ve güncel olması çalışmalara büyük oranda fayda sağlamaktadır. Bu nedenle çok fazla uygulama alanı mevcuttur. Ama özellikle arazi örtüsü veya arazinin kullanımı, bitkisel ürün harita üretimi, tarımsal planlama gibi çalışmalar uzaktan algılamanın önemli konularından biri olup, sınıflandırma konusu araştırmacıların üzerinde çalıştığı konulardandır (Barret ve Curtis, 1992; Shanahan ve ark., 2001; Conrad ve ark., 2010, Friedl ve ark., 2010; Gumma ve ark., 2011; Algancı ve ark., 2013; Mialhea ve ark., 2015; Kaynak, 2017).

Literatüre göre uyduların kullanıldığı ve tarımsal amaçlı çalışmalar 1970'li yıllarda başlamış olup ilk olarak Bauer ve ark. (1973) tarafından gerçekleştirilmiştir (Rodriguez-Galiano ve ark., 2012; Dizdaroğlu, 2019). Bauer çalışmasında Landsat 1 uydu görüntüsünü kullanarak, ABD'nin orta batı kısımlarındaki tarlalarında mısır ve soya ürünlerini sınıflandırmıştır (Chappelle ve ark., 1991; Dizdaroğlu, 2019). Özellikle son 10 yıldır uydu sistemlerinin artması ve gelişmiş sınıflandırma algoritmalarının kullanılmasıyla, bilgilerin doğruluğu ve güvenilirliği artmış ve giderek de daha iyi duruma gelmektedir. Piksel ve nesne tabanlı sınıflandırma için literatürde farklı algoritmalar yer almakta ve kullanılmaktadır. Bunlar; Destek Vektör Makineleri (DVM), Rastgele Orman (RO), En Yakın Komşuluk (EYK), Yapay Sinir Ağları (YSA), Karar Ağaçları (KA)'dır.

Uzaktan algılama çalışmaları sayesinde büyük alanların haritalanması kısa sürede gerçekleştirilebilmektedir. Bu alanların arazi örtüsü, tarım yapısı-türü, hızlı ve güncel şekilde yapılmalıdır (Köseoğlu ve Gündoğdu, 2004; Tosun, 2009; Taşcı, 2018). Bu problemde ötürü yapay zekâ algoritmaları ile hızlı bir çözüm yolu önerilmiştir (Saralıoğlu ve Güngör, 2022).

Pal ve Mather (2005), Doğu İngiltere ve Orta İspanya olarak seçtikleri iki bölge için, çok bantlı Landsat-7 ve hiperspektal DAIS uydu görüntülerinden yararlanarak DVM, YSA ve EÇB sınıflandırma yöntemlerini, Dixon ve Candede (2008), Landsat TM 5 uydu görüntüsünü kullanarak Güney Batı Florida bölgesinin arazi kullanımı belirlemek amacıyla YSA, DVM ve EYK sınıflandırma algoritmalarını, Kavzoğlu ve Çölkesen (2009), Landsat ETM+ ve Terra ASTER uydu görüntülerini kullanarak Türkiye'nin Gebze ilçesinin arazi örtüsünü tespiti için çalışma kapsamında DVM ve EYK sınıflandırma yöntemlerini tercih etmişlerdir. Akar ve Görmüş (2019), arazi sınıfı tespiti için, Göktürk-2 ve Hyperion EO-1 uydu görüntülerini kullanarak, rastgele orman ve destek vektör makinesi algoritmalarını, Efe ve Algancı (2023) ücretsiz erişim imkânı sunan Google Earth Engine platformundan yararlanarak, rastgele orman ve regresyon analizi esas alınarak 4 farklı makine

öğrenme algoritmasının sonuçlarını incelemişlerdir. Apaydın ve Abdikan (2021), yapmış oldukları çalışmada, Sentinel-2 uydu görüntüsünden faydalanarak fındık bahçelerinin belirlenmesinde piksel tabanlı yöntemi kullanmışlardır. Bu amaçla 3 farklı makine öğrenme algoritmasının (rastgele orman, K en yakın komşu ve destek vektör makineleri) sonuçlarını değerlendirmişlerdir. Ahady ve Kaplan (2022)' de yapmış oldukları çalışmada ise farklı uydu görüntülerinin sınıflandırmaya etkisinin ne olacağı araştırılmıştır.

Yapılan çalışmalar incelendiğinde sınıflandırmayı etkileyen bazı faktörlerin mevcut olduğu anlaşılmıştır. Misal, kullanılan uydu görüntüsü veya buna bağlı olarak uydunun bant kombinasyonu, kullanılan algoritmaların performansı ile birlikte uygun parametre seçimi ya da çalışmada kullanılan eğitim verisine bağlıdır (Üstüner, 2013).

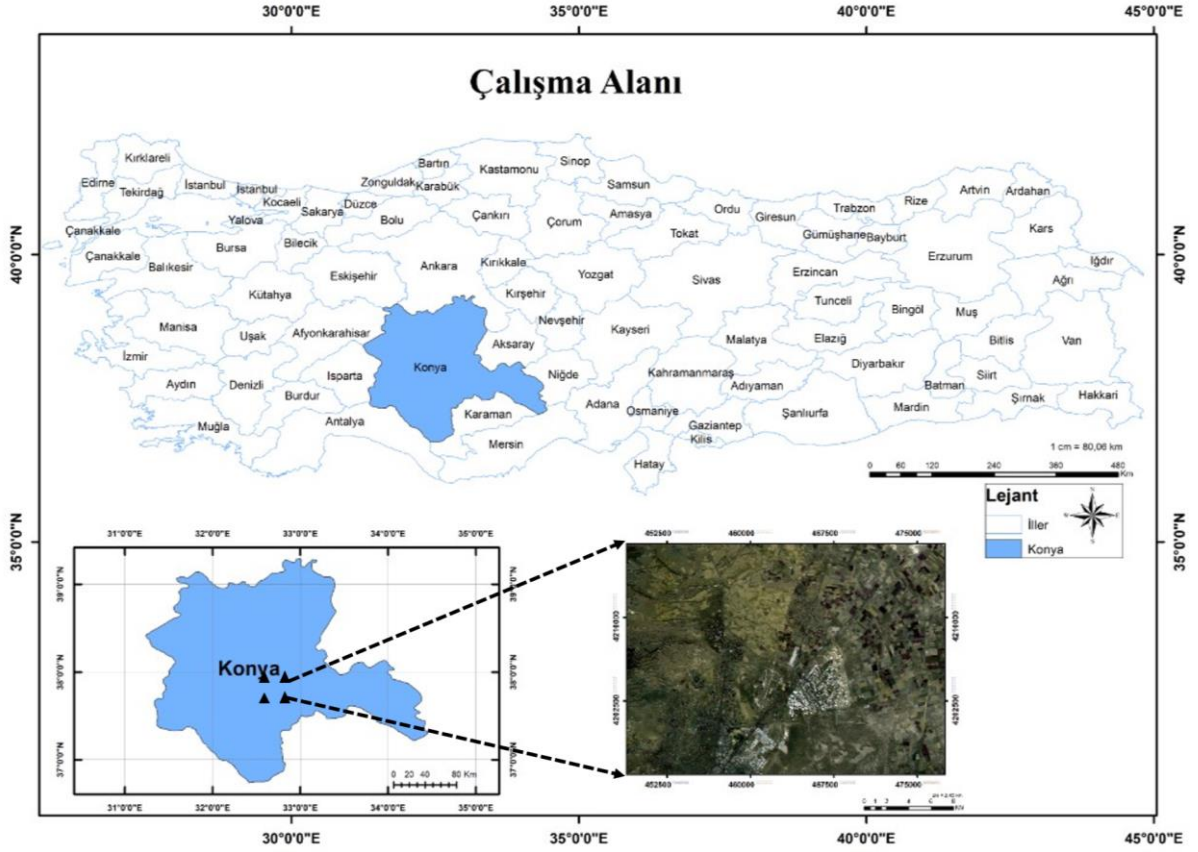
Literatür tarandığında son zamanlarda uydu görüntüsü olarak Avrupa Uzay Ajansı tarafından ücretsiz olarak erişim sağlanan Sentinel-2 (S-2) tercih edilmektedir. Sentinel uydu misyonu, 2015 yılından itibaren radar ve optik verileri sunarken, 2017 yılından itibaren de iklim değişikliklerini tespit etmek ve atmosferde bulunan gazları incelemek amacıyla Sentinel-5P TROPOMI uydusu aracılığıyla verileri sunmaktadır. Örneğin; Sentinel-1 (S-1) radar verileri ile Sayısal Yükseklik Modeli (DEM) araştırmaları (Karabörk ve ark., 2021) ve deformasyon analizi (Orhan, 2021) çalışmaları yapılırken, S-2 optik verileri ile sınıflandırma (Apaydın ve Abdikan, 2021), segmentasyon (Knopp ve ark., 2020) ve su kalitesi (Toming, 2016) gibi çalışmalar yapılmıştır. Ayrıca bitki türü ya da tarımsal ürünlerin belirlenmesi ve tespiti, kıyı çizgi belirlenmesi, hasar tespiti gibi daha birçok çalışmada Sentinel uydu görüntüsü kullanılmaktadır (Altun ve Türker, 2021; Karagöl ve ark., 2021; Polat ve Kaya, 2021; Tunca ve Köksal, 2021).

Bu araştırma kapsamında kontrollü piksel tabanlı sınıflandırma yöntemlerinden olan destek vektör makinası ve rastgele orman algoritmalarının sınıflandırma sonuçlarının karşılaştırılması amaçlanmıştır. Sınıflandırma işleminde kontrollü piksel tabanlı sınıflandırma yöntemi kullanılmıştır. Çünkü bu yöntemin temeli; sadece bir piksel üzerinden işlem yapmak ve her bir pikselin spektral bilgisini esas alarak sınıflandırma işlemini gerçekleştirmektir. Çalışma bölgesi seçilirken de bu durum göz önünde bulundurulmuştur. Detayların sık olduğu kısımlar (bina, yol, yeşillik alan vb.) ve detayların seyrek olduğu alanlar (tarla veya arsa) şeklinde seçim yapılmıştır. Çalışmada 5 sınıf (kurak alan, su alanı, yol, yapı, yeşil bölge) belirlenmiş ve Python v3. ile gerekli kodlamalar yapılarak sınıflandırma işlemi gerçekleştirilmiştir. Ayrıca çalışmada uydu görüntüsünün ön işleme aşamasında SNAP uygulaması kullanılmış ve eğitim verisinin oluşturulmasında da 'Qgis' v3.16'den yararlanılmıştır. Bu çalışmada her iki yöntem (DVM ve RO) göre sınıflandırma işlemi gerçekleştirilerek, elde edilen sonuçların doğrulukları karşılaştırılmıştır.

2. Materyal ve Metot

Çalışma bölgesi olarak Konya ilinin 37°59'29.58"K-32°34'45.47"D kısmında yer almakta ve yaklaşık olarak 600 km² bir alanı kaplamaktadır. Şekil 1'de çalışma alanı verilmiştir.

Yeryüzünün görüntülenmesinde aktif olarak kullanılan uzaktan algılamanın asıl amacı yeryüzü hakkında çeşitli bilgilerin toplanmasına yardımcı olmaktır. Bu amaçla sınıflandırma yöntemi yaygın olarak kullanılmakta ve iki grupta ele alınmaktadır. Bunlar; piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma yöntemleridir. Bu çalışmada görüntü sınıflandırma tekniği olan piksel tabanlı sınıflandırma yöntemi kullanılmıştır.



Şekil 1. Çalışma Alanı

2.1. Piksel (Hücre) Tabanlı Sınıflandırma

Görüntüler satır ve sütunlardan oluşmaktadır ve en temel birimi pikseldir. Görüntüdeki bir piksel hem konumsal hem de spektral bilgileri barındırır. Örneğin; S-2 uydu görüntüsünde 1 piksel içerisinde X ve Y konum bilgisi ile 13 banda ait spektral bilgi bulunmaktadır. Nesne tabanlı sınıflandırma yönteminden sonra piksel tabanlı sınıflandırma yöntemi geliştirilmiştir. Nesne tabanlı yöntemden farklı olarak segmentasyon işlemi bu yöntemde kullanılmamaktadır.

Piksel tabanlı sınıflandırma yaklaşımlarında, görüntü pikselleri, içerdikleri farklı nesnelere spektral özelliklerinde bulunan bilgiye göre analiz edilir ve çeşitli algoritmalar yardımıyla da sınıflara atanır (Campbell ve Wynne, 2011).

Piksel tabanlı sınıflandırmanın bazı negatif yönleri bulunmaktadır. Misal düşük çözünürlüklü uydu görüntüleri kullanılmışsa, bir piksel birden fazla detayı (birden çok arsa, tarla, yapı) ifade edebilir. Bu sebepten ötürü bir piksel içerisindeki detayların ayırt edilmesi problem oluşturmaktadır (Ge ve ark.,

2016). Bu amaçla çalışmamızda 10m konumsal çözünürlüğe sahip S-2 uydu görüntüsünde sınıflandırma işlemi gerçekleştirilmiş olup, sonuçları incelenmiştir. Literatürde piksel tabanlı sınıflandırma işlemi temel olarak iki kısma ayrılmaktadır (Şekil 2). Bunlar; kontrollü sınıflandırma ve kontrolsüz sınıflandırmadır.



Şekil 2. Piksel tabanlı sınıflandırma temel işlem adımları

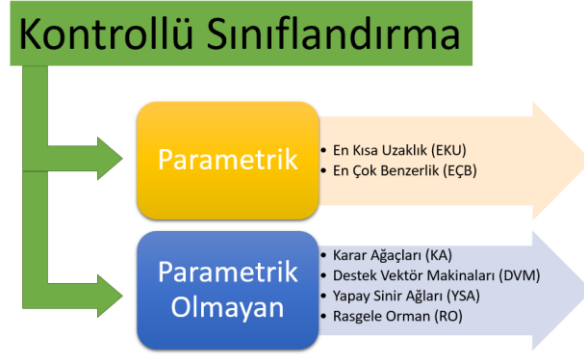
2.1.1. Kontrollü Sınıflandırma

Kontrollü sınıflandırma yönteminde, eğitim verisi oluşturma ve sınıflandırma olmak üzere iki aşamadan oluşur. İlk aşama da kullanılan veriler (uydu görüntüsü veya hava fotoğrafı) üzerinden, çalışmanın amacına bağlı olarak eğitim verisi yani örneklem alanları tanımlanır. Örneklem verilerinin seçilmesi sınıflandırma doğruluğunu etkileyen bir faktördür. Bu nedenle analizi yapan kişinin çalışma bölgesi hakkında gerekli bilgi ve donanıma sahip olması gerekir (Kaynak, 2017).

İkinci aşama olan sınıflandırma işleminde oluşturulan eğitim verisi ve kullanılan algoritmalara bağlı olarak her bir piksel, çevresinde bulunan en yakın pikselin benzerlik gösterdiği örnek sınıfına atanır (Kaynak, 2017). Sınıflandırma sonucunda tespit edilen sınıfların, ayrıntılı olarak tanımlanması önemli bir durumdur.

Uydu görüntüleri kullanılarak sınıflandırma işlemi yapılması durumunda her iki yöntem kıyaslandığında, kontrollü sınıflandırmanın kontrolsüz sınıflandırmaya göre daha çok tercih edilmektedir. Çünkü kontrollü sınıflandırma da güvenirliliğin ve doğruluğun yüksek olmasındandır (Üstüner, 2013)

Eğitim verisinin istatistiksel dağılımının kabul durumuna göre kontrollü sınıflandırma parametrik ve parametrik olmayan şekilde ikiye ayrılmaktadır (Şekil 3). Parametrik sınıflandırmada eğitim verisinin istatistiksel dağılımı üzerine bir kabul varken, parametrik olmayan durumda böyle bir kabul söz konusu değildir (Üstüner, 2013).



Şekil 3. Kontrollü Sınıflandırma Bileşenleri

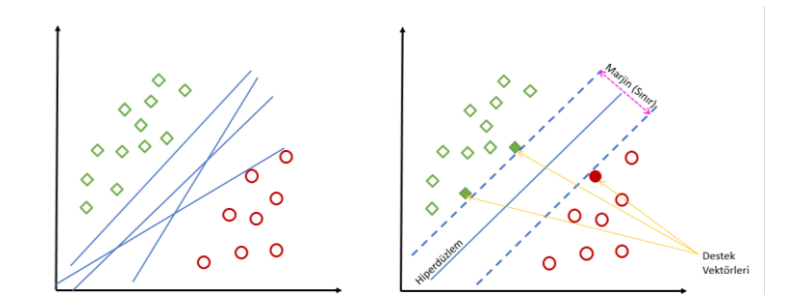
2.1.1.1. Destek Vektör Makinesi Algoritması

Destek vektör makineleri Rus Bilim adamları Vladimir Vapnik ve Alexey Ya tarafından 1970'li yılların sonlarına doğru bulunmuş ve geliştirilmiştir. İlk olarak sınıflandırma problemlerini çözmek için tasarlanmış yöntem, daha sonraki aşamalarda regresyon yöntemine de uyarlanmıştır. Bu yöntem 1970'li yıllarda ortaya çıkmasına rağmen uzaktan algılama alanındaki ilk çalışmalar 1990'lı yıllarda yapılmıştır. DVM yöntemiyle uzaktan algılama alanında yapılan ilk çalışma hiperspektral uydu görüntüleri kullanarak, kontrollü bir sınıflandırma işlemi gerçekleştirilmiştir (Gualtieri ve Cromp, 1998). Son yıllarda da uzaktan algılama çalışmalarında sıklıkla DVM'ler kullanılmaktadır (Foody ve Mathur, 2004; Melgani ve Bruzzone, 2004; Karakuş, 2017; Apaydın ve Abdikan, 2021; Saralıoğlu, 2021; Tunca ve Köksal, 2021).

Destek vektör makineleri (DVM) optimum düzeyde sınıfları birbirinden ayırabilecek, parametrik olmayan istatistiksel bir öğrenme yöntemidir (Vapnik, 1996). Bu yöntemin amacı, sınıfları ayırt edebilecek ve marjinin maksimum olmasını sağlayacak hiperdüzlemi bulmaktır (Dizdaroğlu, 2019). Bir hiperdüzlem,


$$w \cdot x_i + b = 0$$

ile ifade edilir. Denklemden gösterilen x_i hiperdüzlem üzerinde bulunan noktayı, w hiperdüzlemin ait doğrusallığı ve b ise hiperdüzlemin merkezden olan uzaklığı yani eğilim değerini temsil eder. Hiperdüzlem iki ya da üç boyutlu doğruyu ifade ederken, marjin de hiperdüzlem ile en yakın veri noktası arasındaki kısmı ifade eden alandır. Şekil 4' de iki boyutlu ayrılabilir iki sınıfa ait sınıflandırma probleminin doğrusal DVM algoritmasıyla çözüm senaryosu ifade edilmiştir.



Şekil 4. İki boyutlu doğrusal destek vektör makinelerinin çözüm senaryosu

Şekil 4’ de görüldüğü üzere sınırın kenar kısmında yer alan noktalar destek vektörleri olarak isimlendirilir. Uygulamada, veriler çok boyutlu olduğu için doğrusal ayırım yapmak yüksek doğruluklu bir sınıflandırma için yeterli olmamaktadır. Böyle durumlarda doğrusal olmayan DVM algoritmasından bahsedilebilir (Şekil 5). Yumuşak sınır veya zor sınır yöntemlerine ek olarak kernel numarası gibi çözümler geliştirilmiştir. Bu geliştirilen teknikler sınıflandırma probleminin çözerek en uygun şekli almasında ve haritalamada kullanılır (Dizdaroglu, 2019).



Şekil 5. Üç boyutlu doğrusal olmayan destek vektör makinelerinin çözüm senaryosu

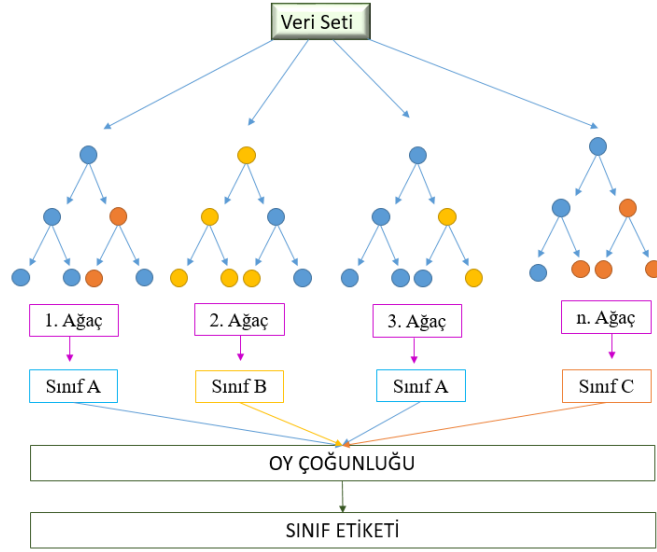
DVM algoritmaların faydaları olduğu kadar, yöntemi uygulayabilmek için gerekli kernellerin seçiminin zor olması dezavantaj olarak ifade etmek mümkündür. Çünkü kernel çeşitlerinin bazıları uzaktan algılama uygulamaları için uygun modeli sağlamayabilir. Literatür incelendiğinde bu alandaki çalışmalarda piksel tabanlı sınıflandırma için, daha çok kullanılan ve doğru sonuçlar verdiği tespit edilen kernel türü Radyal Tabanlı Fonksiyon’dur (Ge ve ark., 2008; Karakuş, 2017). DVM’de yaygın olarak kullanılan kernel çeşitleri, matematiksel olarak ifadeleri ve parametreleri Tablo 1’de verilmiştir. Tabloda geçen C düzenleme (hata) parametresini, d polinomun derecesini, b kayıklık parametresini, γ gamma parametresini ifade etmektedir.

Tablo 1. DVM’de kullanılan kernel çeşitleri ve matematiksel ifadeleri

Kernel Çeşidi	Matematiksel İfadeleri	Parametre Türü
Lineer (Doğrusal)	$K(x_i, x_j) = x_i \cdot x_j$	C
Polinom	$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + b)^d, \gamma > 0, \delta > 0$	d, b, γ, C
Sigmoid	$K(x_i, x_j) = \tanh(-\gamma \ x_i \cdot x_j\ ^2), \gamma > 0, \delta > 0$	b, γ, C
Radyal Tabanlı Fonksiyon	$K(x_i, x_j) = \exp(\gamma(x_i \cdot x_j) - b), \gamma > 0$	γ, C

2.1.1.2. Rastgele Orman Algoritması

Bu teknik Bagging yöntemi (Breiman, 1996) ve Random Subspace yönteminin birleşimiyle oluşmuştur. Yöntemin temelinde, birden çok karar ağacının ürettiği tahminler bir araya getirilerek değerlendirilmesi temeline dayanır (Breiman, 2001). Kısacası, her ağaç bir sınıf tahmin etmekte ve bu sınıflardan en çok oyu alan model tahmini olmaktadır. n adet ağaçtan oluşan rastgele orman algoritması Şekil 6’da verilmiştir.



Şekil 6. n adet ağaçtan oluşan rastgele orman algoritması

Kontrollü sınıflandırma tekniğinde doğruluk, ağaç sayısı, düğüm, dal ve yaprak ile doğru orantılı olarak değişmektedir (Özlem ve Görmüş, 2019). Yani, yöntemde kullanılan ağaç sayısı veya diğer etkenler arttıkça yöntemin doğruluğu da artmaktadır ya da tam tersi durumda geçerli olabilmektedir. Rasgele orman ile karar ağacı yöntem olarak birbirlerine benzese de temel fark rasgele orman da düğümlerin ve dalların oluşması rastgele olarak gerçekleşmektedir.

Diğer makine öğrenme algoritmalarında olduğu gibi bu yöntemin uygulanması için bazı parametrelerin önceden belirlenmesi gerekmektedir. Bu parametreler, oluşturulacak ağaç sayısı, her ağaç sayısı için düğümde kullanılacak örneklem sayılarıdır (Atasever, 2011).

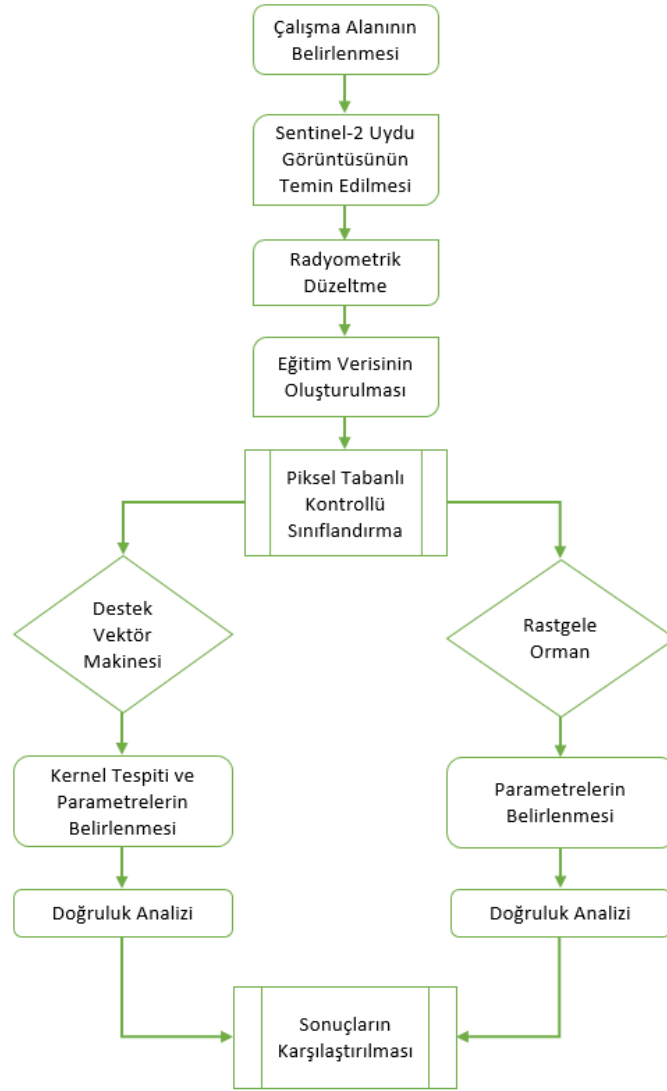
Uygulamada bu yöntem kullanılırken öncelikle rastgele oluşturulacak orman sayısı ve değişken sayısını belirlenmiştir. Yazılan kod ile en iyi parametreler tespit edilmiştir. Bu parametreler; 'Ağacın maksimum derinliği (max_depth)': 10, 'Maksimum özelliklerin sayısı (max_features)': 5, 'Bir düğümü bölebilmek için gereken minimum örnek sayısı (min_samples_split)': 2, 'Ormandaki ağaç sayısı (n_estimators)': 1000' olarak bulunmuştur.

2.1.2. Kontrolsüz (Eğitimsiz) Sınıflandırma

Kontrollü sınıflandırma yönteminde sınıflara ait öncül değer bulunurken, kontrolsüz sınıflandırma yönteminde herhangi bir öncül değeri bulunmamaktadır. Bu yöntemde ilk olarak piksellere ait spektral özellikler ile gruplar belirlenir. Bunun için farklı istatistiksel yöntemler ile doğal olarak oluşturduğu gruplar ile yapılır. Bu grupları oluştururken çeşitli algoritmalarından yararlanır ve bu algoritmalar kümeleme algoritmaları olarak isimlendirilmektedir (Mather ve Koch, 2011; Üstüner, 2013). Ya da kümeleme olarak da ifade edilir. Küme sayısı da algoritma içerisinde yer alan parametrelerden bir tanesi olarak ifade edilir. Kümeleme işleminden sonraki aşamada analiz edilir. Yani belirlenen her küme analiz edilerek etiketlenir ve böylece temsil ettiği sınıfa atanır.

3. Uygulama

Çalışmada 17.11.2020 tarihine ait S-2 uydu görüntüsü kullanılmıştır. Bu uydu görüntüsünün tercih edilmesinin sebebi, ücretsiz olması, yüksek ve orta çözünürlükte görüntülere sahip olmasının yanı sıra literatürdeki çalışmalarda çokça kullanılmasından dolayıdır. Çalışmaya ait iş akışı Şekil 7’de sunulmuştur.



Şekil 7. İş – Akış Çizelgesi

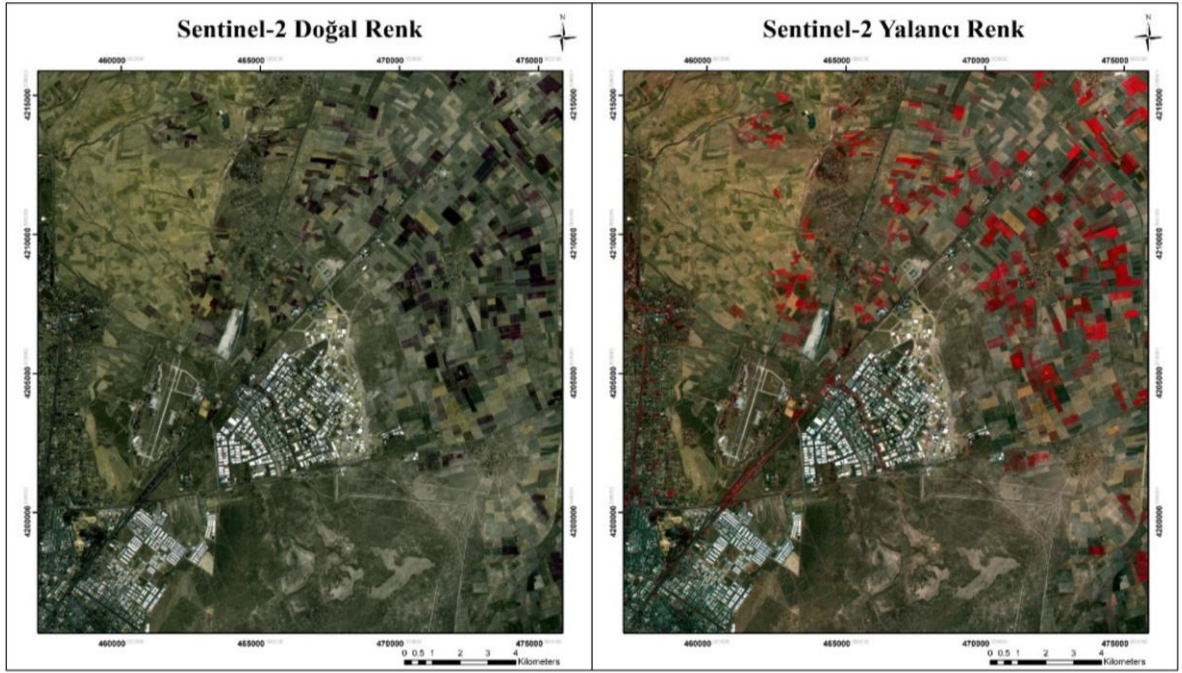
Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı kapsamında S-2A ve S-2B olmak üzere iki eş uydu sisteminden oluşmuştur. 23 Haziran 2015 tarihinde S-2A ve 7 Mart 2017 tarihinde S-2B fırlatılmıştır (ESA, 2021). Uydular yüzey değişikliklerinin izlenmesi, arazinin analiz edilmesi ve acil durum ve yardımlarda bilgi vermek amacıyla gönderilmiş olup, görev süreleri 7 yıl olarak belirlenmiştir. 2018 yılı Mart itibarıyla de kullanıcılara açık hale getirilmiştir. Konumsal çözünürlükleri 10 m, 20 m, 30 m arasında ve radyometrik çözünürlüğü 12 bittir. Toplamda 13 bant içeren uydulara ait spektral bilgiler Tablo 2’de verilmiştir.

Sentinel-2 verileri ESA tarafından sağlanan ve ücretsiz olan SNAP v.8.0 uygulamasında radyometrik çözünürlüğü için ön işleme tabi tutulmuştur. Çalışmada 10 m konumsal çözünürlüğe sahip olan

kırmızı, yeşil, mavi ve yakın kızıl ötesi 4 adet bant kullanılmıştır. Şekil 8’de doğal renk ve yalancı renk görüntüleri sunulmuştur.

Tablo 2. Sentinel-2 uydusuna ait spektral bilgiler (ESA, 2021)

Bant No	Bant İsmi	Konumsal Çözünürlük (m)	Sentinel-2A		Sentinel-2B	
			Dalga Boyu (nm)	Bant Genişliği (nm)	Dalga Boyu (nm)	Bant Genişliği (nm)
1	Kıyı aerosol	60	443,9	27	442,3	45
2	Mavi	10	496,6	98	492,1	98
3	Yeşil	10	560,0	45	559	46
4	Kırmızı	10	664,5	38	665	39
5	Bitki Örtüsü	20	703,9	19	703,8	20
6	Bitki Örtüsü	20	740,2	18	739,1	18
7	Bitki Örtüsü	20	782,5	28	779,7	28
8	Yakın Kızıl Ötesi	10	835,1	145	833	133
8A	Bitki Sıcak Nokta	20	864,8	33	864	32
9	Su Buharı	60	945,0	26	442,3	27
10	Kısa Dalga Kızılötesi (Cirrus)	60	1373,5	75	1376,9	76
11	Kısa Dalga Kızılötesi	20	1613,7	143	1610,4	141
12	Kısa Dalga Kızılötesi	20	2202,4	242	2185,7	238



Şekil 8. Çalışma bölgesine ait Doğal Renk ve Yalancı Renk

Qgis yazılımı da eğitim verisi oluşturmak amacıyla kullanılmıştır. Yeşillik, yol, yapı, kurak alan ve su alanı olarak 5 sınıf belirlenmiştir. Bu sınıfların içerisinde su alanı haricinde hepsinde örneklem sayısı 100 piksel olarak belirlenmiştir. Toplamda 450 piksel eğitim verisi, 135 piksel ise test verisi olarak seçilmiştir. Sınıflandırma için DVM ve RO algoritmasını kullanmak amacıyla Python v3'de uygulamaya yönelik gerekli kodlar yazılmıştır.

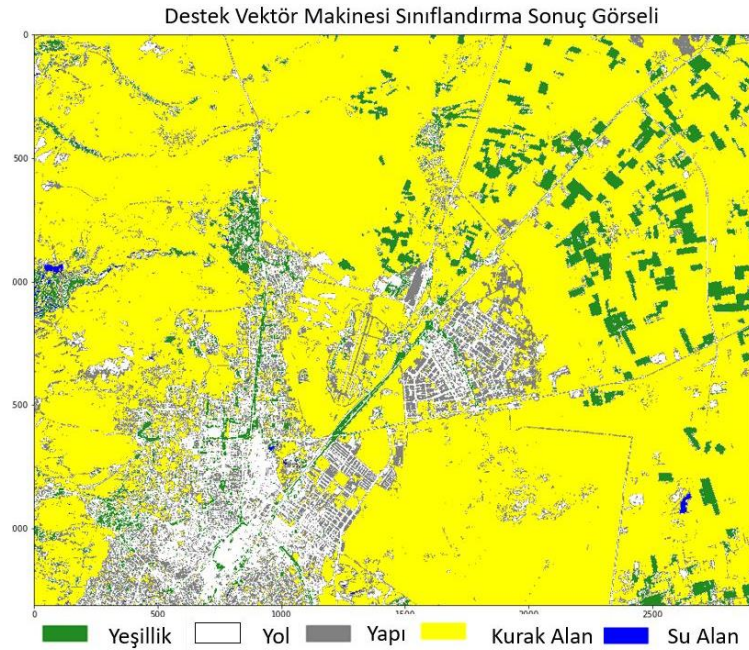
Python, 1980'lerin sonlarına doğru Guido van Rossum tarafından tasarlanan açık kaynak kodlu bir programlama dilidir. Linux, macOS ve Windows işletim sisteminde rahatlıkla kullanılan bir yazılımdır. Çalışma kapsamında arazi örtüsünün tespitini belirlemek amacıyla 5 sınıf belirlenmiştir. Ayrıca numpy, matplotlib, pandas, geopandas, rasterio, scikit-learn kütüphanelerinden yararlanılmıştır. Python'ın temel kütüphanesi olan numpy çok boyutlu diziler ve matrisler için matematiksel işlevleri gerçekleştirmek, matplotlib verileri görselleştirmek ve istatistiksel grafikleri oluşturmak, pandas analiz ve veri işlemek için kullanılmıştır. Geopandas ve rasterio kütüphaneleri ise harita çizmek ve coğrafi referanslı koordinatlar için dizileri içermektedir. Sınıflandırma yapmak amacıyla kullanılan makine öğrenmesi algoritmaları scikit-learn kütüphanesi aracılığıyla içeri aktarılmıştır. Ayrıca çalışmada kullanılan destek vektör makine algoritmasının kernel seçiminde radyal tabanlı fonksiyon tercih edilmiştir. Düzenleme (hata) parametresi ve γ gamma parametresi için birden fazla değer denenmiş olup, en iyi parametre değeri seçilmiştir. Rastgele orman sınıflandırıcısı için, parametre seçiminde, ağacın maksimum derinliği, maksimum özelliklerin sayısı, ormandaki ağaç sayısı gibi değişkenler belirlenmiştir.

Gerekli kodlar yazılarak DVM ve RO sonuç ürünü Şekil 9 ve Şekil 10’da sunulmuştur. DVM ile elde edilen sonuçlar incelendiğinde, genel doğruluk değeri %96,7 ve kappa değeri 0.9535 olarak elde edilmiştir. RO ise, genel doğruluk değeri %86.67 ve kappa değeri 0.8148 olarak hesaplanmıştır.

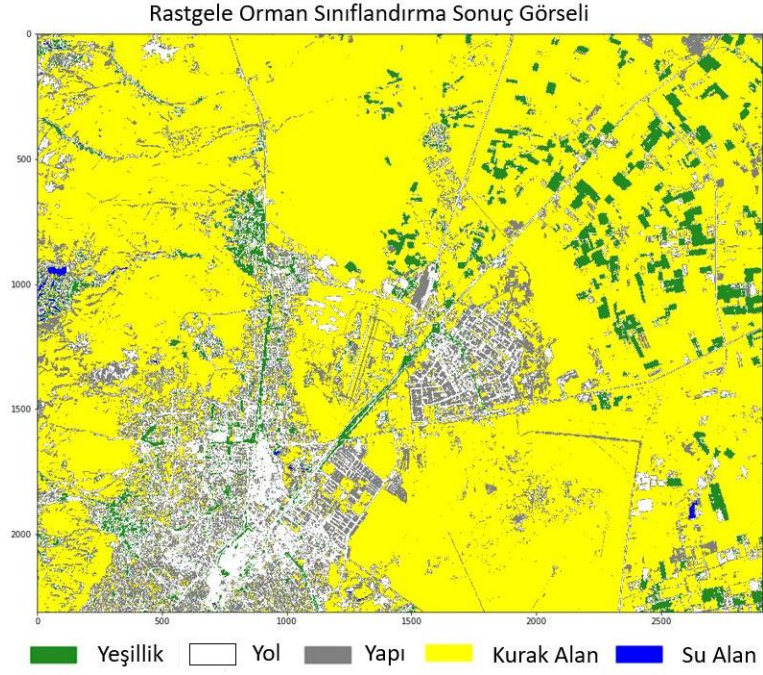
Sonuç görselleri incelendiğinde Şekil 9’daki yapılar ve sulak alanları başarılı bir şekilde sınıflandırılmıştır. Fakat rastgele orman algoritmasında, Şekil 10’un sağ alt köşesindeki yapılar düzgün olarak belirlenememiştir. Çünkü rastgele orman algoritmasında tahmin çoğunluğuna bağlı olarak bir sınıfa atama işlemi gerçekleştirilir. Yine aynı bölge içerisinde tek bir yapı detayı da sulak alan olarak yanlış bir sınıflandırma işlemi olmuştur. Yöntemin sonucunu negatif yönde etkilemektedir. Ayrıca her iki yöntemde de yolların sınıflandırılması işlemi görüntünün bazı bölgelerde doğru bir şekilde gerçekleştirilememiştir. Bunun sebebi bu kısımlardaki yapı ve yol detayların birbirine yakın olması ve sık olmasından kaynaklıdır. Çünkü bir piksel içerisine birden fazla detay girmektedir.

Yeşillik alanları incelediğinde, tarım alanları ve şehir merkezi içerisinde yeşil dokudaki canlılar doğru bir şekilde sınıflandırılmıştır. Bölgenin coğrafi yapısından dolayı büyük bir kısmı kurak arazi olmuştur.

S-2 uydu görüntüsü verileri kullanılarak RO ve DVM algoritmaları ile sınıflandırma performansı değerlendirilmiştir. Sınıflandırmadaki genel doğruluklara elde edilen sonuçlara bakıldığında başarılı bir işlem gerçekleştiği görülmektedir.

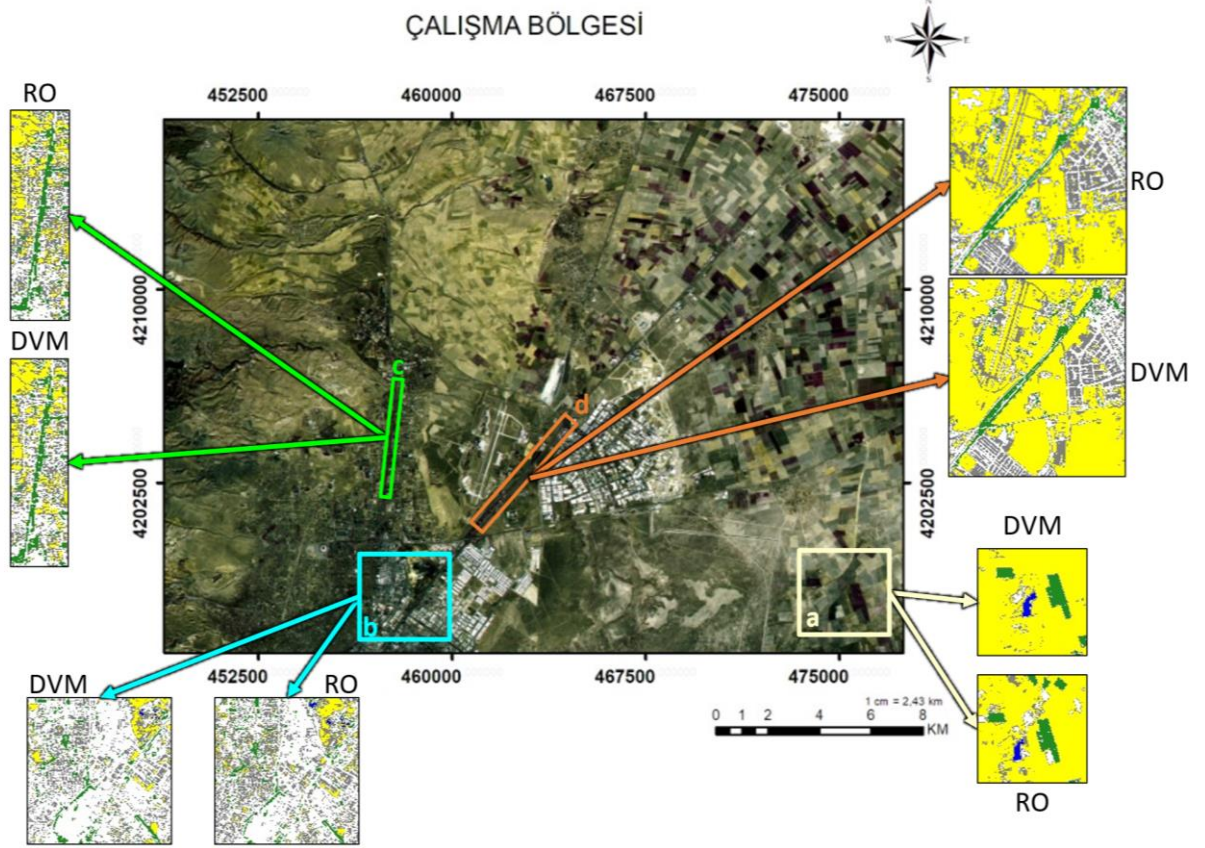


Şekil 9. DVM sonucu



Şekil 10. RO sonucu

Şekil 11’de her iki algoritma tarafından yanlış tespit edilen kısımlar ayrıntılı bir şekilde gösterilmiştir. Şekil 11.a’da yaklaşık 450m²’lik yeşil alan su alanı olarak tespit edilmiştir. Şekil 11.b’de gösterilen alan içerisindeki yapıların çoğu yol olarak algılanmıştır. Çünkü uydunun konumsal çözünürlüğünden ötürü bu kısımda bulunan yeşil alanlar, yapılar ve yollar ayırt edilememiştir. Yine aynı sebepten Şekil 11.c ve Şekil 11.d’de yol ağı iyi tespit edilememiştir. Bunun da temel sebebi bir piksel içerisinde yol kenarında bulunan ağaçların girmesidir.



Şekil 11. Uygulama sonucu yanlış sınıflandırma görseli

Elde edilen sonuçlar daha önce yapılmış birçok çalışma ile uyumlu olduğu görülmektedir. Örneğin; Kesthar ve ark. (2017) çalışmasında arazi değişimini analiz etmek için Landsat uydu görüntüsünü kullanmışlardır ve DVM algoritmasının RO göre sınıflandırma doğruluğunun daha iyi olduğunu öne sürmüşlerdir. Aguilera (2020) ve Apaydın ve Abdikan (2021) yapmış oldukları çalışmada farklı makine öğrenme algoritmalarını kullanmışlar ve DVM daha iyi sonuç verdiğini tespit etmişlerdir. Buna karşılık, Rodriguez-Galiano ve ark. (2012), makine öğrenme algoritmasından karar ağaçları, yapay sinir ağları, DVM ve RO sınıflandırmasını yapmış ve RO'nın doğruluğunun diğerlerine göre daha iyi geldiğini tespit etmiştir. DVM algoritması kullanırken sadece sigmoid ve polinomal kernel çeşidini kullanmıştır. Yapılan çalışmalar incelendiğinde anlaşılıyor ki, kullanılan algoritmalarındaki parametrelerin seçimi oldukça önemlidir.

4. Sonuçlar

Bu çalışmada, S-2 uydu görüntüsü kullanılarak piksel tabanlı sınıflandırma yöntemiyle, makine öğrenme algoritması olan DVM ve RO algoritmaları kıyaslanmıştır. Çalışma kapsamında eğitim verisi olarak 5 sınıf (kurak alan, su alanı, yol, yapı, yeşil bölge) için toplamda 450 piksel seçilmiştir. Elde edilen doğruluk sonuçlarına göre DVM'nin RO'a göre kıyasla daha iyi olduğu tespit edilmiştir. DVM'nin doğruluk sonucu %96,7 iken, RO'da %86,67 olarak bulunmuştur.

Sonuç ürünleri değerlendirildiğinde, alt kısımlardaki yolların ve yapıların çok iyi tespit edilmediği anlaşılmıştır. Bunun sebebi uydunun konumsal çözünürlüğünün düşük olması ve bir piksel içerisinde düşen detayların ayırt edilmemesinden kaynaklanmaktadır. Çünkü Ge ve ark. (2016), yaptıkları çalışmada bu durumu dile getirmişlerdir.

Ayrıca çalışmadaki eğitimi verisi miktarının da sonucu etkileyebileceği düşünülmektedir. Sonraki çalışmalarda farklı zamanlarda, konumsal çözünürlüğü daha iyi olan uydu görüntüleri kullanılabilir ve eğitim verisinin sayısı çoğaltılıp sonuçlar incelenebilir.

Sonuç olarak, makine öğrenme algoritmalarından RO ve DVM ile S-2 uydu görüntüsü sınıflandırılmasında oldukça tatmin edici bir performans sergilediği görülmüştür.

Çıkar Çatışması Beyanı

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Araştırmacıların Katkı Oranı Beyan Özeti

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan ederler.

Kaynakça

- Akar Ö., Tunç Görmüş E. Göktürk-2 ve Hyperion EO-1 uydu görüntülerinden rastgele orman sınıflandırıcısı ve destek vektör makineleri ile arazi kullanım haritalarının üretilmesi. *Geomatik* 2019; 4(1): 68-81.
- Aguilera MAZ. Classification of land-cover through machine learning algorithms for fusion of Sentinel-2a and planetscope imagery. In 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference 2020; 246-253.
- Ahady AB., Kaplan G. Classification comparison of Landsat-8 and Sentinel-2 data in Google Earth Engine, study case of the city of Kabul. *International Journal of Engineering and Geosciences* 2022; 7(1): 24-31.
- Algancı U., Sertel E., Ozdogan M., Ormeci C. Parcel-Level identification of crop types using different classification algorithms and multi-resolution imagery in southeastern Turkey. *Photogrammetric Engineering & Remote Sensing* 2013; 79(11): 1053-1065.
- Altun M., Türker M. Çoklu zamanlı sentinel-2 görüntülerinden tarımsal ürün tespiti: Mardin – Kızıltepe örneği. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi* 2021; 21(4): 881-899.
- Apaydın C., Abdikan S. Fındık bahçelerinin Sentinel-2 verileri kullanılarak piksel tabanlı sınıflandırma yöntemleriyle belirlenmesi. *Geomatik* 2021; 6(2): 107-114.

- Atasever ÜH. Uydu görüntülerinin sınıflandırılmasında hızlandırma (boosting), destek vektör makineleri, rastgele orman (random forest) ve regresyon ağaçları yöntemlerinin kullanılması. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, sayfa no:86, Kayseri, Türkiye, 2011.
- Barret EC., Curtis LE. Introduction to environmental remote sensing. Third ed. Chapman ve Hall: London; 1992.
- Breiman L. Bagging predictors. Machine Learning 1996; 24(2): 123-140.
- Breiman L. Random forests. Machine Learning 2001; 45(1): 5-32.
- Campbell JB., Wynne RH. Introduction to remote sensing. 5th ed. NewYork, USA: The Guilford Press; 2011.
- Chappelle EW., Kim MS., McMurtrey JE. Ratio analysis of reflectance spectra (rars): an algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b, and carotenoids in soybean leaves. Remote Sensing of Environment 1991; 39: 239–247.
- Conrad C., Fritsch S., Zeidler J., Rucker G., Dech S. Per-Field irrigated crop classification in arid Central Asia using spot and aster data. Remote Sensing 2010; 2(4): 1035 – 1056.
- Çelik YB. Mısır ve pamuk ekili alanların çok zamanlı uydu görüntüleri ve obje tabanlı sınıflandırma yöntemi ile tespiti. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, sayfa no:71 İstanbul, Türkiye, 2015.
- Dixon B., Candade N. Multispectral landuse classification using neural networks and support vector machines: one or the other or both. International Journal of Remote Sensing 2008; 29(4): 1185-1206.
- Dizdaroğlu T. Sentinel-1 ve Sentinel-2 verilerinden tarımsal ürün sınıflandırması için makine öğrenme algoritmalarının karşılaştırılması. Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, sayfa no:131, Ankara, Türkiye, 2019.
- ESA. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2> Erişim Tarihi: 11.01.2021.
- Efe E., Alganci U. Çok zamanlı Sentinel 2 uydu görüntüleri ve makine öğrenmesi tabanlı algoritmalar ile arazi örtüsü değişiminin belirlenmesi. Geomatik 2023; 8(1): 27-34.
- Foody GM., Mathur A. A relative evaluation of multiclass image classification by support vector machines. IEEE Transactions on Geoscience and Remote Sensing 2004; 42(6): 1335-1343.
- Friedl MA., Sulla-Menashe D., Tan B., Schneider A., Ramankutty N., Sibley A., Huang XM. Modis collection 5 global land cover: 46 algorithm refinements and characterization of new datasets. Remote Sensing of Environment 2010; 114(1): 168-182.
- Ge QZ., Ling ZC., Qiong L., Hui XX., Zhang G. High efficient classification on remote sensing images based on Svm. Remote Sensing and Spatial Information Sciences 2008; 37(B2).

- Ge Y., Chen Y., Stein A., Li S., Hu J. Enhanced subpixel mapping with spatial distribution patterns of geographical objects. *IEEE Transactions on Geoscience and Remote Sensing* 2016; 54(4): 2356-2370.
- Gualtieri JA., Cromp RF. Support vector machines for hyperspectral remote sensing classification. *Proceedings SPIE* 1998; 3584: 221- 232.
- Gumma MK., Nelson A., Thenkabail PS., Singh AN. Mapping rice areas of South Asia using Modis multitemporal data. *Journal Application Remote Sensing* 2011; 5: 95–113.
- Karabörk H., Makineci HB., Orhan O., Karakus P. Accuracy assessment of dems derived from multiple sar data using the Insar technique. *Arabian Journal for Science and Engineering* 2021; 46(6): 5755-5765.
- Karagöl S., Bayram B., Erdem F., Bakirman T. Aktarımlı öğrenme ile Sentinel-2 görüntülerinden kıyı çizgisi bölütlemesi. *Türkiye Uzaktan Algılama Dergisi* 2021; 3(1): 1-7.
- Karakuş P. Çok zamanlı uydu görüntü verileri ile tarımsal ürünlerin belirlenmesi ve verim tahmini. Selçuk Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, sayfa no:124, Konya, Türkiye, 2017.
- Kavzoglu T., Çölkesen I. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation* 2009; 11(5): 352-359.
- Kaynak T. Nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, sayfa no:144, Kayseri, Türkiye, 2017.
- Keshtkar H., Voigt W., Alizadeh E. Land-cover classification and analysis of change using machine-learning classifiers and multi-temporal remote sensing imagery. *Arabian Journal of Geosciences* 2017; 10(6): 1-15.
- Knopp L., Wieland M., Rättich M., Martinis S. A deep learning approach for burned area segmentation with Sentinel-2 data. *Remote Sensing* 2020; 12(15): 2422.
- Köseoğlu M., Gündoğdu KS. Arazi toplulaştırma planlama çalışmalarında uzaktan algılama tekniklerinden yararlanma olanakları. *Uludağ Üniversitesi Ziraat Fakültesi Dergisi* 2004; 18(1): 45-56.
- Mather PM., Koch M. Computer processing of remotely - Sensed images: An. Introduction. Fourth Edition. Wiley-Blackwell Copernicus Open Access Hub; ESA, 2011.
- Melgani F., Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing* 2004; 42(8): 1778-1790.
- Mialhea F., Gunnell Y., Ignacio JAF., Delbart N., Oganía JL., Henry S. Monitoring land-use change by combining participatory land-use maps with standard remote sensing techniques: showcase from a remote forest catchment on Mindanao Philippines. *International Journal of Applied Earth Observation and Geoinformation* 2015; 36: 69–82.

- Orhan O. Monitoring of land subsidence due to excessive groundwater extraction using small baseline subset technique in Konya, Turkey. *Environmental Monitoring and Assessment* 2021; 193(4):1-17
- Özlem A., Görmüş ET. Göktürk-2 ve Hyperion EO-1 uydu görüntülerinden rastgele orman sınıflandırıcısı ve destek vektör makineleri ile arazi kullanım haritalarının üretilmesi. *Geomatik* 2019; 4(1): 68-81.
- Pal M., Mather PM. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing* 2005; 26(5): 1007-1011.
- Polat N., Kaya Y. Çok bantlı uydu görüntüleriyle orman yangınlarında hasar tespiti. *Bartın Orman Fakültesi Dergisi* 2021; 23(1): 172-181.
- Rodriguez-Galiano VF, Ghimire B., Rogan J., Chica-Olmo M., RigolSanchez JP. An assessment of the effectiveness of a random forest classifier for landcover classification. *ISPRS Journal of Photogrammetry and Remote Sensing* 2012; 67: 93–104.
- Saralioğlu E. Pankromatik bandın piksel tabanlı sınıflandırmaya etkisi. *Turkish Journal of Remote Sensing and GIS* 2021; 2(1): 32-40.
- Saralioğlu E., Güngör O. Yüksek çözünürlüklü uydu görüntülerinden daha hızlı bölge tabanlı derin öğrenme modeli ile bina tespiti. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi* 2022; 12(2): 550-563.
- Shanahan JF., Schepers JS., Francis DD., Varvel GE., Wilhelm WW., Tringe JM., Schlemmer MR., Major DJ. Use of 47 remote-sensing imagery to estimate corn grain yield. *Agronomy Journal* 2001; 93(3): 583-589.
- Taşcı I. Orta çözünürlüklü uydu görüntüleri kullanarak yanmış orman alanlarının farklı sınıflandırma yöntemleri ile haritalanması. *Anadolu Üniversitesi Yüksek Lisans Tezi*, sayfa no:110, Turkey, 2018.
- Toming K., Kutser T., Laas A., Sepp M., Paavel B., Nöges T. First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. *Remote Sensing* 2016; 8(8): 640
- Tosun AG. Hayrabolu sulama sisteminde ürün dağılımının uydu görüntüleri yardımı ile belirlenmesi. *Namık Kemal Üniversitesi Yüksek Lisans Tezi*, sayfa no:45, Tekirdağ, Türkiye, 2009.
- Tunca E., Köksal E. Sentinel-2 uydu görüntülerinden bitki türlerinin makine öğrenmesi ile belirlenmesi. *ÇOMÜ Ziraat Fakültesi Dergisi* 2021; 9(1): 189-200.
- Üstüner M. Destek vektör makineleri yöntemi ile arazi kullanımı sınıflandırılmasında kernel fonksiyonlarına ait karşılaştırmalı parametre duyarlık analizi: rapideye ve spot örneği. *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi*, sayfa no:74, İstanbul, Türkiye, 2013.
- Vapnik VN. The nature of statistical learning theory. New York: Springer-Verlag; 1996.