



Rastgele orman algoritması ve Sentinel-2 MSI ile fındık ekili alanların belirlenmesi: Piraziz Örneği

Seda Terzi Türk^{*1,2} , Filiz Bektaş Balçık³ 

¹ İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, Coğrafi Bilgi Teknolojileri, İstanbul, Türkiye

² İstanbul Topkapı Üniversitesi, Plato MYO, Mimarlık ve Şehir Planlama Bölümü, İstanbul, Türkiye

³ İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, İstanbul, Türkiye

Anahtar Kelimeler

Uzaktan Algılama
Rastgele Orman Sınıflandırması
Sentinel-2 MSI
Fındık Ekili Alanlar

Araştırma Makalesi

Geliş: 08.06.2022
Revize: 07.12.2022
Kabul: 13.12.2022
Yayınlanma: 15.02.2023



Öz

Türkiye’de yetiştirilen sert kabuklu meyvelerin başında gelen fındık, özellikle Doğu Karadeniz bölgesi için ekonomik olarak büyük önem taşımaktadır. Bu çalışmada, 22 Ekim, 2020 tarihli Sentinel-2 MSI uydu görüntüsü bantları ve hesaplanan indeksler ile oluşturulan farklı veri setleri kullanılarak fındık ekili tarım alanları belirlenmiştir. Çalışmaya dâhil edilen farklı bitki indekslerinin hesaplanması ile 5 veri seti üretilmiştir. Giresun ili Piraziz ilçesi çalışma bölgesi seçilmiştir. Sınıflandırma işlemi için rastgele orman (RO) görüntü sınıflandırma yöntemi kullanılmıştır. Çalışma alanında 7 farklı Arazi Kullanımı/Arazi Örtüsü (AKAÖ) tipleri tanımlanmıştır. Birinci veri seti için; seçilen Sentinel-2 MSI bantları RO algoritması ile sınıflandırılmıştır. Diğer veri setlerinde sırasıyla; Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), Yeşil Bant Normalize Edilmiş Fark Bitki Örtüsü İndeksi (GNDVI) ve Normalize Edilmiş Fark Kırmızı Kenar İndeksi (NDVIre) eklenmiştir. 5 veri setine ait sınıflandırma sonuçları hata matrisi kullanılarak karşılaştırılmıştır. McNemar testi sonuçlarına göre her veri seti için sınıflandırma doğruluğu arasındaki farkların istatistiksel olarak anlamlı olmadığı görülmüştür. Veri seti 1 için hesaplanan genel doğruluk %98.98 ve Kappa değeri 0,98 ile diğer dört veri setinden daha yüksek elde edilmiştir.

Determination of hazelnut cropped areas by random forest algorithm and Sentinel-2 MSI: A case study of Piraziz

Keywords

Remote Sensing
Random Forest Classification
Sentinel-2 MSI
Hazelnut Planted Areas

Research Article

Received: 08.06.2022
Revised: 07.12.2022
Accepted: 13.12.2022
Published: 15.02.2023

Abstract

Hazelnut, which is one of the leading hard-shelled fruits grown in Turkey, is of great economic importance especially for the Eastern Black Sea region. In this study, hazelnut cultivated agricultural areas were determined using different data sets created with Sentinel-2 MSI satellite image bands and calculated indices dated 22 October, 2020. 5 data sets were produced by calculating the different plant indices included in the study. Giresun province Piraziz district has been selected as the study area. Random forest (RO) image classification method was used for the classification process. 7 different Land Use/Land Cover (LULC) types have been defined in the study area. For the first data set; selected Sentinel-2 MSI bands were classified by RO algorithm. In other data sets, respectively; added Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI) and Normalized Difference Red Edge Index (NDVIre). The classification results of the 5 data sets were compared using the error matrix. According to the McNemar test results, it was seen that the differences in classification accuracy for each data set were not statistically significant. The overall accuracy calculated for dataset 1 was 98.98% and Kappa value was 0.98, higher than the other four datasets.

1. Giriş

Türkiye’de fındık, yıl boyunca bol yağış alan iklim ve topoğrafik koşullarıyla zengin bitki örtüsüne sahip olan Karadeniz bölgesinde yetişmektedir (Kayalak, 2009). Genelde eğimi yüksek arazilerde ve diğer bitki örtüsü türleri ile bir arada bulunmaktadır. Ayrıca fındık, Türkiye’nin Karadeniz hattı boyunca yetişmekle birlikte Doğu Karadeniz’in Ordu ve Giresun ilçelerinde yoğunlaşarak, Türkiye’nin en yüksek zirai ihracat ürünlerinden birisidir. Dünya fındık üretiminin ortalama %70’ini gerçekleştiren Türkiye, fındık ihracatı ile yıllık yaklaşık 2 milyar dolar gelir elde ederek ekonomisine katkı sağlamaktadır (Doğru, 2020). Fındığın sağladığı hem yüksek eğimli arazilerin değerlendirilmesi hem de ekonomik faydası göz önüne alınırsa, fındık ekili alanlara ait güncel ve yüksek doğruluklu verilerin üretilmesi bu alanların sürdürülebilir olarak değerlendirilmesi açısından önemlidir.

Günümüzde dinamik yapıya sahip uydu teknolojileri ve uzaktan algılamaya tekniklerinden tarım arazilerinin kullanım durumunun belirlenmesinde sıklıkla faydalanılmaktadır. Uydu görüntülerinin çeşitli makine öğrenme algoritmaları ile sınıflandırılması sonucunda arazi kullanım ve arazi örtüsü (AK/AÖ) hakkında bilgi üretilmekte ve bu bilgiler de etkin olarak tarım alanlarının sürdürülebilir yönetim politikalarına altlık oluşturmaktadır (Delen & Balık Şanlı, 2017).

Literatürde uzaktan algılama verileri ile fındık ekili alanların tespiti için farklı çalışmalar mevcuttur. Kavzoğlu & Reis, (2008), Trabzon ilinde çay ve fındık alanlarının tespiti için yaptıkları çalışmada Landsat ETM+ uydu görüntüsü kullanmışlardır. Çalışmada yapay sinir ağları (YSA) ve en çok benzerlik (EÇB) kontrollü sınıflandırma algoritması uygulanmıştır. Sınıflandırma sonucu genel doğruluk %93.62, kappa 0.9263 olarak YSA yönteminde daha iyi sonuçlar vermiştir. Ünal ve ark., (2010), tarafından fındık ekili alanların belirlenmesi için yapılan çalışmada Giresun ili merkez ilçesinde SPOT, Quickbird-Pan ve IKONOS uydu görüntüleri kullanılmıştır. Kontrollü sınıflandırma yöntemi kullanılan çalışmada genel doğruluk %79,05, kappa değeri 0.75 olarak elde edilmiştir. Ayrıca sınıflandırma doğruluğunu farklı eğim ve bakı gruplarında uygulayarak eğim aralığının %10-30 olduğu yerlerde %85.71, bakı gruplandırmasında kuzey bakı yönünde %86.67 olarak belirlemişlerdir. Reis & Taşdemir, (2010), Trabzon ili Bengisu beldesinde yüksek mekânsal çözünürlüğe sahip Quickbird uydu görüntüsü kullanarak fındık ekili alanların tespitini yapmışlardır. Çalışmada kendini örgütleyen eşlemler (Self Organizing Maps-SOM) sınıflandırma algoritması uygulanmıştır. SOM sınıflandırması, sadece görüntüye ait spektral bantlara uygulandığında genel doğruluk %82, kappa değeri 0.73 elde edilirken; çalışmaya Gabor öznitelik bilgisi dâhil edildiğinde genel doğruluk %89, kappa 0.84 olarak hesaplanmıştır. Sonuçlar kıyaslandığında Gabor öznitelik bilgisi ile fındık ekili alanların diğer odunsu bitkilerden ayırt edilmesinde etkili olduğu tespit edilmiştir. Sakarya ilinde yapılan çalışmada ise 2007 yılına ait Landsat uydu görüntüsü kullanılarak en çok benzerlik sınıflandırma algoritması ile fındık ekili alanların tespiti yapılmıştır.

Sınıflandırma sonucu genel doğruluk %86, kappa 0.811 olarak elde edilmiştir. (Şener ve ark., 2013). Akar & Güngör, (2013), tarafından yapılan çalışmada Trabzon ili Sürmene ilçesinde çay ve fındık alanlarının yoğun bulunduğu yerde 8 bantlı multispektral (MS) ve pankromatik (PAN) WorldView-2 uydu görüntüleri kullanılarak sınıflandırma gerçekleştirilmiştir. RO sınıflandırması sonucu genel doğruluk %79.05, kappa 0.75 olarak elde edilmiştir. Daha sonraki aşamada PAN görüntüsü üzerinde farklı filtre boyutlarının farklı yönlerde uygulanması ile eş dizimlilik matrisi (EDM) oluşturulmuş ve bu matris yardımıyla doku özellikleri çıkarılmıştır. Doku özellikleri kullanılarak yapılan sınıflandırmada genel doğruluk %84.08, kappa 0.81 değerlerine yükselmiştir. Bu da doku özelliğinin sınıflandırmadaki başarısını ortaya koymuştur. Bir başka çalışmada, Trabzon ili Beşikdüzü ilçesine ait fındık ekili alanlar 2019 yılına ait Sentinel-2 MSI uydu görüntüsünde 10m mekânsal çözünürlüğe sahip spektral bantlar kullanılarak belirlenmiştir. Sınıflandırmada destek vektör makineleri (DVM), rastgele orman (RO) ve K en yakın komşu (K-EYK) makine öğrenme algoritmaları kullanılarak bu üç algoritmanın fındık ekili alanların belirlenmesindeki performansı karşılaştırılmıştır. En yüksek genel doğruluk %91.09 ve 0.86 kappa değeri olarak DVM sonucu elde edilmiş ve bu yöntemi sırasıyla RO ve K-EYK takip etmiştir (Apaydın & Abdikan, 2021). Avustralya’nın Yeni Güney Galler’deki Riverina bölgesinin 6200 km²’lik alanında Sentinel-1 (SAR) ve Sentinel-2 MSI uydu görüntüleri kullanılarak fındığın da dahil olduğu 12 mahsul sınıfı haritası oluşturulmuştur. Sınıflandırma ve regresyon ağacı tekniği (SRAT), RO ve DVM makine öğrenme algoritmaları sınıflandırmada kullanılmış ve en yüksek genel doğruluk %97.7 ile DVM sonucu elde edilmiştir (Brinkhoff ve ark., 2019).

Bu çalışmada, RO kontrollü sınıflandırma algoritması Sentinel-2 MSI uydu görüntüleri kullanılarak uygulanmıştır. Giresun ili Piraziz ilçesi çalışma bölgesi olarak seçilmiştir. Çalışma bölgesinde çeşitli AK/AÖ kategorileri tanımlanmıştır. Beş farklı veri seti üretilmiş ve RO yöntemiyle sınıflandırılmıştır. Birinci veri seti için Sentinel-2 MSI uydu görüntüsünün bantlar arasında korelasyonuna bakılarak belirlenen 6 bant (bant2, bant3, bant4, bant8a, bant11 ve bant12) seçilmiştir. Orijinal bantların yanı sıra Sentinel-2 MSI görüntüsü ile Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), Yeşil Bant Normalize Edilmiş Fark Bitki Örtüsü İndeksi (GNDVI) ve Normalize Edilmiş Fark Kırmızı Kenar İndeksi (NDVI_{re}) gibi farklı bitki indeksleri hesaplanmıştır. Bu hesaplanmış indeksler, seçilen bantlara eklenmiş ve diğer veri setleri olarak RO algoritması ile sınıflandırılmıştır. Üretilen beş farklı veri setinin sonuçları hata matrisi kullanılarak karşılaştırılmıştır. Ayrıca, elde edilen sınıflandırma doğrulukları arasındaki farkların istatistiksel olarak anlamlı olup olmadığı McNemar testi kullanılarak analiz edilmiştir.

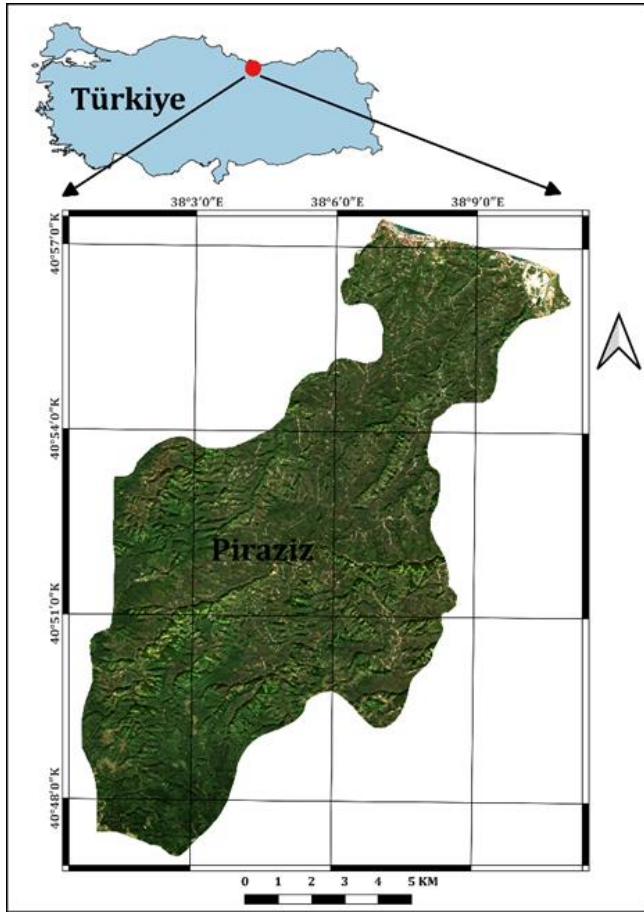
Bu çalışmanın diğer çalışmalardan farkı; yardımcı veri seti olarak kullanılan bitki indekslerinin fındık ekili alanların tespitinde kullanımı ile sınıflandırma doğruluğunun etkisine katkısının araştırılmasıdır.

2. Çalışma alanı ve veri seti

Uzaktan algılama görüntüleri ile AK/AÖ hakkında elde edilen bilgiler ürün bazında detaylandırılarak fındık ekili alanlar için de bilgi üretir ve bu sonuçlar daha sonra kırsal alanların sürdürülebilir olarak planlanmasına katkı sağlar (Aydınöglü, 2010). Uzaktan algılama görüntülerinden doğru tematik bilgi üretmek için farklı sınıflandırma algoritmaları yaygın olarak kullanılmaktadır (Marangoz, 2009).

2.1 Çalışma Alanı

Fındık üretimi genellikle dik yamaçlardan ve engebeli arazi ortamlarından kaynaklanan düzensiz ekimler ve sabit olmayan yoğunluk ile karakterize edilir (Monarca ve ark., 2016). Bu çalışma kapsamında da fındığın yoğun olarak yetiştirildiği yaklaşık 128 bin metrekare yüzölçümüne sahip Giresun ili Piraziz ilçesi pilot bölge olarak seçilmiştir (Şekil 1).



Şekil 1. Çalışma Alanı

Çalışmada veri seti olarak orman alanlarının canlılığını yitirdiği ve diğer ağaçların yapraklarının dökülmeye başlamasıyla fındık ağaçlarının ayırt edilebilirliğinin arttığı 22.10.2020 tarihine ait atmosferik düzeltmesi yapılmış Sentinel-2A uydu görüntüleri Copernicus Açık Erişim Merkezinden ücretsiz olarak <https://scihub.copernicus.eu/dhus/#/home> adresinden temin edilmiştir. Sentinel-2 MSI uydu sistemi Avrupa Uzay Ajansı (ESA) tarafından 2015 yılında fırlatılmıştır. Sentinel-2 MSI misyonunun amacı, arazi örtüsü/kullanımı izleme, iklim değişikliği ve afet izleme

için yüksek çözünürlüklü uydu verileri sağlamaktır (Gorton & Tregear, 2008). Sentinel-2 MSI, uydu görüntüleri özellikle zamansal ve mekânsal çözünürlükte gelişmiş veriler sunar (Pedrotti, 2004). Sentinel-2 MSI görüntüleri için 13 spektral bant, 10 ila 60 m arasında değişen mekânsal çözünürlüklere sahiptir (Taşdemir, 2012). Görünür ve yakın kızılötesi (NIR) bantlar 10 m mekânsal çözünürlüğe, kızılötesi bantlar 20 m mekânsal çözünürlüğe ve diğer bantlar 60 m'ye sahiptir (Tablo 1). 10 m mekânsal çözünürlük, Sentinel-2 MSI verilerinin Dünya yüzeyinin (örneğin, kentsel yayılmalar ve tarım) ayrıntılı olarak araştırılması için yüksek potansiyele sahip olmasını sağlar. Sentinel-2 verilerinin diğer bir özelliği, 5 günlük yüksek zamansal çözünürlüğüdür (Rivas-Martínez, 2005).

Sentinel-2 uydu görüntüsünün kırmızı-kenar ve yakın kızılötesi spektral bantları bünyesinde barındırması, AK/AÖ çalışmalarında son yıllarda sıklıkla tercih edilmesini sağlamakla birlikte başarılı sonuçlar üretmektedir (Immitzer ve ark., 2016; Yousefi ve ark., 2022; Balçık, 2018; Ahady & Kaplan, 2022)

Tablo 1. Sentinel-2 uydusunun teknik özellikleri

Sentinel-2 Bantlar	Çözünürlük (m)	Dalga Boyu (µm)
Bant 1- Kıyı	60	0,433-0,453
Bant 2 - Mavi	10	0,458-0,523
Bant 3 - Yeşil	10	0,543-0,578
Bant 4 - Kırmızı	10	0,650-0,680
Bant 5 - Kırmızı Kenar	20	0,698-0,173
Bant 6 - Kırmızı Kenar	20	0,734-0,748
Bant 7 - Kırmızı Kenar	20	0,765-0,785
Bant 8 - Kızılötesi	10	0,785-0,900
Bant 8A - Kırmızı Kenar	20	0,855-0,875
Bant 9 - Su buharı	60	0,930-0,950
Bant 10 - Kısa Dalga Kızılötesi	60	1,365-1,385
Bant 11 - Kısa Dalga Kızılötesi	20	1,565-1,655
Bant 12 - Kısa Dalga Kızılötesi	20	2,100-2,280

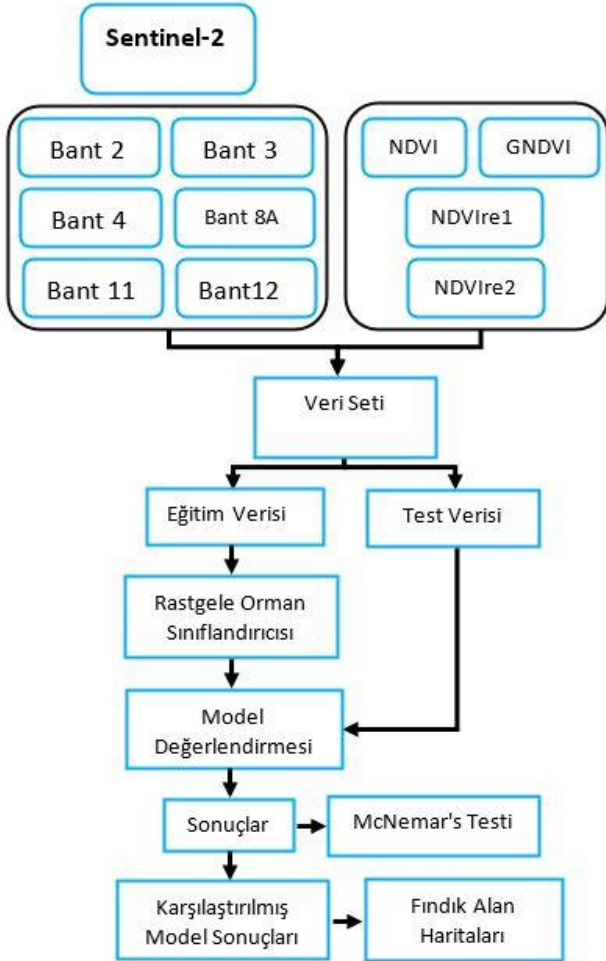
Çalışmada kullanılan bant2, bant3, bant4, bant8a, bant11 ve bant12 nolu bantlar, bantlar arasındaki korelasyon değerlerine göre belirlenmiştir. Bitki indekslerinin oluşturulması kısmında bant5 ve bant6 da çalışmaya dâhil edilmiştir.

3. Yöntem

Fındık ekili alanlara ait haritaların üretilmesi için piksel tabanlı rastgele orman kontrollü sınıflandırma algoritması kullanılmıştır. Çalışmada kullanılan iş akışı grafiği Şekil 2'de verilmiştir.

Görüntülerdeki yansıtım özelliklerinin dikkate alınarak piksellerin farklı sınıflara atanması olarak bilinen sınıflandırmanın en yaygın kullanım türü piksel tabanlı sınıflandırmadır. Bu yöntemde bilinmeyen piksel belirli bir sınıfa ait olma olasılığına sahiptir. Bundan dolayı, her bir pikselin olasılığı hesaplanır ve her piksel en yüksek olasılığa sahip olan sınıfa atanır (ENVI, 2005; Sunar ve ark., 2013; Karakuş ve ark., 2017). Ayrıca piksel tabanlı sınıflandırmalar Sentinel-2 MSI görüntüsü gibi orta mekânsal çözünürlüklü verilerde önemli avantajlar

sağlamaktadır (Bayburt, 2009; Efe & Algancı, 2023). Bu yöntemde öncelikle arazide tanımlayacağımız kategoriler belirlenmekte, belirlenen kategorilere ait eğitim ve test verileri toplanmakta ve seçilen bir sınıflandırma algoritmasına göre sınıflandırma işlemi yapılabilmektedir (Jensen, 2005). Bu çalışma için sınıflandırma algoritması olarak Rastgele Orman (RO) sınıflandırması seçilmiştir.



Şekil 2. Çalışmaya ait iş akış şeması

RO algoritması, toplu öğrenme yöntemleri arasında sınıflandırmada çok daha iyi performans sergilediği için daha çok tercih edilen karar ağacı tabanlı bir sınıflandırıcıdır. Bu yöntem rastgele seçilen örneklem kümesi ve bu örneklemden elde edilen değişkenler alt kümesini kullanarak birden çok karar ağacı üretir (Belgiu & Drăgut, 2016). Oluşan her karar ağacı için sınıflandırma sonucunda bir oy alması söz konusudur. En çok oya sahip olan karar ağacı belirlenerek sınıflandırmada ana ağaç yapısı belirlenir. Henüz sınıf etiketi belli olmayan yeni veri seti tüm ağaç tahminlerinde en fazla oy alan sınıfa atanarak sınıflandırılır. RO sınıflandırmasında önemli olan ve kullanıcı tarafından belirlenen iki parametre vardır. Bunlar ağaç sayısı ve değişken sayısıdır (Breiman, 2001; Archer & Kimes 2008). Bu iki parametre sınıflandırma doğruluğunu önemli derecede etkilemektedir. En uygun değerlerde parametrelerin belirlenmesi için bu çalışmada tekrarlı denemeler yapılmış ağaç sayısı 500, değişken sayısı 2 olarak alınmıştır.

Tarımsal ürün desenlerinin uzaktan algılanma yöntemi ile belirlenmesinde bitki indeksleri kullanılmaktadır. Bu veriler çalışmada kullanılan yardımcı elemanlardır. İndeksler her bir bitkinin spektral imzasına dayanarak üretilmiş ve bitkinin yaprak pigmentleri ile yapısını temsil etmekte kullanılmaktadır (Jackson ve Huete, 1991). Özellikle klorofile duyarlı olmaları sebebiyle yakın kızılötesi veya kırmızı kenar spektral bantları ile elde edilmiş bitki indeksleri tarım alanlarının izlenmesinde ve tespitinde sıklıkla tercih edilmekte ve verimli sonuçlar vermektedir (Amliana ve ark., 2016; Wang ve ark., 2018, Souza ve ark., 2020). Yapılan bu çalışmada sınıflandırma işlemlerine katkılarını değerlendirmek üzere NDVI, GNDVI ve NDRE indeksleri eklenmiştir. Kullanılan indekslere dair formüller Tablo 2'de gösterilmiştir.

Tablo 2. Sınıflandırma aşamasında kullanılan indeksler

İndeksler	Sentinel-2 Formül	Kaynak
NDVI	$\frac{B8a - B4}{B8a + B4}$	Bigler ve ark., (2007)
GNDVI	$\frac{B8a - B3}{B8a + B3}$	Gitelson ve ark. (1996)
NDVIre1	$\frac{B8a - B5}{B8a + B5}$	Rouse (1973)
NDVIre2	$\frac{B8a - B6}{B8a + B6}$	Liu ve ark. (2018)

Doğruluk analizinde en sık kullanılan yöntem hata matrislerinin oluşturulması ve bu matrislerden elde edilen doğruluk ölçütlerinin analiz edilmesidir. Bu matris gerçek arazi örtüsünden referans alınarak belirli bir arazi örtüsü tipinde atanan piksellerin sayısını satırlar ve sütunlar halinde oluşmuş sayıların karesel bir sayı dizisidir. Genel sınıflandırma doğruluğu, doğru sınıflandırılmış piksel sayısının toplam piksel sayısına bölünmesiyle elde edilir. Hata matrisi yardımıyla hesaplanan kullanıcı ve üretici doğrulukları sınıf doğrulukları hakkında bilgi edinilmesinde kullanılan önemli doğruluk ölçütlerindedir. Ayrıca doğruluk değerlendirmelerinde kullanılan Kappa değeri hata matrisi kullanılarak hesaplanır. Kappa sayısı 1'e eşit olduğunda mükemmel sonuç verirken sifıra yaklaştığında iyi bir sınıflandırma olmadığını ifade eder. (Congalton ve ark., 2009).

Bu çalışmada oluşturulan veri setleri ile birlikte elde edilen genel doğruluklar arasındaki farkların istatistiksel olarak anlamlılığı McNemar testi kullanılarak analiz edilmiştir. Ki-kare dağılımını esas alan McNemar testi hesaplamalarda 2x2 boyutlu bir hata matrisi kullanılmaktadır (Foody, 2004).

4. Bulgular ve Tartışma

Sınıflandırma yöntemi ile tematik harita üretiminde çalışma amacına göre arazi örtüsü sınıflarının belirlenmesi çok önemlidir. Çalışma yapılacak bölgede uygulanacak kontrollü sınıflandırma işlemi için kullanılacak sınıflar; fındık, orman, tarım/mera, şehir yapısı, endüstriyel ve ticari alan, yol ve su yüzeyi olmak üzere 7'ye ayrılmaktadır. Sınıflandırmada kullanılacak sınıflar belirlendikten sonra sınıflandırma işlemi için

gerekli eğitim verisi Tarım ve Orman Bakanlığı tarafından temin edilen 1/25000 ölçekli Arazi Kullanım Haritası referans alınarak toplanmıştır. Sınıfları doğru temsil etmek adına homojen olarak seçilmiş görüntü nesnelere ait toplanan eğitim verilerinin sayısı **Tablo 3**'de yer almaktadır.

Tablo 3. Sınıflar için belirlenen eğitim ve test piksel sayısı

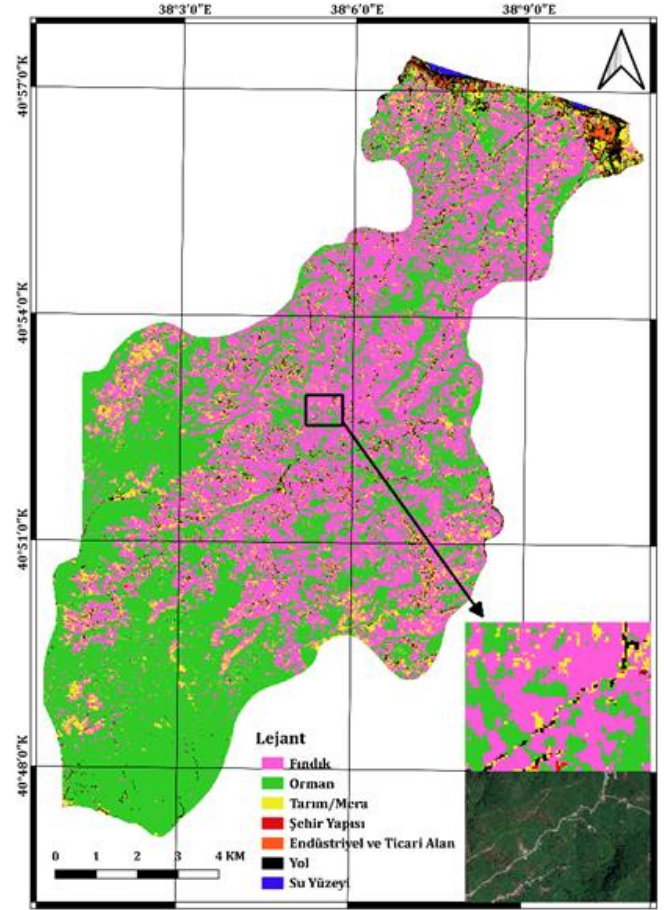
Sınıflar	Eğitim Verisi	Test Verisi
Fındık	2166	922
Orman	3059	1303
Tarım/Mera	940	397
Şehir Yapısı	560	240
Endüstriyel ve Ticari Alan	435	186
Yol	636	278
Su Yüzeyi	245	105
Toplam	8041	3431

Genel olarak çalışma alanının çoğunluğunun orman ve fındık alanı olmasından dolayı bu durum eğitim ve test veri sayılarına da yansımıştır. Eğitim verisi oluşturma aşamasından sonra toplanan veriler ile çalışma tarihine ait uydu görüntülerinde ilk senaryo seçtiğimiz 6 bantın RO sınıflandırması yapılarak oluşturulmuştur. Daha sonra kullanılan bantlara NDVI, GNDVI, NDVIre1 ve NDVIre2 ayrı ayrı eklenerek 5 senaryoda genel doğruluğa ve sınıf bazında doğruluğa katkısı analiz edilmiştir.

Tablo 4. Karşılaştırma için oluşturulan senaryolar. 6 bant: bant 2, bant 3, bant 4, bant 8a, bant 11, bant 12.

Senaryolar	Özellikler
S1	6 Bant
S2	6 Bant + NDVI
S3	6 Bant + GNDVI
S4	6 Bant + NDVIre1
S5	6 Bant + NDVIre2



Sınıflandırma işlemine ilk olarak orijinal bantlar ile başlanmıştır. Daha sonra her görüntüye üretilen indeksler eklenerek her bir indeksin sınıflandırma doğruluğuna etkisi araştırılmıştır. Bu doğrultuda da en yüksek genel doğruluklu sonuç ve kapa değeri senaryo 1'de elde edilmiştir (**Şekil 3**). Dolayısıyla çalışmanın ana hipotezi olan yardımcı veri setlerinin sınıflandırma doğruluğuna pozitif etkisinin olmadığı görüldü. Ancak bütün veri setleri arasındaki sınıflandırma doğruluğu farklarının istatistiksel olarak anlamlı olup olmadığı McNemar testi ile incelendiğinde bu farkların istatistiksel olarak anlamlı olmadığı da görülmüştür. Hesaplanan istatistik değerler %95 güven aralığındaki kritik değerden ($\chi^2=3.84$) küçük olduğundan aradaki farkın anlamlı olmadığı sonucuna varılmıştır (**Çölkesen & Yomraloğlu, 2014**). En düşük genel sınıflandırma doğruluğu ise NDVIre2 indeksi ile yapılan senaryo 5 de %97.49 olarak elde edilmiştir. Bu çalışmada genel doğruluk ile kapa istatistiğinin yanı sıra üretici ve kullanıcı doğruluk değerleri de sunulmuştur (**Tablo 5**).



Şekil 3. En yüksek sınıflandırma doğruluğu elde edilen senaryo 1 tematik haritası

Tablo 5'e göre fındık için üretici ve kullanıcı doğruluğu en yüksek değerleri S1'de almıştır. Orman sınıfı için üretici doğruluğu S1'de, kullanıcı doğruluğu S3'te en yüksek gelmiştir. Tarım/mera ve yol sınıflarının her ikisi de üretici doğruluğunda en yüksek değere S4'de, kullanıcı doğruluğunda S1'de ulaşmıştır. Şehir yapısı kullanıcı doğruluğu S2 hariç hepsinde tam gelmiştir. Üretici doğruluğu için bu durum S3 ve S5 haricinde %100 değerine ulaşmıştır. Endüstriyel ve ticari alan sınıfının üretici doğruluğu her senaryoda tam gelmiştir. Üretici doğruluğu için bu durum S1 ve S2 haricinde %100 değerine ulaşmıştır. Su yüzeyi sınıfı hem üretici doğruluğunda hem kullanıcı doğruluğunda da her senaryo için %100 olarak belirlenmiştir.

Çalışma kapsamında fındık alanlarının 22.10.2022 tarihinde RO makine öğrenme algoritmasının Sentinel-2 uydu görüntüleri ile tematik haritalanması gerçekleştirilmiştir. Yapılan sınıflandırma işlemi sonucunda elde edilen haritalar incelendiğinde her senaryoda az miktarda fındık ve tarım/mera alanlarının birbirine karıştığı gözlemlenmiştir. Bunun sebebi olarak, kullanılan yersel referans verisinde tarım alanı olarak ayrılan bölgelere de fındık dikiminin yapıldığı tespit edilmiştir. Orijinal bantlarla yapılan senaryo 1 (S1) sınıflandırma işlemi sonrasında elde edilen genel doğruluk %98.98, kapa %98.65 olarak elde edilmiştir. Bitki indeksleri dâhil edilerek üretilen senaryo 2, 3, 4 ve 5'de genel doğruluk değeri ve kapa senaryo 1'e göre çok az miktarda azalmıştır (**Tablo 6**).

Tablo 5. Sınıfların senaryolara göre üretici ve kullanıcı doğruluğu**Tablo 6.** Senaryolara göre genel doğruluk ve kappa

Burada görüldüğü üzere en yüksek değerler orijinal bant olarak belirlenen 6 bant (band2, band3, band4, band8a, band11 ve band12) ile oluşturulan senaryo 1'de görülmektedir. Bu senaryoyu sırasıyla S2, S4, S3 ve S5 takip etmiştir.


Çalışma alanı seçilen Piraziz ilçesinin sınıflara göre alan dağılımı da yapılmış ve ilçede en fazla alanı ormanların kapladığı belirlenmiştir (Tablo 7).

Orman alanını sırasıyla fındık, tarım/mera, yol, şehir yapısı, endüstriyel ve ticari alan takip etmiştir.

5.Sonuç

Bu çalışmada 2020 yılı ekim ayına ait Sentinel-2 MSI uydu görüntüsü piksel tabanlı olarak sınıflandırılmış ve ekonomik değere sahip olan fındık ekili alanları gösteren tematik harita oluşturulmuştur. Sınıflandırmada RO

algoritması kullanılmış ve sınıflandırma performansları doğruluk analizleri ile test edilmiştir. Sınıflandırmada oluşturulan 7 sınıf kendilerine ait spektral özelliklere göre sınıflandırılmıştır. RO sınıflandırıcısı ile indeks eklemeyen sınıflandırılma sonucunda %98.98 genel sınıflandırma doğruluğu elde edilmiştir. Daha sonra kullanılan orijinal bantlara NDVI, GNDVI, NDVIre1 ve NDVIre2 ayrı ayrı eklenerek sınıflandırma doğruluklarının etkilerine bakılmıştır. Sonuçlar karşılaştırıldığında en yüksek sınıflandırma doğruluğu senaryo 1 de elde edilmiş, en düşük genel sınıflandırma doğruluğu ise NDVIre2 indeksi ile yapılan senaryo 5 de %97.49 olarak elde edilmiştir. En yüksek iki sınıflandırma doğruluğu arasındaki farkın (1.49) istatistiksel olarak anlamlı olup olmadığı McNemar testi ile incelenmiştir. Hesaplanan istatistik değeri (0.8069) %95 güven aralığındaki kritik değerden ($\chi^2=3.84$) küçük olduğundan dolayı yardımcı veri seti olarak NDVI, GNDVI, NDVIre1 ve NDVIre2 indekslerinin kullanımı ile sınıflandırma doğruluğunda anlamlı değişiklikler ortaya çıkmamıştır. Çalışmanın ana teması olan fındık sınıfı için en yüksek üretici doğruluğu ve kullanıcı doğruluğu sırasıyla %98.69 ve %98.05 olarak S1'de belirlenmiştir. Piraziz ilçesi belirlenen sınıflara göre alansal dağılım olarak incelendiğinde fındık, yol ve su yüzeyi senaryo 4'de; orman ve tarım/mera senaryo 5'de; endüstriyel ve ticari alan senaryo 1'de; şehir yapısı senaryo 2'de en yüksek alana sahip olduğu belirlenmiştir. Farklı tarihli ve farklı bir sınıflandırma algoritması kıyaslama çalışmaları devam etmektedir.

Tablo 7. Senaryolara göre sınıfların alansal dağılımı

Bilgilendirme/Teşekkür

Bu çalışmada Arazi Kullanım Haritası (Ölçek:1/25000) verisi Tarım ve Orman Bakanlığı tarafından temin edilmiş ve eğitim verisi seçiminde kullanılmıştır. Tarım ve Orman Bakanlığı'na desteğinden dolayı teşekkür ederiz.

Araştırmacıların katkı oranı

Seda Terzi Türk: Literatür taraması, Görüntü işleme, Makale yazımı, Düzenleme; **Filiz Bektaş Balçık:** Makale yazımı, Düzenleme

Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

Kaynakça

- Ahady, A. B., & Kaplan, G. (2022). 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*, 7(1), 24-31.
- Akar, Ö., & Güngör, O. (2013). Eş Dizimlilik Matrisi ve Rastgele Orman Sınıflandırıcısı ile Çay ve Fındık Alanlarının Sınıflandırılması.
- Amliana, D. R., Prasetyo, Y., & Sukmono, A. (2016). Analisis Perbandingan Nilai Ndvı Landsat 7 Dan Landsat 8 Pada Kelas Tutupan Lahan (Studi Kasus: Kota Semarang, Jawa Tengah). *Jurnal Geodesi Undip*, 5(1), 264-274.
- Apaydın, C., & Abdikan, S. (2021). Fındık bahçelerinin Sentinel-2 verileri kullanılarak piksel tabanlı sınıflandırma yöntemleriyle belirlenmesi. *Geomatik*, 6(2), 107-114.
- Archer, K. J., & Kimes, R. V. (2008). Empirical characterization of random forest variable importance measures. *Computational statistics & data analysis*, 52(4), 2249-2260.

- Aydinoglu, A. C. (2010). Examining environmental condition on the growth areas of Turkish Hazelnut (*Corylus Colurna* L.). *African Journal Of Biotechnology*, 9(39), 6492-6502.
- Balçık, F. B. (2018). Evaluation Of Sentinel-2 Msi Data for Land Use/Land Cover Classification Using Different Vegetation İndices. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 6, 839-846.
- Bayburt, S. (2009). Uydu Görüntülerinin Piksel ve Nesne Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması (Doğu Trakya Bölgesi Örneği) (Doctoral Dissertation, Fen Bilimleri Enstitüsü).
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31.
- Bigler, C., Gavin, D. G., Gunning, C., & Veblen, T. T. (2007). Drought induces lagged tree mortality in a subalpine forest in the Rocky Mountains. *Oikos*, 116(12), 1983-1994.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
- Brinkhoff, J., Vardanega, J., & Robson, A. J. (2019). Land Cover Classification Of Nine Perennial Crops Using Sentinel-1 And-2 Data. *Remote Sensing*, 12(1), 96.
- Congalton, R. G., & Green, K. (2009). *Assessing The Accuracy Of Remotely Sensed Data*, 2. Baskı, Crc Press, New York.
- Çölkesen, İ., & Yomralıoğlu, T. (2014). Arazi örtüsü ve kullanımının haritalanmasında WorldView-2 uydu görüntüsü ve yardımcı verilerin kullanımı. *Harita Dergisi*, 152(2), 12-24.
- Delen, A., Balık Şanlı, F., (2017), Determination of Cotton Fields By Object-Based Classification Method: A Case Study in Menemen District. *Journal Of New Results in Engineering and Natural Science*, 6, 1-8
- Doğru, B. (2020). Fındık, İklim Değişikliği ve Çevresel Etkiler Raporu. Rainforest Alliance <https://Www.Rainforest-Alliance.Org/> (Access Date: 09.09.2020)
- Efe, E., & Alganci, U. (2023). Çok zamanlı Sentinel 2 uydu görüntüleri ve makine öğrenmesi tabanlı algoritmalar ile arazi örtüsü değişiminin belirlenmesi. *Geomatik*, 8(1), 27-34.
- ENVI, (2005), ENVI's User Guide, http://geol.hu/data/online_help/ApplyingMaximumLikelihoodClassification.html
- Footy, G. M. (2004). Thematic map comparison. *Photogrammetric Engineering & Remote Sensing*, 70(5), 627-633.
- Gitelson, A. A., & Merzlyak, M. N. (1996). Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of plant physiology*, 148(3-4), 494-500.
- Gorton, M., & Tregear, A. (2008). Government Support To Regional Food Producers: An Assessment Of England's Regional Food Strategy. *Environment And Planning C: Government And Policy*, 26(6), 1047-1060.
- Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First Experience With Sentinel-2 Data For Crop And Tree

- Species Classifications In Central Europe. *Remote Sensing*, 8(3), 166.
- Jackson, R. D., & Huete, A. R. (1991). Interpreting vegetation indices. *Preventive veterinary medicine*, 11(3-4), 185-200.
- Jensen, J. R. (2005). Thematic Information Extraction: Pattern Recognition. *Introductory Digital Image Processing: A Remote Sensing Perspective*, 337-406.
- Karakuş, P., Karabork, H., & Kaya, S. (2017). A comparison of the classification accuracies in determining the land cover of Kadirli Region of Turkey by using the pixel based and object based classification algorithms. *International Journal of Engineering and Geosciences*, 2(2), 52-60.
- Kavzoglu, T., & Reis, S. (2008). Performance Analysis of Maximum Likelihood And Artificial Neural Network Classifiers For Training Sets With Mixed Pixels. *Giscience & Remote Sensing*, 45(3), 330-342.
- Kayalak, S. (2009). Türkiye Fındık Piyasasındaki Ekonomik Değişkenlerin Yapısal Değişimi ve Zaman Serisi Analizi. Ankara Üniversitesi Fen Bilimleri Enstitüsü, Yayınlanmamış Doktora Tezi, Ankara.
- Liu, J., Zhang, Z., & Zhang, M. (2018). Impacts of forest structure on precipitation interception and run-off generation in a semiarid region in northern China. *Hydrological Processes*, 32(15), 2362-2376.
- Marangoz, A. M. (2009). Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi ve CBS Ortamında Bütünleştirilmesi. Yıldız Teknik Üniversitesi, Fbe Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı Uzaktan Algılama ve CBS Programında Hazırlanan Doktora Tezi, İstanbul, 53-65.
- Monarca, D., Cecchini, M., Colantoni, A., Bedini, R., Longo, L., Bessone, W., ... & Schillaci, G. (2016, May). Evaluation Of Safety Aspects for A Small-Scale Machine for Nuts Harvesting. In *Proceedings of The Mechtech 2016 Conference—Mechanization and New Technologies for The Control and Sustainability of Agricultural and Forestry Systems*, Alghero, Italy (Pp. 32-35).
- Pedrotti, F. (2004). *Cartografia Geobotanica*. Pitagora.
- Reis, S., & Taşdemir, K. (2010). Fındık Alanlarının Kendini Örgütleyen Eşlemlerle (Self Organizing Maps) Belirlenmesi.
- Rivas-Martinez, S. (2005). Notions On Dynamic-Catenal Phytosociology as A Basis of Landscape Science. *Plant Biosystems-An International Journal Dealing with All Aspects of Plant Biology*, 139(2), 135-144.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1), 309.
- Sener, M., Altıntaş, B., & Kurc, H. C. (2013). Planning And Controlling Of Hazelnut Production Areas With The Remote Sensing Techniques. *Ksü Doğa Bilimleri Dergisi*, 16(1).
- Souza, J. B. C., De Brito Filho, A. L., Carneiro, F. M., Do Santos, A. F., & Da Silva, R. P. (2020). Avaliação Da Qualidade Dos Índices De Vegetação (Ndre E Ndvı) Para A Cultura Do Amendoim, Utilizando Cartas De Controle. *South American Sciences*, 1(1), E2095-E2095.
- Sunar, F., Özkan, C., & Osmanoğlu, B. (2013). Uzaktan Algılama (2.Baskı). T.C. Anadolu Üniversitesi, Yayın No: 2320, Açıköğretim Fakültesi Yayın No:1317, Eskişehir.
- Taşdemir, K. (2012). Exploiting Spectral and Spatial Information for the Identification of Hazelnut Fields Using Self-Organizing Maps. *International Journal of Remote Sensing*, 33(19), 6239-6253.
- Ünal, E., Aydoğdu, M., Ceylan, N., Sezer, A., Özenç, N., & Duyar, Ö. (2010). Giresun İlinde Fındık Alanlarının Uzaktan Algılama ile Tespit Edilmesinde Arazi Topografyasının Etkisinin İncelenmesi ve Alternatif Tarım Ürünlerine Uygunluğunun Belirlenmesi. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 19(1-2), 1-10.
- Wang, Z., Yang, X., Liu, Y., & Lu, C. (2018). Extraction of Coastal Raft Cultivation Area with Heterogeneous Water Background by Thresholding Object-Based Visually Salient NDVI from High Spatial Resolution Imagery. *Remote Sensing Letters*, 9(9), 839-846.
- Yousefi, S., Mirzaee, S., Almohamad, H., Al Dughairi, A. A., Gomez, C., Siamian, N., ... & Abdo, H. G. (2022). Image Classification and Land Cover Mapping Using Sentinel-2 Imagery: Optimization of SVM Parameters. *Land*, 11(7), 993.

