

Kaynaştırılmış Sentinel-1 SAR ve Landsat-8 Optik Veriden Makine Öğrenme Algoritması ile Tarımsal Ürün Tespiti

Agricultural Crop Detection with a Machine Learning Algorithm from Fused Sentinel-1 SAR and Landsat-8 Optical Data

Müslüm Altun^{1*}, Mustafa Türker¹

¹Hacettepe Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, 06800, Ankara/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Müslüm Altun
altunmuslum06@gmail.com

doi: 10.48123/rsgis.999749

Yayın süreci

Geliş tarihi: 23.09.2021
Kabul tarihi: 31.01.2022
Basım tarihi: 14.03.2022

Özet

Bu çalışmada, tek tarihe ait kaynaştırılmış Sentinel-1 Yapay Açıklıklı Radar (Synthetic Aperture Radar-SAR) ve Landsat-8 verilerinin sınıflandırma ile tarımsal ürün tespitine olan etkisi araştırılmıştır. Çalışma alanı olarak, Manisa'da bir bölge seçilmiştir. Görüntü kaynaştırma için Ehlers yöntemi, görüntü sınıflandırma için rastgele orman (RO) makine öğrenme algoritması kullanılmıştır. Sınıflandırma orjinal Sentinel-1 verisi ile orjinal Landsat-8 verisi ile ve kaynaştırılmış veri setleri ile gerçekleştirilmiştir. Orjinal Sentinel-1 DD veya DY bantı ile yapılan sınıflandırmanın genel doğruluğu %35 mertebesinde hesaplanmıştır. Sentinel-1 DD ve DY bantların birlikte kullanılmasının sınıflandırma performansına katkısı %6 kadar olmuştur. Orjinal Landsat-8 verisi ile yapılan sınıflandırma sonucu hesaplanan genel doğruluk değeri (%71,18), orjinal Sentinel-1 verisine göre oldukça yüksektir. Landsat-8 ile kaynaştırılmış Sentinel-1 DY ve DD bantları veri setleri ile yapılan sınıflandırmanın genel doğruluğu sırasıyla %80,44 ve %82,16 olarak hesaplanmıştır. En yüksek genel doğruluk değeri (%87,72), Landsat-8 ile kaynaştırılmış Sentinel-1 DD+DY bantları veri seti ile yapılan sınıflandırmada elde edilmiştir. Elde edilen bulgulara göre, sınıflandırmada kaynaştırılmış tek tarihli Landsat-8 ve Sentinel-1 DD+DY bantları veri setinin kullanılması doğruluğu önemli oranda artırmaktadır.

Anahtar kelimeler: Sentinel-1 SAR, Landsat-8, Sınıflandırma, Rastgele Orman (RO), Ehlers görüntü kaynaştırma

Abstract

In this study, the effect of fused single-date Sentinel-1 SAR and Landsat-8 data on agricultural crop detection by classification was investigated. A region in Manisa, Turkey was chosen as study area. Ehlers method was used for image fusion and random forest (RF) machine learning algorithm was used for image classification. Classification was carried out using only Sentinel-1 data, only Landsat-8 data, and the fused Sentinel-1 and Landsat-8 datasets. In classification using only Sentinel-1 VV or VH band, the overall accuracies were calculated at the level of 35%. The combined use of Sentinel-1 VV and VH bands contributed about 6% to classification performance. The accuracy (71,18%) calculated from classification performed using Landsat-8 data alone is quite high when compared to classification performed using Sentinel-1 data alone. In classification with the fused Landsat-8 and Sentinel-1 DD dataset and with the fused Landsat-8 and Sentinel-1 DY dataset, the accuracies were calculated as 80.44% and 82.16%, respectively. The highest accuracy (87.72%) was obtained in classification performed using the fused Landsat-8 and Sentinel-1 VV+VH bands dataset. Based on the results, the use of the fused single-date Landsat-8 and Sentinel-1 VV+ VH bands dataset in classification was found to significantly increase the accuracy.

Keywords: Sentinel-1 SAR, Landsat 8, Classification, Random Forest (RF), Ehlers image fusion

1. Giriş

Yer gözlem uydularının en yaygın kullanıldığı alanlardan birisi tarımsal ürün tespitidir (Zhan vd. 2002; Thenkabail vd. 2010; Gumma vd. 2011; Thenkabail vd. 2011). Tarım alanlarında üretilen ürünlerin etkin bir şekilde yönetilmesi, izlenmesi, karar verilmesi ve istatistiklerin çıkarılmasında uydu görüntülerinden elde edilen tematik haritaların sağladığı bilgiler oldukça kullanışlıdır (Turker ve Arikan, 2005; Ozdarici ve Turker, 2006; Liu vd. 2014; Viskovic vd. 2019).

Tarımda uzaktan algılama uygulamaları, optik ve Yapay Açıklıklı Radar (Synthetic Aperture Radar-SAR) uydularının her ikisiyle de yapılabilmektedir (Lemoine ve Leo, 2015; Lussem vd. 2016; Nasirzadehdizaji vd. 2019; Kussul vd. 2017). Ürün tespiti uydu görüntülerinin tarımsal alanlarda en yaygın kullanım alanları arasında yer almaktadır. Optik uydu görüntüleri ile sınıflandırma ve ürün türü tespitinde pek çok çalışma yapılmasına ve ilerleme kaydedilmesine rağmen bulut örtüsü ve zamansal çözünürlük gibi kısıtlar nedeniyle istenen tarihlere ait görüntüleri bulmak ve dolayısıyla gerekli bilgiyi çıkarmak her zaman mümkün olamamaktadır. Optik uyduların aksine, SAR uyduları görüntü alımında kendi enerji kaynaklarını kullanan aktif sensöre sahiptir. SAR uydularının önemli avantajları arasında hava durumlarından etkilenmemeleri ve gece gündüz görüntü alımı yapabileceğine sahip olmaları yer almaktadır. Bu nedenle, tarımsal alanlarda ürün türü tespitinde radar görüntülerinin kullanımı her geçen gün yaygınlaşmaktadır.

Çeşitli kısıtlayıcı etkilerinden dolayı, optik ve SAR uydu görüntülerinin birlikte kullanımı kaçınılmaz olmuştur. Farklı ürün türlerinin ayırt edilmesinde belirgin bir şekilde öne çıkan birlikte kullanım, tarımsal amaçlı çalışmalara olan ilgiyi artırmaktadır (Foody vd. 1994). Farklı sensörlere sahip uydular kullanılarak tarımsal alanların sınıflandırmasını ve tarımsal ürün tespitini amaçlayan çalışmalar yapılmıştır (Skriver, 2012; Sonobe vd. 2014; Hütt vd. 2016; McNairn ve Shang, 2016; Csillik ve Belgiu, 2017).

Uzaktan algılama çalışmalarında kullanılacak veri temini zaman ve maliyet analizi açısından oldukça pahalıdır. Sentinel ve Landsat uydu görüntülerinin ücretsiz olarak temin edilebilmesi bu güçlüğün ortadan kaldırılmasında oldukça önemlidir. Ayrıca, Landsat-8 uydusunun zengin bant sayısı, kullanıcılara farklı konumsal çözünürlükte görüntü sunması ve Sentinel-1 uydusunun düşük zamansal çözünürlük özelliği ile görüntüleri kısa sürede kullanıma kazandırması açısından birçok farklı alanda yaygın kullanımı ile ön plana çıkmaktadır. Bu özellikleri ile Sentinel-1 ve Landsat-8 uydularının yaygın kullanım alanlarından birisi tarımsal alanlardır. Küresel tarım alanlarının önemli bir bölümü sıklıkla bulutla kaplı olduğu için, Sentinel-1 görüntülerinin kullanımı, net optik görüntü elde etmenin zor olduğu ya da yeterli sayıda görüntünün alınamadığı bölgelerde, tarımsal ürün deseni tespiti için ayrı bir öneme sahiptir (Bush ve Ulaby, 1978; Brisco ve Brown, 1995; Van Niel ve McVicar, 2004; Skriver, 2012; Sonobe vd. 2014; Siachalou vd. 2015).

Konuya ilişkin yapılan literatür araştırması sonucunda yapılan çalışmalar incelendiğinde, Chen vd. (2020) tarafından yapılan çalışmada Zimbabwe, Masvingo şehrinde 15 Nisan 2018 ve 22 Nisan 2018 tarihli Sentinel-1 SAR görüntüsü ile 26 Nisan 2018 tarihli Landsat-8 OLI bantları Decision Level Fusion (DLF) tekniğiyle kaynaştırılmış ve Destek Vektör Makineleri (DVM) algoritması ile sınıflandırılmıştır. Çalışmada, SAR DD+DY polarize bantları kullanılmıştır. Çalışmada ayrıca benek (speckle) filtresinin sonuçlara etkisi de ölçülmüştür. Benek filtresi uygulanmadan DLF tekniğiyle kaynaştırılan bantlar ile yapılan sınıflandırmada, %96,02 genel doğruluk ve 0,9515 kapa katsayısı, benek filtresi uygulanarak DLF tekniğiyle kaynaştırılan bantlar ile yapılan sınıflandırmada, %94,69 genel doğruluk ve 0,9378 kapa katsayısı elde edilmiştir. Benek filtresinin sınıflandırma doğruluğunu düşürdüğü görülmüştür. En iyi doku bilgisinin Mavi bant ve devamında Kırmızı banttan elde edildiği belirtilmiştir. DY polarizasyonlu bant ile üretilen doku özelliklerinin DD polarizasyonlu bant ile üretilenden daha iyi performans gösterdiği belirtilmiştir.

Nuthammachot ve Stratoulas (2019) tarafından yapılan çalışmada 25 Şubat 2015 tarihli Sentinel-1 SAR görüntüsü ile 18 Mart 2015 tarihli Landsat-8 OLI görüntüsü kullanılarak resolution merge ve The Local Mean Variance Matching (LMVM) veri kaynaştırma teknikleri karşılaştırılmıştır. Sentinel-1A uydusunun DD ve DY polarizasyonlu bantları kullanılmıştır. Sentinel-1A SAR, Landsat-8 OLI, Resolution merge (Sentinel-1 + Landsat 8) ve LMVM (Sentinel-1 + Landsat 8) olmak üzere 4 veri En Yüksek Olasılık (ML) kontrollü sınıflandırma algoritması kullanılarak sınıflandırılmıştır. Elde edilen sonuçlara göre yalnızca Sentinel-1A SAR verisi ile %58,50 genel doğruluk ve 0,48 kapa katsayısı, yalnızca Landsat-8 OLI verisi ile % 67,16 genel doğruluk ve 0,59 kapa katsayısı doğruluk değerleri hesaplanmıştır. Resolution merge tekniği ile kaynaştırılmış Sentinel-1 ve Landsat-8 verisi kullanılarak %79,75 genel doğruluk ve 0,75 kapa katsayısı değerleri hesaplanmıştır. LMVM tekniği ile kaynaştırılmış Sentinel 1 + Landsat 8 verisi kullanılarak yapılan sınıflandırmada, %59,84 genel doğruluk ve 0,52 kapa katsayısı değerleri hesaplanmıştır.

Otukei vd. (2015) tarafından yapılan çalışmada, 4 Aralık 2009 ve 15 Aralık 2009 tarihli 2.75 m çözünürlüklü TerraSAR-X ve 21 Şubat 2005 tarihli 30 m çözünürlüklü Landsat ETM+ görüntüleri high pass filtering (HPF), Principal Component Analysis with band substitution (PCA), Principal Component with Wavelet Transform (WPCA) görüntü kaynaştırma teknikleri kullanılarak kaynaştırılmış ve karar ağacı sınıflandırıcı algoritması ile sınıflandırılmıştır. HPF, PCA ve WPCA teknikleri ile kaynaştırılmış görüntülerde sırasıyla %74,99, %83,12 ve %85,38 genel doğruluk ve sırasıyla 0,7220, 0,8100 ve 0,8369 kapa katsayısı değerleri elde edilmiştir. WPCA'nın kullanılan kaynaştırma teknikleri içinde en uygun olduğu belirtilmiştir.

Suwarsono vd. (2018) tarafından yapılan çalışmada 1 Ekim 2018 tarihli Landsat 8 ile 17 Eylül 2018 tarihli Sentinel-1 SAR görüntüsü RGB Transformation ve Brovey Transformation görüntü kaynaştırma yöntemleri ile kaynaştırılarak volkanlardaki lav akışı birikintilerinin görünümünü keskinleştirmek için morfolojisi çıkartılmıştır. Çalışmada Sentinel-1 DD polarize bant kullanılmıştır. Sonuçlar görsel olarak şekiller ile kıyaslanarak verilmiştir. Sonuçlara göre kullanılan görüntü ve tekniklerin yanardağların her türlü hava koşullarında sürekli olarak gözlemlenebildiğini göstermiştir.

Dimov vd. (2016) tarafından yapılan çalışmada; Özbekistan, Frage Vadisinde yaz ürünü alanlarını, bahçe alanlarını ve meyvelik alanların ayırmasını yapmak için 8 Ağustos 2015 tarihli Sentinel-1 SAR ve Landsat 8 OLI görüntüleri, Wavelet, Ehlers, Principal Component Analysis (PCA), Gram-Schmidt görüntü kaynaştırma teknikleri ile kaynaştırılmıştır. Her bir yöntem ile kaynaştırılan görüntüler DVM, En Yakın Komşuluk, Rastgele Orman (RO) ve Naive Bayesian (NB) algoritmaları ile sınıflandırılmıştır. Ehlers yöntemi ile kaynaştırılan görüntünün RO algoritması ile sınıflandırması %85,9 genel doğruluk ile en iyi sonucu vermiştir.

Cao vd. (2020) tarafından yapılan çalışmada, Çin, Heilongjiang şehrinde 2015 yılı Mayıs ve Ekim ayları arasında çekilmiş Sentinel-1 SAR ve Landsat 7 Enhance Thematic Mapper-Plus (ETM+) ve Landsat 8 OLI görüntülerinden türetilmiş Normalleştirilmiş Fark Bitki İndeksi (NDVI) bantları birlikte kullanılarak çeltik ürünü haritalamasına yönelik sınıflandırma yapılmıştır. Çalışmada SAR DD ve DY bantları ile NDVI bandı kaynaştırılarak kullanılmıştır. DVM ve RO algoritmaları kullanılarak yapılan sınıflandırmada en iyi sonuçlar 0,94 genel doğruluk ve 0,93 kappa katsayısı ile RO algoritması ve DY polarize durumundaki SAR verisinin birlikte kullanılarak hesaplanan sınıflandırmadan elde edilmiştir.

Forget vd. (2018) tarafından yapılan çalışmada, Sub-Saharan Africa da yerleşim alanları içinde ve dışında 2015 ve 2016 yıllarında farklı zamanlarında alınmış 12 adet Sentinel-1A , -1B SAR ve Landsat-8 verileri kaynaştırılarak piksel tabanlı RO algoritması ile sınıflandırma yapılmıştır. SAR verisinin DD ve DY polarizasyon bantları kullanılmıştır. DD polarizasyon bandının DY'ye göre daha iyi performans verdiği belirtilmiştir. Grey Level Co-Occurrence Matrix (GLCM) ile farklı pencere boyutlarında doku özellikleri oluşturularak analiz edilmiştir. PCA görüntü kaynaştırma tekniği kullanılarak optik ve SAR veriler birleştirilmiştir. Yalnızca optik veri, yalnızca SAR verisi ve PCA tekniği ile kaynaştırılmış SAR ve optik verisi ile piksel tabanlı RO algoritması ile yapılan sınıflandırma sonuçlarının karşılaştırmasında kaynaştırılmış görüntülerin sınıflandırması ile elde edilen sonuçlar diğerlerine göre oldukça yüksek performans sağlamıştır.

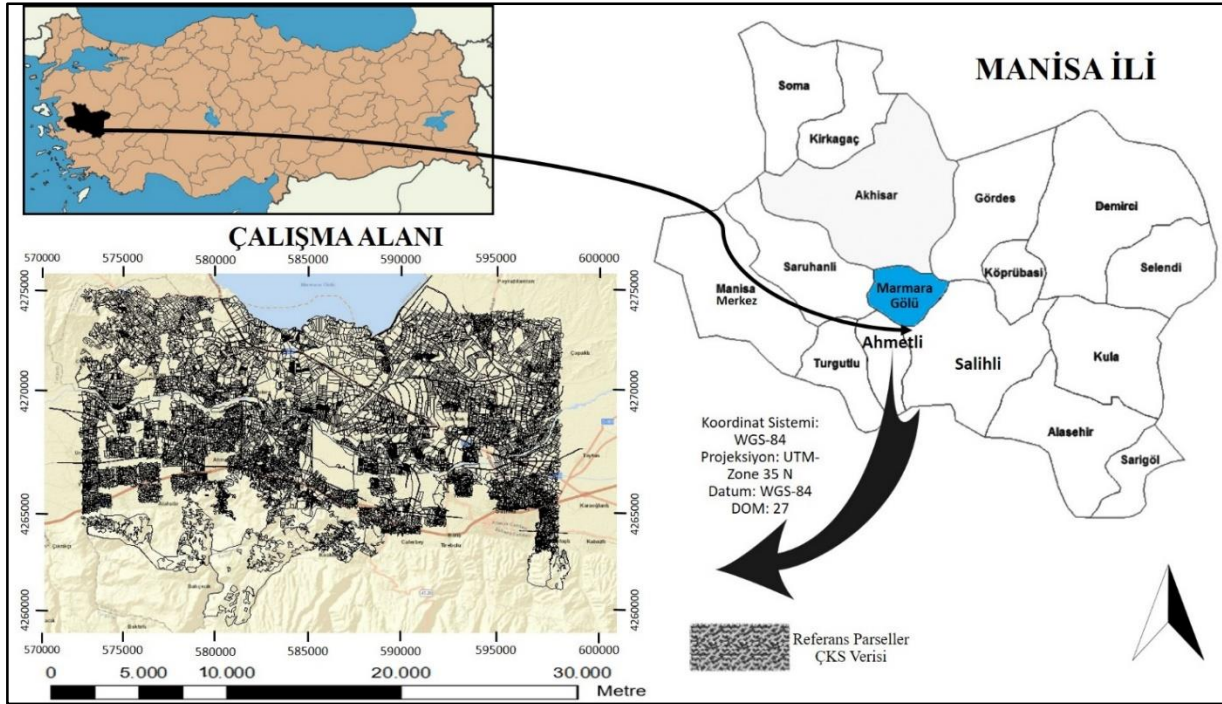
Zhang ve Xu (2018) tarafından yapılan çalışmada, Çin'in, The Pearl River Delta (PRD) bölgesinde en iyi arazi örüsünü bulma amaçlı görüntü sınıflandırma yapılmıştır. Çalışmada, 30 m çözünürlüklü Landsat ETM+ ile 75 m çözünürlüklü ENVISAT ASAR (WSM) görüntüsü, 10 m çözünürlüklü SPOT-5 ile 12,5 m çözünürlüklü ENVISAT ASAR (IMP) görüntüsü, 10 m çözünürlüklü SPOT-5 ile 3 m çözünürlüklü TerraSAR-X görüntüsü, Pixel level, Feature Level A, Feature Level B ve Decision Level kaynaştırma teknikleri ile kaynaştırılmıştır. Kaynaştırılmış görüntülerin sınıflandırması, ML, Artificial Neural Network (ANN), DVM ve RO algoritmaları ile yapılmıştır. Feature Level B tekniği ile elde edilen kaynaştırılmış görüntü ile ML, ANN, DVM ve RO algoritmaları ile yapılan sınıflandırma diğer kaynaştırma yöntemlerine göre (0,92 genel doğruluk ve 0,96 kappa katsayısı) daha iyi performans sağlamıştır.

Bu çalışmanın amacı, tek tarihe ait (07.06.2017) kaynaştırılmış Sentinel-1 Yapay Açıklıklı Radar (Synthetic Aperture Radar-SAR) (Düşey Düşey-DD ve Düşey Yatay-DY bantlar) ve Landsat-8 verilerinin makine öğrenme algoritması kullanılarak sınıflandırılması, yapılan sınıflandırma sonucunda tespit edilen tarımsal yaz ürünlerinin sınıflandırma performansına etkisini araştırmaktır. Manisa İli, Salihli ve Ahmetli İlçeleri arasında kalan tarımsal alan çalışma alanı olarak seçilmiştir. Çalışmada, Sentinel-1 10 m çözünürlüklü DD ve DY polarizasyonlu bantlar ve Landsat-8 30 m çözünürlüklü Kıyı Aerosol, Mavi, Yeşil, Kırmızı, Yakın Kızılötesi, Kısa Dalga Kızılötesi 1 ve Kısa Dalga Kızılötesi 2 bantlar kullanılmıştır. Görüntü kaynaştırma işlemi Ehlers yöntemi ile gerçekleştirilmiştir. Sınıflandırma için RO makine öğrenme algoritması kullanılmıştır. Tespit edilen ürünler bölgede en yaygın ekilen buğday, domates, mısır, mısır2, pamuk, üzüm, yonca ve zeytindir. SAR ve optik görüntülerin kaynaştırılarak kullanıldığında ürün tespiti sınıflandırma doğruluğuna olumlu katkısı hesaplanan doğruluk değerleri ile gösterilmiştir.

2. Çalışma Alanı ve Veriler

Çalışma alanı, Manisa İli; Ahmetli ve Salihli İlçeleri sınırları içinde yer alan yaklaşık 520 km²lik bir tarımsal alandan oluşmaktadır (Şekil 1). Çalışma alanının yaklaşık koordinatları 573369.16 m, 4275559.88 m (Kuzey Batı); 573369.16 m, 4257782.09 m (Güney Batı); 603175.50 m, 4275559.88 m (Kuzey Doğu); 603175.50 m, 4257782.09 m (Güney Doğu) ve projeksiyon bilgileri WGS 84, UTM-Zone 35 N, DOM 27 şeklindedir.

Çalışma alanındaki parsellerin büyük bir bölümü yaz ürünleri ile ekili olmasının yanında, alımı yapılan görüntü tarihi itibarıyla ekili olmayan nadas alanları ve tarım dışı alanlar da bulunmaktadır. Bölgede yetiştirilen ürünler ağırlıklı olarak buğday, domates, mısır, pamuk, üzüm, yonca olup sabit ürün olarak da zeytin bulunmaktadır. Ayrıca, bir yıl içerisinde birden fazla ürün hasadı da yapılmaktadır. Tarım parsellerinin büyüklükleri yaklaşık 3 dekar ile 4700 dekar arasında değişmektedir.



Şekil 1. Çalışma alanı

Alanı kapsayan Sentinel-1 SAR görüntüsü ile Landsat-8 optik görüntülerin görsel incelemesi yapılmış ve her iki uyduya ait aynı tarihte (07.06.2017) alımı yapılmış görüntüler seçilmiştir. Sentinel-1 SAR görüntülerinin DD ve DY polarizasyonlu C bantları ve Landsat-8 uydu görüntülerinin Kıyı Aerosol, Mavi, Yeşil, Kırmızı, Yakın Kızılötesi, Kısa Dalga Kızılötesi 1 ve Kısa Dalga Kızılötesi bantları ilgili sitelerden (Copernicus, 2021; EarthExplorer, 2021) indirilmiştir. İndirilen veri dosyaları metadata, geometrik ve radyometrik düzeltme dosyaları vb. bilgileri de içermektedir. Sentinel-1 SAR görüntüsü DD ve DY polarizasyonlu SAR C bantları ile Landsat-8 Kıyı Aerosol, Mavi, Yeşil, Kırmızı, Yakın Kızılötesi, Kısa Dalga Kızılötesi 1 ve Kısa Dalga Kızılötesi 2 optik bantlarının konumsal çözünürlükleri birbirinden farklıdır. Uyduların bantlarına ait konumsal çözünürlük bilgisi Tablo 1' de verilmiştir.

Tablo 1. Çalışmada kullanılan Sentinel-1 ve Landsat-8 görüntüleri bantları ve konumsal çözünürlükleri

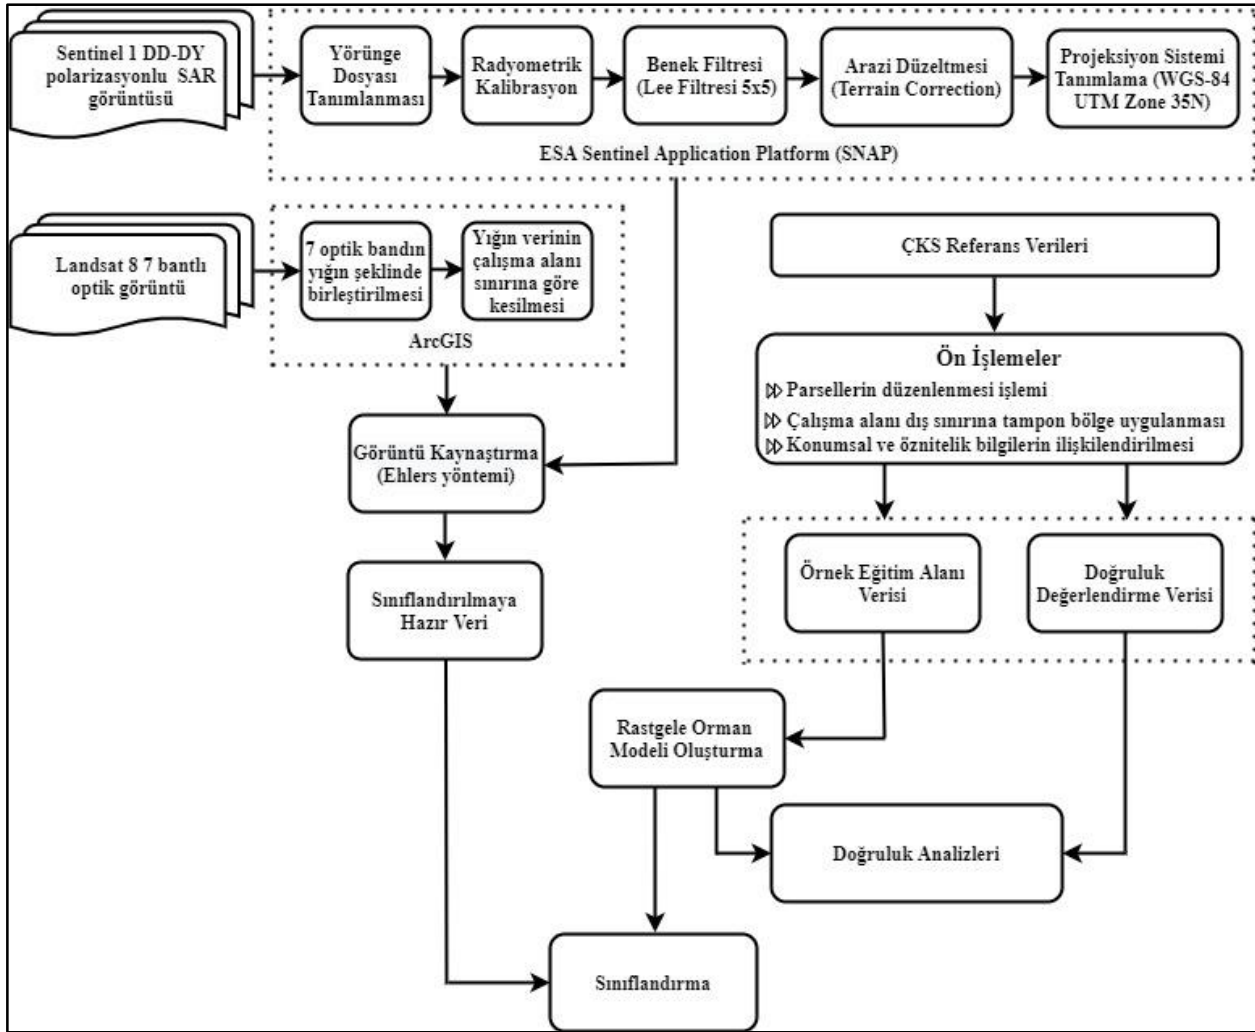
Uydu	Band	Konumsal Çözünürlük (m)
Sentinel-1	C band- DD polarizasyon	10
	C band- DY polarizasyon	10
Landsat-8	Band 1- Kıyı Aerosol	30
	Band 2- Mavi	30
	Band 3- Yeşil	30
	Band 4- Kırmızı	30
	Band 5- Yakın Kızıl Ötesi	30
	Band 6- Kısa Dalga Kızılötesi 1	30

Çiftçi Kayıt Sistemi (ÇKS), tarımsal desteklemelerin izlenebilir, denetlenebilir, raporlanabilir ve sorgulanabilirliğinin sağlanması için, çiftçi bilgilerinin bir veri tabanında toplandığı bir kayıt sistemidir (T.C. Tarım ve Orman Bakanlığı, 2021). Bu çalışmada zemin doğrulama referans verisi olarak mevcut ÇKS verileri kullanılmıştır.

ÇKS verisinin konumsal bilgileri arasında fiziksel yeryüzü üzerinde temsil ettiği lokasyon bilgisi bulunurken, öznitelik bilgileri arasında ise veri tipi, il, ilçe, mahalle, ada ve parsel numarası gibi tapu kaydı bilgileri ve zemin referans numarası, toplam parsel yüzölçümü, ekili alan yüzölçümü, ekili ürün adı ve toplam parsel yüzölçümü ile ekili alan yüzölçümü arasındaki fark değeri bilgileri yer almaktadır. Çalışma alanına ait ÇKS verisinde toplam 28169 adet parsel bulunmaktadır.

3. Yöntem

Çalışmada kullanılan yöntemin adımlarını özetleyen akış diyagramı Şekil 2’de gösterilmiştir. Yöntem, veri ön işlemleri, görüntü kaynaştırma, sınıflandırma ve doğruluk analizleri olmak üzere dört temel adımdan oluşmaktadır. İlk olarak, Sentinel-1 SAR ile Landsat-8 optik görüntülere gerekli ön işleme adımları uygulanmıştır. Sonra, zemin referans verisi olarak kullanılabilmesi için, ÇKS verisi üzerinde gerekli düzenleme işlemleri yapılmıştır. Yöntemin ikinci adımında, Sentinel-1 SAR görüntüleri ile Landsat-8 optik görüntüleri Ehlers görüntü kaynaştırma tekniği kullanılarak kaynaştırılmıştır. Görüntü kaynaştırma ile elde edilen kaynaştırılmış görüntüler, RO makine öğrenme algoritması tekniği kullanılarak, parsel-tabanlı yaklaşımla sınıflandırılmıştır. Son adım olarak, elde edilen sonuçların doğruluk analizleri yapılmıştır.



Şekil 2. Yöntemin akış diyagramı

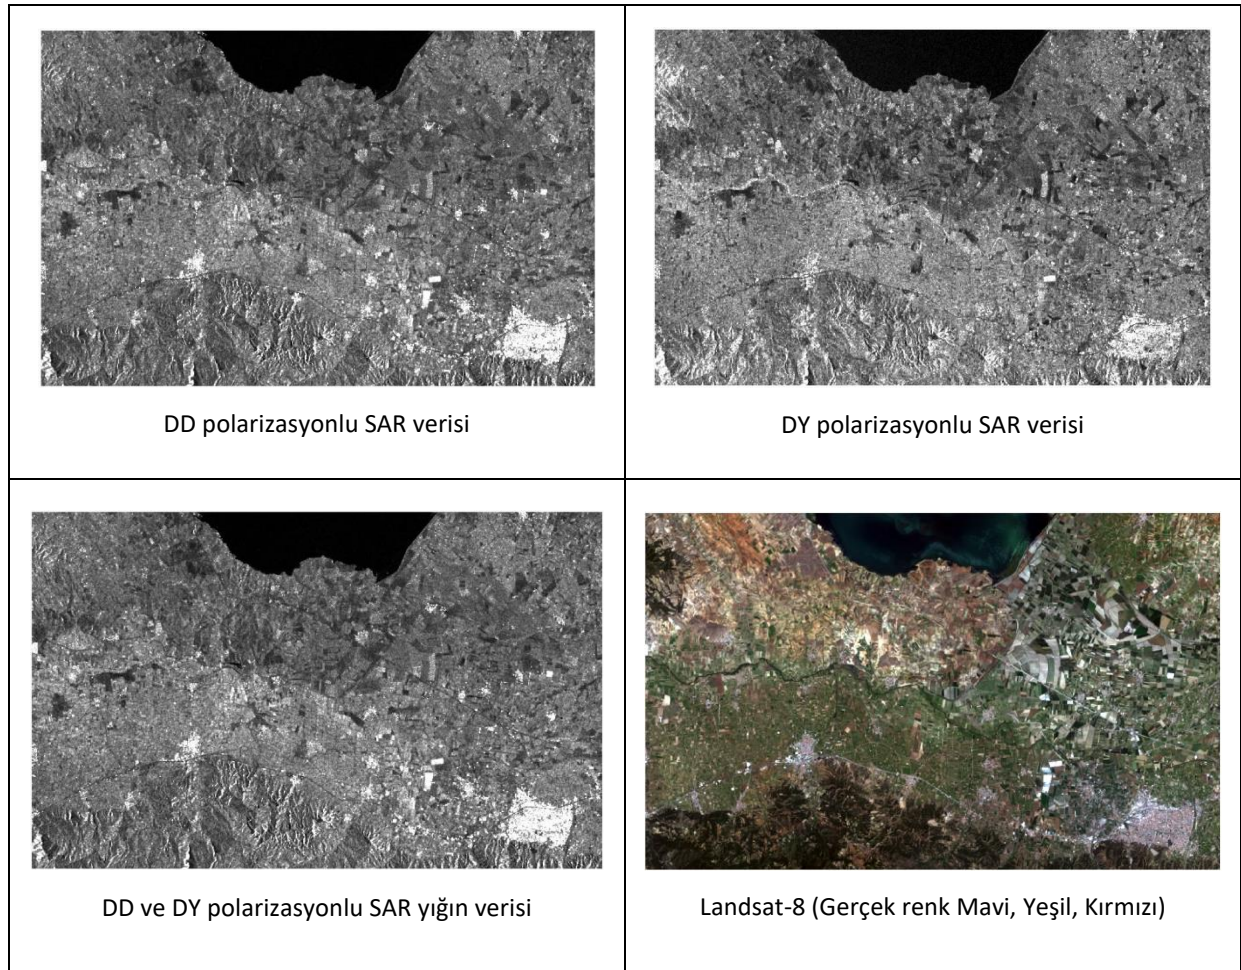
3.1 Veri Ön İşlemleri

Interferometric Wide Swath (IW) modunda ve Level 1 Grid (GRDH) formatında temin edilen Sentinel-1 DD ve DY polarizasyonlu verilere ön işlemler uygulanmıştır. Ön işlemler için Avrupa Uzay Ajansı (European Space Agency-ESA) tarafından ücretsiz olarak sağlanan Sentinel Uygulama Platformu (Sentinel Application Platform-SNAP) yazılımı kullanılmıştır (ESA Copernicus Open Access Hub, 2021). Sırasıyla, yörünge dosyası uygulama, radyometrik kalibrasyon, benek filtreleme (Lee Filtresi 5x5), topografik düzeltme ve geri yansıma db çevirme ön işleme adımları gerçekleştirilmiştir. Yörünge dosyası uygulama ön işleme adımı ile SAR verisinin uydu yörünge durum vektörlerine güncel düzeltmeler getirilerek doğru uydu konumu ve hız bilgisi elde edilmiştir. Radyometrik kalibrasyon adımı piksel değerleri radyometrik olarak kalibre edilmiş SAR geri yansıma değerlerine çevrilmiştir.

SAR görüntülerinde taneli gürültü olarak görünen benek, birçok temel geri yansılardan yansıyan dalgaların kaynağa gelmesinden kaynaklanmaktadır (Lee vd. 1994). Dolayısıyla, benek filtreleme adımında 5x5 Lee filtresi (Filipponi, 2019) uygulanarak taneli gürültü azaltılmıştır. SAR sinyallerinin yanal gözleme geometrisi nedeniyle, yeryüzündeki engebeli topografya SAR sinyallerinin geri saçılma değerlerini etkilemektedir. Bu etki çok engebeli arazide, örneğin tepelik alanlarda, veri çekimi açısındaki değişikliklerden (artış ve azalma) dolayı çok yüksek olabilmektedir. Dolayısıyla, topografik düzeltme ile bu bozulmalar düzeltilmiş ve görüntü geometrik olarak gerçek yeryüzüne en yakın hale getirilmiştir. Geri yansıma dB çevirme adımında, Eşitlik 1' de verilen logaritmik dönüşüm kullanılarak herhangi bir birim değeri olmayan geri yansıma katsayıları dB olarak çevrilmiştir (Filipponi, 2019).


$$\beta_{db}^0 = 10 * \log_{10}(\beta^0) \quad (1)$$

Landsat-8 optik uydu görüntüsüne uygulanan ön işleme adımı sınıflandırmada kullanılacak bantların ArcGIS yazılımında birleştirilmesi işleminden ibarettir (ArcGIS User Guide, 2021). Ön işleme aşamaları sonrası elde edilen DD, DY ve DD+DY polarizasyonlu Sentinel-1 SAR verileri ile Landsat-8 optik görüntü Şekil 3'de verilmiştir.



Şekil 3. Ön işleme aşamaları sonrası elde edilen DD, DY ve DD+DY polarizasyonlu Sentinel-1 SAR verileri ile Landsat-8 optik görüntünün gösterimi

Sonuçların doğruluk analizlerinde kullanılacak yer gerçeği verilerine (ÇKS verileri) gerekli ön işleme adımları uygulanmıştır. Birçoğu ekili ürün içermediğinden alanı 1000 m²'den küçük parseller elimine edilmiştir. Parsellerde yetiştirilen ürün türleri ile parsellerin (poligonun) konumsal verisi ilişkilendirilmiştir. Yapılan düzenleme işlemlerinden sonra, kalan 1024 parsel referans veri olarak kullanılmıştır (Şekil 4).




Şekil 4. Referans veri olarak kullanılan parseller

3.2 Sentinel-1 SAR ve Landsat-8 Optik Görüntülerin Kaynaştırılması

Çalışmada Sentinel-1 SAR görüntüsü (DD ve DY bantları) ile Landsat-8 görüntüsünün (çoklu spektral bantlar) kaynaştırılması için, Ehlers görüntü kaynaştırma tekniği kullanılmıştır (Adrian vd. 2021; Erdas Imagine User Guide, 2021). Ehlers kaynaştırma yöntemi, kaynaştırılmış görüntüyü üretirken IHS (Intensity-Hue-Saturation) ve Fourier dönüşümlerini kullanmaktadır (Alparone vd. 2004; Klonus ve Ehlers, 2009). Orijinal çok bantlı görüntüye (bu çalışmada Landsat 8-bantları) IHS dönüşümü uygulanır. IHS dönüşümü sonrası parlaklık bileşeni elde edilir. Parlaklık bileşenine ve görüntü kaynaştırmada kullanılacak olan pankromatik görüntüye (bu çalışmada Sentinel-1 DD ve DY polarizasyonlu bantlar) FFT (Fast Fourier Transformation) dönüşümü uygulanarak frekans uzayına geçiş sağlanır (Breiman, 2001). Çoklu bantlı verinin parlaklık bileşeni alçak geçirgen filtre ile filtrelenir. Pankromatik verinin bileşeni ise yüksek geçirgen filtreyle filtrelenir (Gungor, 2008; Dammavalam, 2012). Frekans uzayında filtrelenmiş bileşenlere ters FFT dönüşümü uygulanarak tekrar konumsal uzaya geçilir. Konumsal uzayda kaynaştırması yapılacak girdi görüntüler toplanarak yeni bir parlaklık bileşeni oluşturulur. Yeni parlaklık bileşeni ve IHS dönüşümünde kullanılan ton (hue) ve doygunluk (saturation) bileşenleri kaynaştırma işlemine girdi veri kabul edilerek ters IHS dönüşümü uygulanır ve kaynaştırılmış görüntü elde edilmiş olur (Pal, 2005a; Schowengerdt, 2007).

Ehlers görüntü kaynaştırma tekniğinin avantajı frekans uzayında filtreleme yapmasıdır (Yılmaz ve Güngör, 2013). Buna karşın kaynaştırılmış görüntünün piksel parlaklık değerlerinin, orijinal girdi çok bantlı görüntüye göre fazla olabilmesi bir dezavantaj olarak kabul edilmektedir (Mather ve Tso, 2009). Bu çalışmada görüntü kaynaştırma işleminin yapılmasının amacı Sentinel-1 SAR ve Landsat-8 verilerinin birleşiminden yüksek konumsal çözünürlüklü çok bantlı veri elde edebilmektir. Bunun için birinci girdi veri yüksek konumsal çözünürlüklü pankromatik özellikli Sentinel 1 DD ve DY polarizasyonlu SAR verisi, ikinci girdi veri düşük konumsal çözünürlüklü çok bantlı (7 bant) optik Landsat 8 veridir. Ehlers görüntü kaynaştırma tekniğinin görüntülerin spektral yapısını değerlendirirken frekans uzayında parlaklık (intensity), ton (hue) ve renksel doygunluk (saturation) bileşenlerini frekans uzayında ele alması ve renk yapısını korumadaki başarısı, kaynaştırılan sonuç ürünler üzerinden görsel analizler yardımıyla tespit edildiğinden, Ehlers yöntemi bu çalışma için tercih sebebi olmuştur. Bu çalışmada görüntü kaynaştırma işlemi Erdas Imagine yazılımı ile yapılmıştır. Çalışma alanı içerisinde farklı bölgelere ait kesitler Şekil 5' de gösterilmiştir. Şekil 5 (a), Sentinel-1 DD polarizasyonlu veriyi; Şekil 5 (b), Landsat-8 7 bantlı optik veriyi; Şekil 5 (c) ise kaynaştırma işlemi sonrası elde edilen veriyi temsil eden kesitlerdir.



Şekil 5. Seçili alanlara ait görüntülerin kaynaştırma öncesi ve sonrası gösterimi: (a) Sentinel-1 DD polarizasyonlu bant, (b) Landsat-8 gerçek renkli (B4, B3, B2) görüntü, (c) Kaynaştırılmış gerçek renkli (B4, B3, B2) görüntü

Görüntülerin kaynaştırılması sonucu elde edilen görüntülerin başarısını ölçmek ve çeşitli parametrelerin kalitesini değerlendirmek amacıyla görsel analiz ve yorumlamanın yanı sıra nicel ölçütlere ihtiyaç duyulmaktadır. Bu ihtiyacı karşılamak amacıyla bu çalışmada, literatürde kabul gören ve sıkça kullanılan iki adet değerlendirme yöntemi kullanılmıştır. Başarı ölçütü yöntemlerinde referans görüntü olarak Landsat-8 çok bantlı optik veri, kaynaştırılma başarısı hesaplanacak olan görüntü olarak ise Sentinel-1 SAR DD, DY ve DD+DY bantları ile Landsat-8 çok bantlı verilerin kaynaştırılmış görüntüsü kullanılmıştır. Değerlendirme yöntemleri olarak yaygın kullanılan ve RMSE (Root Mean Square Error - Karese Ortalama Hata) (Witharana vd. 2013) ve ERGAS (Erreur Relative Globale Adimensionnelle de Synthèse - Boyutsuz Global Görelî Sentez Hatası) (Alparone vd. 2008) yöntemleri seçilmiştir. RMSE başarı değerlendirici metriği görüntünün her bir pikselindeki değişim miktarını belirlemekte kullanılır ancak bu metrik kaynaştırmada kullanılan görüntülerin konumsal çözünürlüklerini dikkate almaz. RMSE başarı ölçütü çok bantlı referans görüntü ile kaynaştırılmış görüntü arasındaki farkların karesel ortalama hatasını temel alan metriktir (Witharana vd. 2013).

Eşitlik 2 sonucu elde edilen değer ile görüntü kaynaştırma arasında ters orantılı bir ilişki olup, Eşitlik 2 ile hesaplanan değer ne kadar küçük değer olarak hesaplanırsa, görüntü kaynaştırma kalitesinin o kadar başarılı olduğu kabul edilir.

$$RMSE = \sqrt{\frac{\sum_x \sum_i (X_i(x) - Y_i(y))^2}{n \times m \times d}} \quad (2)$$

Eşitlik 2’de yer alan parametrelerden; X çok bantlı görüntüyü, Y kaynaştırma işlemi sonrası elde edilen görüntüyü x ve y piksel indeksini, i bant numarasını ifade etmektedir. Eşitlik 2’ nin payda kısmında yer alan n satır sayısını, m sütun sayısını, d ise bant sayısını göstermektedir. RMSE değerlendirme yönteminin etki alanı aralığının (domain interval) sıfır (0) ile sonsuz (∞) aralığında olması beklenmektedir. RMSE ölçütü görüntünün her pikselindeki spektral distorsiyonun ortalama oranını temsil etmektedir. Sıfır (0) değerine yakın RMSE, kaynaştırılmış görüntünün çok bantlı görüntüye yakın olduğunu gösterir (Witharana vd. 2013).

ERGAS kalite metriği ise, kaynaştırılmış görüntüdeki piksel parlaklık değerlerinin yüksek çözünürlükten düşük çözünürlüğe geçtiği andaki kalitesini ölçer. Bir başka ifade ile ERGAS başarı değerlendirici metriği, kaynaştırılmış görüntüdeki radyometrik bozulmaları tespit edebilmektedir. ERGAS değerlendirme yönteminin etki alanı aralığının (domain interval) sıfır (0) ile sonsuz (∞) aralığında olması beklenmektedir. Eşitlik 3 sonucu hesaplanan değer ne kadar küçük ise, bir başka deyişle sıfıra ne kadar yakınsar ise kaynaştırma işleminin o kadar başarılı sayıldığı kabul edilir.

$$ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{RMSE(n)}{\mu(n)} \right)^2} \quad (3)$$

Eşitlik 3’ de N bant sayısını, RMSE karesel ortalama hatayı, $\frac{h}{l}$ pankromatik görüntüdeki piksel parlaklık değerlerinin çok bantlı görüntüdeki piksel değerlerine oranını, $\mu(n)$ ise n . bandın ortalamasını göstermektedir. ERGAS, kaynaştırılmış görüntüdeki spektral bozulma miktarını ifade etmektedir. Yüksek spektral kaliteli görüntü elde etmek için ERGAS değerinin mümkün olduğunca küçük olması beklenir (Alparone vd. 2008).

3.3. Görüntü Sınıflandırma

Sınıflandırma işlemi MATLAB R2019b ortamında RO makine öğrenme algoritması ile gerçekleştirilmiştir (MathWorks, 2021). RO algoritması temel sınıf olarak karar ağacını kullanan topluluk algoritmalarından birisidir (Breiman, 2001; Horning, 2010). İlk olarak eğitim veri setinin 2/3’ ünden önyükleme örnekleri oluşturulur. Bu örnekler eğitim veri setlerini oluşturur ve ağaç gelişimi için kullanılır. Genelleştirilmiş hatalar (Out of Bag-OOB errors) verisi olarak da adlandırılan eğitim veri setinin 1/3’ lük geri kalan kısmı hataları test etmek için kullanılır. Ağaç gelişim işlemine başlamadan önce, RO algoritmasını başlatmak için kullanıcı tarafından iki parametre tanımlanır. Bu parametreler, en iyi bölünmeyi belirlemek için her bir düğümde kullanılan değişken sayısı (mtry) ve geliştirilecek ağaçların sayısıdır (ntree). Toplam değişken (bant) sayısının M adet olduğu varsayılırsa, M sayısının kareköküne eşit alınan mtry sayısı genel olarak optimum sonuca en yakın sonucu verdiği varsayılır (Horning, 2010). RO algoritması birçok bireysel karar ağacı tarafından yapılan sınıflandırmaları birleştirir.

Bu tip bir modelin eğitimi için sadece rastgele özniteliklerin uzay boyutluluğunun değil, aynı zamanda söz konusu bölme değişkenleri tarafından üretilen karar limitlerine dayalı olarak oluşturulacak ağaç sayısının da tanımlanması gerekmektedir (Breiman vd. 1984; Congalton ve Green, 2008). Rastgele Orman (RO) sınıflandırıcısı diğer sınıflandırma algoritmalarından farklı olarak, birbirinden bağımsız ve rastgele seçim ile belirlenen çoklu karar ağaçlarını kullanır. Oluşturduğu her bir ağaç, farklı bir modeli temsil eder. RO’nun bu çalışma prensibi, ağaçlar arasındaki korelasyonu minimuma indirdiği için, diğer makine öğrenme algoritmalarına göre daha yüksek sınıflandırma sağlamaktadır (Breiman, 2001). Parametre değerlerinin seçiminden sonra, her bir önyüklemeli örnekten budama olmadan tanımlanan mtry ve ntree parametrelerine göre ağaçlar geliştirilir. Her bir ağacın oluşturulması için bu işlemler tekrarlanır. Orman oluşturulduktan sonra nesnel tüm ağaçlar tarafından sınıflandırılır ve tüm sınıflandırmaların çoğunluk değeri alınarak sonuç sınıf elde edilir (Liaw ve Wiener, 2002; Akar, 2013). RO algoritmasında tanımlanan ağaç sayısı (ntree) kadar ağaç üretildiğinde, ntree tane ağaçtan elde edilen tahmin sonuçlarına dayanılarak aday pikselin sınıfı belirlenir (Liaw ve Wiener; 2002).

Bu çalışmada, Breiman (2003), Breiman (2001), Pal (2005) ve Archer ve Kimes (2008) tarafından yapılan çalışmalara dayanarak ntree değeri olarak 100 alınmış, mtry değeri ise $\sqrt{\text{band sayısını}}$ şeklinde hesaplanmıştır. Sınıflandırma işlemi farklı sayıda girdi görüntüleri ile gerçekleştirilmiştir. Dolayısıyla, her bir sınıflandırma işleminde girdi görüntü sayısı değiştiği için bant sayısı da değişmiştir. Örneğin, yalnız Sentinel-1 verisi DD veya DY polarizasyonlu bandın kullanıldığı sınıflandırma işleminde mtry değeri $\sqrt{1}$ iken, kaynaştırılmış Sentinel-1 (DD veya DY polarizasyonlu bant) ve Landsat-8

verisinin kullanıldığı sınıflandırma işleminde mtry değeri $\sqrt{7}$, kaynaştırılmış Sentinel-1 verisi (DD ve DY) ve Landsat-8 verisinin kullanıldığı sınıflandırma işleminde ise mtry değeri $\sqrt{14}$ olarak hesaplanmıştır. Sınıflandırmada, homojen piksel grupları ile işlem yapılan parsel-tabanlı yaklaşım kullanılmıştır. Parsel-tabanlı yaklaşımda piksellerin şekil, renk, doku, büyüklük, ilişki ve desen gibi belirli özelliklerine göre piksel grupları oluşturulup, işlemler bu piksel grupları üzerinden yapılmaktadır (Utgoff ve Brodley, 1990; Pal ve Mather, 2003; Rodriguez-Galiano vd. 2012). Bu çalışmada homojen piksel gruplarının tanımlanmasında ÇKS parsel sınırları verisi kullanılmıştır. Her bir parsel için, o parsel içine düşen sınıflandırılmış piksellerin frekans hesabı yapılmış ve frekansı en yüksek sınıfın etiketi parsel içindeki tüm piksellere atanmıştır. 1024 adet referans parsel verisinin yarısı (512 adet) eğitim verisi, yarısı da (512 adet) sınıflandırma doğruluğunun hesaplanması için test verisi olarak kullanılmıştır.

Buğday, Domates, Mısır, Mısır_2, Pamuk, Üzüm, Yonca ve Zeytin sınıflandırma ile tespit edilecek ürünler (sınıflar) olarak belirlenmiştir. Görüntülerin ve ÇKS verilerinin analizleri neticesinde iki farklı türde mısır ürünü olduğu tespit edilmiş olup mısır iki farklı sınıfa (Mısır ve Mısır_2) ayrılmıştır. Tanımlanan tarımsal ürünlere ilişkin eğitim ve test verileri parsel ve piksel sayıları Tablo 2' de verilmiştir. Sınıflandırma yedi (7) farklı görüntü seti ile yapılmış ve elde edilen sonuçlar karşılaştırılmıştır. Özellikle, kaynaştırılmış tek tarihli Sentinel-1 SAR ve Landsat-8 optik veri setinin sınıflandırma doğruluğuna etkisi değerlendirilmiştir. Sınıflandırma için kullanılan görüntü setleri şunlardır: i) Yalnız Sentinel-1 DD bandı, ii) Yalnız Sentinel-1 DY bandı, iii) Sentinel-1 DD ve DY bantları birlikte, iv) Yalnız Landsat-8 verisi, v) Kaynaştırılmış Sentinel-1 DD bandı ve Landsat-8 veri seti, vi) Kaynaştırılmış Sentinel-1 SAR DY bandı ve Landsat-8 veri seti, vii) Kaynaştırılmış Sentinel-1 DD+DY bantları ve Landsat-8 veri seti.

Tablo 2. Ürünlere ilişkin eğitim ve test verileri parsel ve piksel sayıları

Tarımsal Ürün	Eğitim Verisi (Parsel/Piksel)		Test Verisi (Parsel/Piksel)	
Buğday	94	37852	94	11473
Domates	26	12880	26	4399
Mısır	78	26636	78	10480
Mısır_2	25	7661	25	3628
Pamuk	28	15090	28	7020
Üzüm	202	33996	202	14398
Yonca	8	6027	8	563
Zeytin	51	27482	51	11670
TOPLAM	512	167624	512	63631
GENEL TOPLAM	1024 / 231255			

4. Bulgular ve Yorumlar

Erdas Imagine yazılımında Ehlers görüntü kaynaştırma tekniği kullanılarak yapılan kaynaştırma işleminin RMSE ve ERGAS kalite metrikleri ile hesaplanan matematiksel başarı ölçüt değerleri Tablo 3' de verilmiştir. RMSE başarı ölçütüne göre metrik değerler, kaynaştırılmış Landsat-8 ve Sentinel-1 DD verisi için 25,238, kaynaştırılmış Landsat-8 ve Sentinel-1 DY verisi için 29,187 ve kaynaştırılmış Landsat-8 ve Sentinel-1 DD+DY verisi için 22,643 olarak hesaplanmıştır. RMSE kalite değerlendirici ölçütü etki alanı aralığının (domain interval) sıfır (0) ile sonsuz (∞) aralığında olması gerektiği düşünüldüğünde; kaynaştırılmış görüntülerin, çok bantlı görüntüye hesaplanan metrik değerler kadar yakın olduğu yorumu yapılabilir.

Tablo 3. Kaynaştırma ölçütü sonuçları metrik değerler

Kaynaştırılan Veri	RMSE	ERGAS
Etki Alanı Aralığı (Domain Interval)	[0, ∞)	[0, ∞)
Kaynaştırılmış Landsat-8 ve Sentinel-1 DD	25,238	6,551
Kaynaştırılmış Landsat-8 ve Sentinel-1 DY	29,187	6,599
Kaynaştırılmış Landsat-8 ve Sentinel-1 DD+DY	22,643	5,972

ERGAS kalite ölçümüne göre metrik değerler, kaynaştırılmış Landsat-8 ve Sentinel-1 DD verisi için 6.551, kaynaştırılmış Landsat-8 ve Sentinel-1 DY verisi için 6,599 ve kaynaştırılmış Landsat-8 ve Sentinel-1 DD+DY verisi için 5,972 olarak hesaplanmıştır. Kaynaştırma sonucu elde edilen metrik değerler etki alanı aralığının (domain interval) sıfır (0) ile sonsuz (∞) aralığında olması gerektiği kabul edilen ERGAS metrik değerlendirici yönteminde; kaynaştırılmış görüntülerin, çok bantlı görüntüye hesaplanan değerler kadar yakın olacağı bulgusuna ulaşılabilir. ERGAS metriği ile hesaplanan sayısal değerlerin, RMSE metriği ile hesaplanan sayısal değerlere göre sıfıra daha çok yakınsadığı Tablo 3' de açıkça görülmektedir. Bu durumun RMSE metriğinin kaynaştırmada kullanılan görüntülerin konumsal çözünürlüklerini dikkate almadığı, ERGAS metriğinin ise bu dezavantajı ortadan kaldırdığı gerçeğine bağlanmaktadır. Buna karşılık, ERGAS metriğinin de, kaynaştırılmış görüntü ile orijinal çok bantlı görüntü arasındaki korelasyonu hesaba katmadığı ERGAS kalite ölçütünün bir dezavantajı olarak görülebilir. Bu ve benzeri bazı eksikliklerinden dolayı kalite metrikleri her zaman güvenilir sonuçlar üretemeyebilmektedirler (Gungor, 2008). Bu çalışmada RMSE ile ERGAS yöntemleri kendi aralarında kıyaslandığında ERGAS yönteminin kaynaştırılmış görüntülerin başarısını ölçerken daha etkili bir araç olduğunun çıkarımı Tablo 3'ün yorumlanmasından anlaşılabilir.

Tablo 3'de yer alan RMSE ve ERGAS kalite ölçütleri ile hesaplanan metrik değerler incelendiğinde, görüntü kaynaştırma işlemi sonrasında konumsal detay kalitesi artırılırken, çok bantlı görüntünün renk içeriğinin korunduğu değerlendirilmektedir.

Sınıflandırma sonuçlarının doğruluk analizleri için hata matrisleri oluşturulmuştur. Sınıflandırma işlemi parsel tabanlı yapıldığından, doğruluk analizleri için 512 adet parsel manuel yöntemle seçilerek test verisi olarak kullanılmıştır. Test parselleri sayısının belirlenmesinde, Horning (2010), Liaw ve Wiener, (2002), Akar (2013) ve Rodriguez-Galiano vd. (2012) tarafından yapılan çalışmalar dikkate alınmıştır. Hata matrislerinden genel doğruluk ve Kappa katsayısı değerleri hesaplanmıştır. Ayrıca, her sınıf için üretici doğruluğu (ÜD) ve kullanıcı doğruluğu da (KD) hesaplanmıştır. Hata matrisinin her bir sütunu ayrı bir sınıfa karşılık gelirken, satırlar referans verilerin atandıkları sınıfları temsil etmektedir. Buna göre k tane sınıf için hata matrisi k satır ve k sütundan oluşur (Congalton, 1991; Campbell ve Wynne, 1996). Bu çalışmada k (sınıf sayısı) 8'dir. Eşitlik 4, 5, 6, 7 ve 8'de yer alan n, toplam referans veri örüntü sayısıdır. nij, referans veride j kategorisindeyken (j=1,2,...,k) sınıflandırılmış veri içinde i sınıfına (i=1,2,...,k) atanan örüntülerin sayısını gösterir. İ kategorisine atanan sınıflandırma verisindeki örüntü sayısı Eşitlik 4'de, j kategorisi için referans verideki örüntü sayısı Eşitlik 5'de gösterilmiştir. Genel doğruluk değeri Eşitlik 6'ya göre hesaplanmıştır.

$$n_{i+} = \sum_{j=1}^k n_{ij} \quad (4)$$

$$n_{+j} = \sum_{i=1}^k n_{ij} \quad (5)$$

$$\text{Genel doğruluk} = \frac{\sum_{i=1}^k n_{ii}}{\sum_{j=1}^k n_{+j}} = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (6)$$

Her sınıf için üretici doğruluğu, doğru sınıflandırılmış örnek sayısının o kategoriye ait sütun sayısına bölünmesi ile (Eşitlik 7) ve kullanıcı doğruluğu da doğru sınıflandırılmış örnek sayısının o kategori için olan satır sayısına bölünmesi ile hesaplanmıştır (Eşitlik 8).

$$\text{Üretici Doğruluğu} = \frac{n_{jj}}{n_{+j}} \quad (7)$$

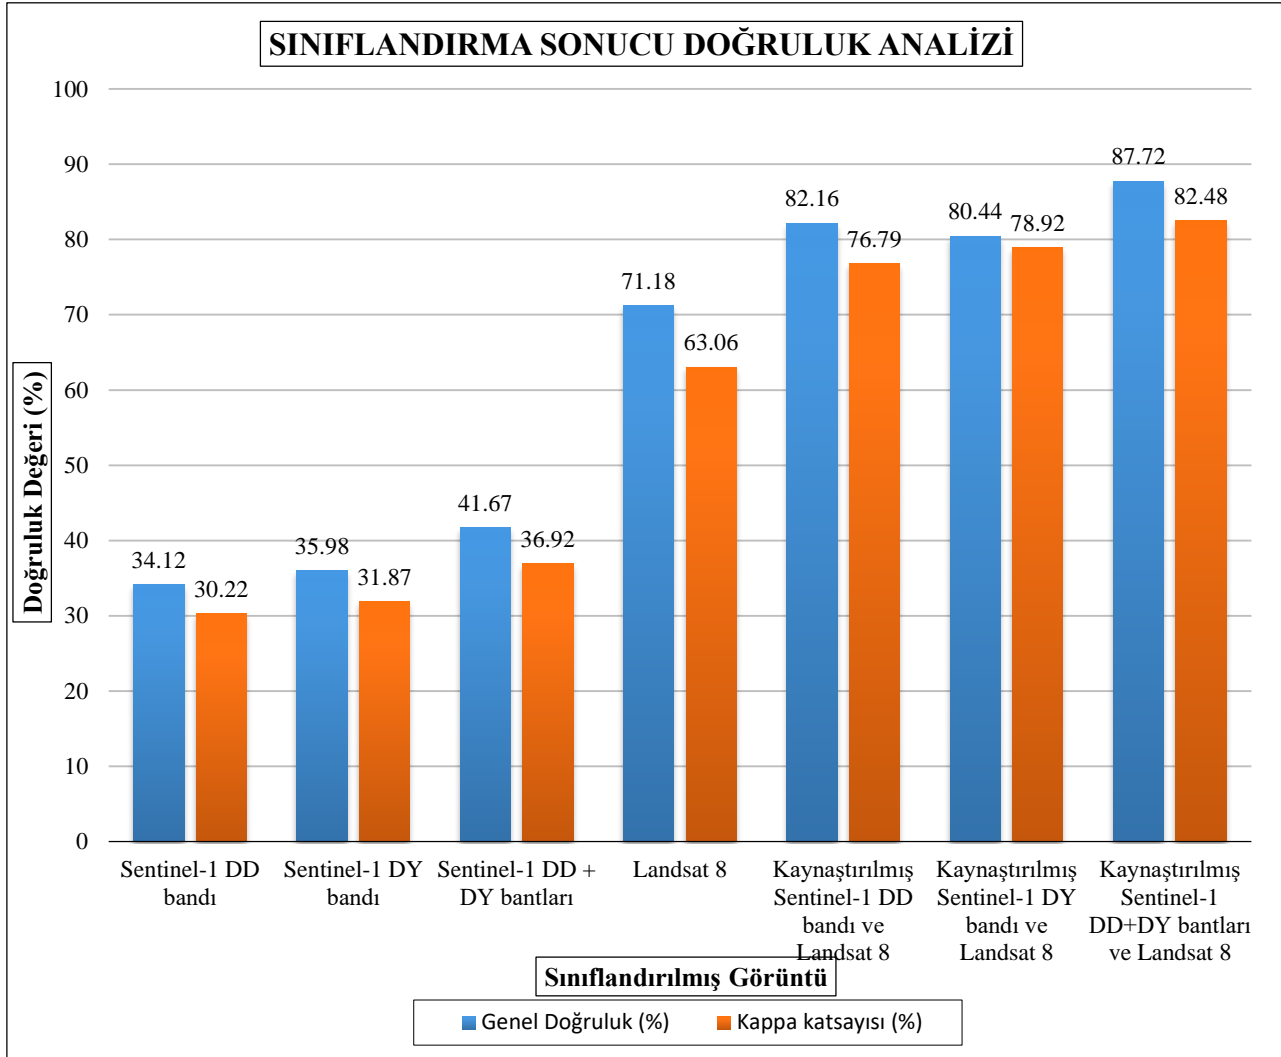
$$\text{Kullanıcı Doğruluğu} = \frac{n_{ii}}{n_{i+}} \quad (8)$$

Doğruluk analizlerinde kullanılan bir diğer ölçüt, Kappa katsayısıdır (Congalton, 1991; Campbell ve Wynne, 1996). Kappa katsayısı, hata matrisindeki genel doğrulukla olasılıklı doğruluk arasındaki farka dayanır. Sınıflar arası doğrulukları da içerdiğinden genel doğruluk ölçütünden daha iyi bir ölçüdür. Kappa katsayısının hesaplanmasında Eşitlik 9 kullanılmıştır.

$$\text{Kappa katsayısı} (\kappa) = \frac{N \sum_{i=1}^k x_{ij} - \sum_{i=1}^k (x_{i+} * x_{+j})}{N^2 - \sum_{i=1}^k (x_{i+} * x_{+j})} \quad (9)$$

Eşitlik 9 da, N tüm kategorilerdeki örnek sınıf toplamını, $\sum x_{ij}$ doğru sınıflandırılmış örnek sayısını, $\sum (x_{i+} * x_{+j})$ ise her kategorideki hata matrisinin satır ve sütun toplamını ifade etmektedir.


Hesaplanan doğruluk değerleri Tablo 4’de verilmiştir. Tablo 4’de 2–8. sütunlar sınıflandırmada kullanılan veri setlerini göstermektedir. Örneğin, 2. sütün, yalnız Sentinel-1 DD bandı kullanılarak yapılan sınıflandırma sonucu elde edilen doğruluk değerlerini göstermektedir. Genel doğruluk ve Kappa katsayısı değerlerinin grafiksel karşılaştırması Şekil 6’da gösterilmiştir. Sınıflandırma sonucu elde edilen tematik haritalar Şekil 7 (a-g)’de gösterilmiştir.




Şekil 6. Farklı veri setleri ile yapılan sınıflandırma sonucu elde edilen genel doğruluk ve kappa katsayısı değerlerinin grafiksel gösterimi

Tablo 4. Farklı veri setleri ile yapılan sınıflandırma sonucu hesaplanmış doğruluk değerleri (ÜD: üretici doğruluğu, KD: kullanıcı doğruluğu, genel doğruluk ve kappa katsayısı, DD: düşey düşey polarizasyon, DY: düşey yatay polarizasyon)


Tarımsal Ürün	Sentinel-1 DD bandı		Sentinel-1 DY bandı		Sentinel-1 DD + DY bantları		Landsat-8		Kaynaştırılmış Sentinel-1 DD bandı ve Landsat-8		Kaynaştırılmış Sentinel-1 DY bandı ve Landsat-8		Kaynaştırılmış Sentinel DD+DY bantları ve Landsat-8	
	ÜD (%)	KD (%)	ÜD (%)	KD (%)	ÜD (%)	KD (%)	ÜD (%)	KD (%)	ÜD (%)	KD (%)	ÜD (%)	KD (%)	ÜD (%)	KD (%)
Buğday	48,00	48,42	50,62	51,06	58,62	59,13	60,10	64,55	68,60	67,26	83,91	85,42	71,33	75,21
Domates	30,57	32,11	32,23	33,86	37,33	39,21	76,16	78,33	90,25	91,70	65,10	64,86	80,01	80,38
Mısır	36,76	42,59	38,76	44,91	44,89	52,01	66,28	72,73	88,29	87,28	80,88	77,68	72,24	74,27
Mısır_2	22,71	25,64	23,94	27,03	27,73	31,31	81,16	80,58	70,40	70,98	76,19	78,69	88,46	87,83
Pamuk	36,04	41,87	38,00	44,15	44,01	51,13	80,72	77,14	76,81	74,66	91,86	89,94	87,98	84,08
Üzüm	42,99	47,41	45,33	49,99	52,50	57,90	74,19	74,87	91,16	90,63	88,97	88,50	97,93	98,82
Yonca	41,51	39,79	43,78	41,96	50,70	48,60	76,12	77,76	74,14	70,35	85,40	82,33	94,38	96,42
Zeytin	25,52	29,65	26,91	31,27	31,17	36,21	71,63	73,90	77,58	75,58	58,09	62,67	94,55	97,54
Genel Doğruluk	34,12		35,98		41,67		71,18		82,16		80,44		87,72	
Kappa Katsayısı	30,22		31,87		36,92		63,06		76,79		78,92		82,48	




(a) Sentinel-1 DD bandı sınıflandırma sonucu




(b) Sentinel-1 DY bandı sınıflandırma sonucu




(c) Sentinel-1 DD+DY bantları sınıflandırma sonucu




(d) Landsat-8 sınıflandırma sonucu



(e) Kaynaştırılmış Landsat-8 ve Sentinel-1 DD veri seti sınıflandırma sonucu



(f) Kaynaştırılmış Landsat-8 ve Sentinel-1 DY veri seti sınıflandırma sonucu



(g) Kaynaştırılmış Landsat-8 ve Sentinel-1 DD+DY veri seti sınıflandırma sonucu

Şekil 7. Farklı veri setleri ile gerçekleştirilen sınıflandırma sonucu elde edilen tematik haritalar

Tablo 4'de verilen doğruluk değerlerine göre, Sentinel-1 DD bandı kullanılarak yapılan sınıflandırma genel doğruluk değeri %34,12 ve Kappa katsayısı değeri %30,22 olarak hesaplanmıştır. Buğday için ÜD ve KD değerleri sırasıyla %48,00 ve %48,42 olarak hesaplanmıştır. Benzer şekilde, bu değerler sırasıyla domates için %30,57 ve %32,11; mısır için %36,76 ve %42,59; mısır_2 için %22,71 ve %25,64; pamuk için %36,04 ve %41,87; üzüm için %42,99 ve %47,41; yonca için %41,51 ve %39,79; zeytin için %25,52 ve %29,65 olarak hesaplanmıştır. Mısır_2, en düşük ÜD ve KD değerlerine sahip ürün olurken, buğday en yüksek doğruluk değerlerini sağlayan ürün olmuştur.

Sentinel-1 DY bandı kullanılarak yapılan sınıflandırma genel doğruluk değeri %35,98 ve Kappa katsayısı değeri %31,87 olarak hesaplanmıştır. Buğday için ÜD ve KD değerleri sırasıyla %50,62 ve %51,06 olarak bulunmuştur. Benzer şekilde, bu değerler sırasıyla domates için %32,23 ve %33,86; mısır için %38,76 ve %44,91; mısır_2 için %23,94 ve %27,03; pamuk için %38,00 ve %44,15; üzüm için %45,33 ve %49,99; yonca için %43,78 ve %41,96; zeytin için %26,91 ve %31,27 olarak hesaplanmıştır. Bu veri seti ile yapılan sınıflandırmada da Mısır_2 en düşük ÜD ve KD değerlerine sahip ürün olurken, buğday en yüksek doğruluk değerlerini sağlayan ürün olmuştur.

Sentinel-1 DD ve DY bantları ayrı ayrı kullanılarak yapılan sınıflandırma sonucu hesaplanan ÜD, KD, genel doğruluk ve Kappa katsayısı değerleri genel olarak %50 ve altında kalmıştır. Bu durum sınıflandırmada kullanılan verinin tek bantlı ve pankromatik veri olması ve sınıflandırma doğruluğuna önemli derecede etki eden bant sayısı ve renk faktörünün düşük olmasından kaynaklanmaktadır. Hesaplanan doğruluk değerlerine dayanarak, sınıflandırmada yalnız Sentinel-1 DD veya DY bantlarından birisinin kullanılması halinde bu çalışma alanında ekilen ürünlerin güvenilir şekilde tespit edilemeyeceği değerlendirilmektedir.

Sentinel-1 DD ve DY bantları ile yapılan sınıflandırma sonuçları genel doğruluk değerleri karşılaştırıldığında, DY bandının DD bandına göre yaklaşık %1,86 daha iyi performans sağladığı görülmektedir. Benzer şekilde Kappa katsayısı değerleri karşılaştırıldığında, DY bandının DD bandına göre bir miktar daha iyi sonuç verdiği görülmüştür.

Sentinel-1 DD ve DY bantların sınıflandırmada birlikte kullanılmasıyla genel doğruluk değeri %41,67 ve Kappa katsayısı değeri %36,92 olarak hesaplanmıştır. Bu veri seti ile yapılan sınıflandırmada ürün bazında üretici ve kullanıcı doğruluk değerleri sırasıyla şu şekildedir: Buğday için %58,62 ve %59,13; domates için %37,33 ve %39,21; mısır için %44,89 ve %52,01; mısır_2 için %27,73 ve %31,31; pamuk için %44,01 ve %51,13; üzüm için %52,50 ve %57,90; yonca için %50,70 ve %48,60; zeytin için %31,17 ve %36,21.

Sentinel-1 DD ve DY bantların sınıflandırmada birlikte kullanılması, bu bantların tek kullanılmalarına göre yaklaşık %5 daha iyi sonuç üretmiştir. Bu bulgular, bu çalışmada sınıflandırmaya dâhil edilen bant sayısında artış olduğunda, sınıflandırma sonuçlarında da doğru orantılı olarak artış olduğu genellemesini doğrulamaktadır.

Sınıflandırmada Landsat-8 verisinin tek başına kullanılması ile %71,18 genel doğruluk ve %63,06 Kappa katsayısı değerlerine ulaşılmıştır. Ürün bazında doğruluklar değerlendirildiğinde, buğday için hesaplanan ÜD (%60,10) ve KD (%64,55) değerleri beklenenden düşük çıkmıştır. Diğer ürünler için hesaplanan ÜD ve KD değerleri şu şekildedir: Domates için %76,16 ve %78,33; mısır için %66,28 ve %72,73; mısır_2 için %81,16 ve %80,58; pamuk için %80,72 ve %77,14; üzüm için %74,19 ve %74,87; yonca için %76,12 ve %77,76 ve zeytin için %71,63 ve %73,90 olarak hesaplanmıştır. Sentinel-1 SAR verisine (DD, DY ve DD+DY) göre Landsat-8 genel doğrulukta %37 oranına kadar daha yüksek performans sağlamıştır. Kappa katsayısı için değerlendirildiğinde, Landsat-8 lehine doğruluk artışı %33 mertebesinde. Ürün bazında ÜD ve KD değerleri de Sentinel-1 SAR verisi ile sınıflandırmaya göre yaklaşık %30 civarında daha yüksektir. Landsat-8 optik bantları konumsal çözünürlüğü 30 m, Sentinel-1 DD ve/veya DY bantların konumsal çözünürlüğü 10 m olmasına rağmen, Landsat-8 ile yapılan sınıflandırma doğruluğu, Sentinel-1 ile yapılan sınıflandırma doğruluğuna göre önemli oranda daha yüksek çıkmıştır. Bulgular değerlendirildiğinde, en azından bu çalışma alanındaki ürün türlerinin tespitinde, daha yüksek konumsal çözünürlüklü Sentinel-1 SAR verisi yerine daha düşük konumsal çözünürlüklü çok bantlı Landsat-8 optik veri tercih edilmelidir. Ayrıca, piksel veya nesnelerin (bu çalışma için tarımsal parseller) renk etkisinin, piksellerin yeryüzünde kapladığı büyüklük (konumsal çözünürlük) faktörüne göre daha önemli bir parametre olduğunu elde edilen bulgular göstermiştir (Tablo 4).

Kaynaştırılmış Sentinel-1 DD bandı ve Landsat-8 veri seti ile yapılan sınıflandırma neticesinde genel doğruluk değeri %82,16 ve Kappa katsayısı değeri %76,79 olarak hesaplanmıştır. Ürün bazında hesaplanan ÜD ve KD değerleri sırasıyla şu şekildedir: Buğday için %68,60 ve %67,26; domates için %90,25 ve %91,70; mısır için %88,29 ve %87,28; mısır_2 için %70,40 ve %70,98; pamuk için %76,81 ve %74,66; üzüm için %91,16 ve %90,63; yonca için %74,14 ve %70,35 ve zeytin için %77,58 ve %75,58. Yalnız Landsat-8 verisi veya yalnız Sentinel-1 DD bandı ile yapılan sınıflandırma sonucuna göre kaynaştırılmış Sentinel-1 DD bandı ve Landsat-8 veri seti ile yapılan sınıflandırmada önemli oranda performans artışı olmuştur (Tablo 4 ve Şekil 6).

Kaynaştırılmış Sentinel-1 DY bandı ve Landsat-8 veri seti ile yapılan sınıflandırmanın genel doğruluk değeri %80,44 ve Kappa katsayısı değeri %78,92 olarak hesaplanmıştır. Ürünler için hesaplanan ÜD ve KD değerleri sırasıyla şu şekildedir: Buğday için %83,91 ve %85,42; domates için %65,10 ve %64,86; mısır için %80,88 ve %77,68; mısır_2 için %76,19 ve %78,69; pamuk için %91,86 ve %89,94; üzüm için %88,97 ve %88,50; yonca için %85,40 ve %82,33 ve zeytin için %58,09 ve %62,67.

Kaynaştırılmış Sentinel-1 DY bandı ve Landsat-8 veri seti ile sınıflandırma, yalnız Landsat-8 verisi ya da yalnız Sentinel-1 verisi ile sınıflandırmaya göre belirgin oranda daha yüksek performans sağlamıştır (Tablo 4 ve Şekil 6).

Kaynaştırılmış Sentinel-1 DD ve DY bantları ile Landsat-8 veri seti kullanılarak yapılan sınıflandırmada genel doğruluk değeri %87,72 ve Kappa katsayısı değeri %82,48 olarak hesaplanmıştır. Buna göre, değerlendiriciler arasındaki uyum ele alındığında, $\kappa < 0$ hiç uyum olmadığını, $0 \leq \kappa \leq 0.20$ çok düşük bir uyum olduğunu, $0.21 \leq \kappa \leq 0.40$ düşük bir uyum olduğunu, $0.61 \leq \kappa \leq 0.80$ yüksek bir uyum olduğunu ve $0.81 \leq \kappa \leq 1.00$ hemen hemen mükemmel bir uyum olduğunu göstermektedir. Bununla birlikte, 0.70'den daha büyük bir Kappa katsayısı için değerlendiriciler arasındaki uyumun yeterli olduğu da söylenebilir (Cohen, 1960). Cohen, (1960)'a göre bu değerler oldukça başarılı sonuçlar olarak kabul görmektedir. Bu veri seti ile elde edilen genel doğruluk ve Kappa katsayısı değerleri bu çalışmada elde edilen en başarılı sonuçlardır. Ürün bazında hesaplanan ÜD ve KD değerleri sırasıyla şu şekildedir: Buğday için %71,33 ve %75,21; domates için %80,01 ve %80,38; mısır için %72,24 ve %74,27; mısır_2 için %88,46 ve %87,83; pamuk için %87,98 ve %84,08; üzüm için %97,93 ve %98,82; yonca için %94,38 ve %96,42 ve zeytin için %94,55 ve %97,54.

ÜD ve KD değerleri değerlendirildiğinde (Tablo 4), tüm ürünler için en yüksek ÜD ve KD değerlerinin kaynaştırılmış Sentinel-1 DD+DY bantları ve Landsat-8 veri seti ile yapılan sınıflandırmadan elde edilmediği görülmüştür. Örneğin, buğdaya ait en yüksek ÜD ve KD değerleri (%83,91 ve %85,42) kaynaştırılmış Sentinel-1 DY bandı ve Landsat-8 veri seti ile yapılan sınıflandırmayla elde edilmiştir. Pamuk için de hesaplanan en yüksek ÜD ve KD değerlerini (%91,86 ve %89,94) kaynaştırılmış Sentinel-1 DY bandı ve Landsat-8 veri seti sağlamıştır. Diğer taraftan, domates ve mısır için en yüksek ÜD ve KD değerlerini kaynaştırılmış Sentinel-1 DD bandı ve Landsat-8 veri seti sağlamıştır. Çalışmada sınıflandırılan ürünlerin yarısı için (Mısır_2, Üzüm, Yonca ve Zeytin) en yüksek ÜD ve KD değerleri kaynaştırılmış Sentinel-1 DD+DY bantları ve Landsat-8 veri seti ile yapılan sınıflandırmada elde edilmiştir (Tablo 4).

Bu çalışmada elde edilen sonuçlar neticesinde yapılan sınıflandırma işlemi değerlendirildiğinde, çok bantlı görüntünün spektral çözünürlük artışına göre daha az olmakla birlikte, konumsal çözünürlük artışının sınıflandırma sonucu elde edilen doğruluk sonuçlarına pozitif yönde katkı sağladığı yorumlanmaktadır. Çünkü kaynaştırılmış Sentinel-1 DD ve DY bantları ve Landsat-8 veri setinin çoklu bantlı olmasının yanı sıra 10 m konumsal çözünürlüğe sahip olmasının sınıflandırma sonuçlarına olumlu etkisi olmuştur. Yalnız 30 m konumsal çözünürlüklü Landsat 8 verisi ile yapılan sınıflandırma sonucu veya yalnız 10 m çözünürlüklü pankromatik SAR DD ve/veya DY bantları ile yapılan sınıflandırma sonucu bu bulgunun doğruluğunu göstermektedir.

5. Sonuçlar

Bu çalışmada, kaynaştırılmış tek tarihe ait Sentinel-1 SAR ve Landsat-8 verilerinin, tarımsal yaz ürünlerinin (buğday, domates, mısır, pamuk, üzüm, yonca ve zeytin) tespitine yönelik olarak, RO makine öğrenme algoritması ile sınıflandırma performansına olan etkisi araştırılmıştır. Elde edilen sonuçlara göre, orijinal Sentinel-1 DD veya DY polarizasyonlu bantlar ile yapılan sınıflandırma işleminde genel doğruluk değeri en yüksek %35.98 olurken, orijinal Sentinel-1 DD ve DY bantların her ikisinin de kullanılması genel doğruluk değerini ancak %41.67'ye kadar yükseltmiştir. Dolayısıyla, tek tarihli orijinal Sentinel-1 SAR DD ve/veya DY verisi, en azından bu çalışma alanında, tarımsal yaz ürünleri tespiti için yeterli değildir. Sınıflandırmada tek tarihli orijinal Landsat-8 verisi 30 m çözünürlüklü bantlar (Kıyı Aerosol, Mavi, Yeşil, Kırmızı, Yakın Kızılötesi, Kısa Dalga Kızılötesi 1 ve Kısa Dalga Kızılötesi 2 - Tablo 1) kullanıldığında, %71.18 genel doğruluk değerine ulaşılmıştır. Cohen (1960)'a göre bu oran makul sonuç olarak kabul görmektedir. Sentinel-1 SAR verisine göre yaklaşık iki kat daha iyi performans gösteren Landsat-8 verisi tek tarihli görüntü sınıflandırma işleminde çok bantlı optik görüntü kullanımının önemini göstermiştir.

Landsat-8 ile kaynaştırılmış Sentinel-1 DD ve DY verileri yığını ile yapılan sınıflandırmanın genel doğruluğu %87.72 ve Kappa katsayısı %82.48 olarak hesaplanmıştır. Bu değerler bu çalışmada kullanılan süreç ve tekniğin başarılı olduğunu göstermektedir. Bu sonuç, farklı girdi verilerin diğer kombinasyonları ile karşılaştırıldığında, bu çalışma için en yüksek sınıflandırma doğruluğu olarak elde edilmiştir. Orijinal pankromatik Sentinel-1 SAR verisi tek başına kullanıldığında düşük doğruluk verdiği, ancak optik bir görüntü ile birleştirilip birlikte kullanıldığında oldukça tatmin edici sonuçlar verdiği tespit edilmiştir.

Bu çalışmada SAR ve optik verileri bir arada daha etkin kullanabilmek için, SAR görüntülerine yeniden ölçeklendirme (rescale) işlemi uygulanmıştır. Yeniden ölçeklendirme işlemindeki amaç, SAR görüntüsü ile çok bantlı optik veri setini aynı radyometrik aralığa getirmek ve sonrasında aynı radyometrik aralıktaki pankromatik ve çok bantlı veri setini kaynaştırarak sınıflandırma işlemi yapmaktır. Yeniden ölçeklendirme işleminin görüntü kaynaştırma işlemine olumlu katkı sağladığı ve sınıflandırma doğruluğunu artırdığı değerlendirilmektedir.

Görüntü kaynaştırma işleminin başarısını ölçmek amacıyla ERGAS ve RMSE kalite ölçütleri ile metrik kalite değerleri hesaplanmıştır. Hem elde edilen metrik değerler (Tablo 3) hem de görsel analizler, görüntü kaynaştırma işlemi sonrasında konumsal detay kalitesinin arttığını ve çok bantlı görüntünün renk içeriğinin korunduğunu göstermektedir.

Ücretsiz temin edilebilen Sentinel-1 SAR ve Landsat-8 optik görüntülerin sahip oldukları sırasıyla yüksek konumsal çözünürlük ve çok bantlı özellik etkilerini bir arada kullanıma sunması ve belirli büyüklükteki tarım parsellerinin bulunduğu bölgelerdeki tarımsal uygulamalar için yeterli olması, bu verileri tarımsal ürün tespiti için çok değerli hale getirmiştir. Referans verileri elde etmek için araziye gidilip gerekli bilgiler toplanmalı veya araziden toplanan bilginin yerine geçebilecek tarım parselleri bilgisine (örn., parsel sınırları, ekili ürün isimleri vd.) ihtiyaç duyulmaktadır. Bu çalışmada elde edilen bulgular, ÇKS verilerinin sınıflandırmada arazi gerçeği verileri olarak kullanılabilmesi için mutlak suretle birtakım düzenleme işlemlerinden ve analizlerden geçirilmesi gerektiğini göstermiştir.

Bu çalışmada referans veri olarak kullanılan ÇKS verileri çiftçilerin sözlü beyanlarına göre hazırlanmaktadır. Elde edilen sonuçlar değerlendirildiğinde, bazı öznitelik bilgileri (örn., ekili alan yüzölçümü, ekili ürün adı, toplam parsel alanı ile ekili alan arasındaki fark, vb.) eksik veya hatalı olan ÇKS parsellerin önerilen yöntemle otomatik olarak tespit edilebileceği ve olası hataların giderilebileceği sonucuna varılmıştır.

Teşekkür

Bu çalışmada kullanılan ÇKS verilerinin temin edildiği T.C. Tarım ve Orman Bakanlığı'na çok teşekkür ederiz.

Kaynaklar

- Adrian, J., Vasit Sagan, V., & Maimaitijiang, M. (2021). Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175(2021), 215-235. doi: 10.1016/j.isprsjprs.2021.02.018.
- Akar, Ö. (2013). *Rastgele orman sınıflandırıcısına doku özellikleri entegre edilerek benzer spektral özellikteki tarımsal ürünlerin sınıflandırılması (Doktora tezi)*, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Türkiye.
- Alparone, L., Alazzi, B., Baronti, S., Garzelli, A., Nencini, F. & Selva, M. (2008). Multispectral and panchromatic data fusion assessment without reference. *Photogrammetric Engineering and Remote Sensing*, 74(2), 193-200.
- Alparone, L., Baronti, S., Garzelli, A., & Nencini, F. (2004). A global quality measurement of pan-sharpened multispectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 1(4), 313-317. doi: 10.1109/LGRS.2004.836784.
- ArcGIS User Guide. (2021, Nisan 22). *ArcGIS Desktop User Guide Documentation*, Retrieved from <https://desktop.arcgis.com/en/documentation/>
- Archer, K. J., & Kimes, R. V. (2008). Empirical characterization of random forest variable importance measure. *Computational Statistics & Data Analysis*, 52(4), 2249-2260. doi: 10.1016/j.csda.2007.08.015.
- Breiman, L. (2001). Random forests, *Machine Learning*, 45(1), 5-32.
- Breiman, L. (2003). Manual setting up, using, and understanding random forests. *RColorBrewer MASS*, 4(0), 1-33.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone C. J., (1984). *Classification and Regression Trees*. Boca Raton, Chapman & Hall/CRC Press.
- Brisco, B., & Brown, R. J. (1995). Multidate SAR/TM synergism for crop classification in Western Canada. *Photogrammetric Engineering & Remote Sensing*, 61(8), 1009-1014.
- Bush, T. F., & Ulaby, F. T. (1978). An evaluation of radar as a crop classifier. *Remote Sensing of Environment*, 7(1), 15-36.
- Campbell, J.B., Wynne, R.H. (1996). *Introduction to Remote Sensing*. New York, London, Guilford Press.
- Cao, J., Cai, X., Tan, J., Cui, Y., Xie, H., Liu, F., Yang, L., & Luo, Y. (2020). Mapping paddy rice using Landsat time series data in the Ganfu Plain irrigation system, Southern China, from 1988-2017. *International Journal of Remote Sensing*, 42(4), 1556-1576. doi: 10.1080/01431161.2020.1841321.
- Chen, S., Useya, J., & Hillary Mugiyu, H. (2020). Decision-level fusion of Sentinel-1 SAR and Landsat 8 OLI texture features for crop discrimination and classification: case of Masvingo, Zimbabwe. *Heliyon*, 6(11), 1-14.
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37-46.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46.
- Congalton, R. G., Green, K. (2008). *Assessing the accuracy of remotely sensed data: Principles and practices*. Boca Raton, CRC Press.
- Copernicus. (2021, Mart 30). *Copernicus Open Access Hub*. Retrieved from <https://scihub.copernicus.eu/dhus/#/home>
- Csillik, O., & Belgiu, M. (2017, May). Cropland mapping from Sentinel-2 time series data using object-based image analysis. In *Proceedings of the 20th AGILE International Conference on Geographic Information Science Societal Geo-Innovation Celebrating, Wageningen, The Netherlands* (pp. 9-12).
- Dammavalam, S. R., Maddala, S., & Mhm, K. P. (2012). Quality assessment of pixel-level image fusion using fuzzy logic. *International Journal on Soft Computing*, 3(1), 11-23. doi:10.5121/ijsc.2012.3102.

- Dimov, D., Kuhn, J., & Conrad, C. (2016, July). Assessment of cropping system diversity in the fergana valley through image fusion of Landsat 8 and Sentinel-1. In *23rd ISPRS Congress*, 2016. (pp.173-180). XXIII ISPRS.
- EarthExplorer. (2021, Mart 30). *USGS Earth Explorer*. Retrieved from <https://earthexplorer.usgs.gov>
- Erdas Imagine User Guide. (2021, Nisan 22). *Hexagon Erdas Imagine User Guide*, Retrieved from <https://www.hexagongeospatial.com/>
- ESA Copernicus Open Access Hub. (2021, Mart 30). *Overview, Sentinel-1 Data Offer*, Retrieved from <https://scihub.copernicus.eu/userguide/>
- Filippini, F. (2019). Sentinel-1 GRD preprocessing workflow. *Multidisciplinary Digital Publishing Institute Proceedings*, 18(1), 11-15. doi:10.3390/ECRS-3-06201.
- Foody, G. M., M. B. McCulloch, M. B., & W. B. Yates, W.B. (1994). Crop classification from C-band polarimetric radar data. *International Journal of Remote Sensing*, 15(14), 2871-2885. doi: 10.1080/01431169408954289.
- Forget, Y., Shimoni, M., Gilbert, M., & Linard, C. (2018). Complementarity between Sentinel-1 and Landsat 8 imagery for built-up mapping in Sub-Saharan Africa. *Preprints*, doi: 10.20944/preprints201810.0695.v1.
- Gumma, M. K., Nelson, A., Thenkabail, P. S., & Singh, A. N. (2011). Mapping rice areas of South Asia using MODIS multitemporal data. *Journal of Applied Remote Sensing*, 5(1), 1-26. doi: 10.1117/1.3619838.
- Gungor, O. (2008). *Multi sensor multi resolution image fusion (Doctoral dissertation)*, Purdue University, USA.
- Horning, N. (2010, December). Random forests: An algorithm for image classification and generation of continuous fields data sets. In *International Conference on Geoinformatics for Spatial Infrastructure Development in Earth and Allied Sciences*, 2010. Proceedings. GIS-IDEAS.
- Hütt, C., Koppe, W., Miao, Y., & Bareth, G. (2016). Best accuracy land use/land cover (LULC) classification to derive crop types using multitemporal, multisensor, and multi-polarization SAR satellite images. *Remote Sensing*, 8(8), 684-698. doi:10.3390/rs8080684.
- Klonus, S., & Ehlers, M. (2009, July). Performance of evaluation methods in image fusion. In *2009 12th International Conference on Information Fusion* (pp. 1409-1416). IEEE.
- Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017, May). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782. doi: 10.1109/LGRS.2017.2681128.
- Lee, J.S., Jurkevich, I., Dewaele, P., Wambacq, P., & Oosterlinck, A. (1994). Speckle filtering of synthetic aperture radar images: A review. *Remote Sensing Reviews*, 8(4), 313-340. doi: 10.1080/02757259409532206.
- Lemoine, G., & Leo, O. (2015, November). Crop mapping applications at scale: Using google earth engine to enable global crop area and status monitoring using free and open data sources. In *International Geoscience and Remote Sensing Symposium, (IGARSS)* (pp. 1496-1499). IEEE. doi: 10.1109/IGARSS.2015.7326063.
- Liaw, A., & Wiener, M. (2002). Classification and regression by random forest. *R News*, 2(3), 18-22.
- Liu, M.W., Ozdogan, M., & Zhu, X. (2014). Crop type classification by simultaneous use of satellite images of different resolutions. *IEEE Transactions on Geoscience and Remote Sensing*, 52(6), 3637-3649. doi: 10.1109/TGRS.2013.2274431.
- Lussem, U., Hütt, C., & Waldhoff, G. (2016, July). Combined analysis of Sentinel-1 and Rapid Eye data for improved crop type classification: An early season approach for rapeseed and cereals. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41(2016), 959-963. doi:10.5194/isprsarchives-XLI-B8-959-2016.
- Mather, P., & Tso, B. (2009). *Classification methods for remotely sensed data*. BW: CRC Press.
- MathWorks. (2021, Mayıs 8). *MathWorks Makers of MATLAB and Simulink*. Retrieved from <https://www.mathworks.com/>
- McNairn H., & Shang J. (2016). A Review of multitemporal synthetic aperture radar (SAR) for crop monitoring. In Ban, Y. (Eds.) *Multitemporal remote sensing. Remote sensing and digital image processing* (Vol. 20, pp. 217-340). Canada, Ottawa, ON: Springer Press.
- McNairn, H., & Shang, J. (2016). A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. *Multitemporal remote sensing*, 317-340.
- McNairn, H., & Shang, J. (2016). A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. *Multitemporal remote sensing*, 20(2016), 317-340.
- Nasirzadehdzaji, R., Sanli, F. B., Cakir, Z., & Sertel, E. (2019, July). Crop mapping improvement by combination of optical and SAR datasets. In *2019 8th International Conference on Agro Geoinformatics*, (pp. 1-6). IEEE. doi: 10.1109/Agro-Geoinformatics.2019.8820604.
- Nuthammachot, N., & Stratoulas, D. (2019). Fusion of Sentinel-1A and Landsat-8 images for improving land use/land cover classification in Songkla Province, Thailand. *Applied Ecology and Environmental Research*, 17(2), 3123-3135. doi: 10.15666/aeer/1702_31233135.

- Otukei, J. R., Blaschke, T., & Collins, M. (2015). Fusion of TerraSAR-x and Landsat ETM+ data for protected area mapping in Uganda. *International Journal of Applied Earth Observation and Geoinformation*, 38(2015), 99-104. doi: 10.1016/j.jag.2014.12.012.
- Ozdarici A. & Turker, M. (2006, July). Field-based classification of agricultural crops using multi-scale images, *Proceedings of the 1st International Conference on Object-based Image Analysis*, 2006. (pp. 1-7). OBIA'06.
- Pal, M. (2005a, February). Multiclass approaches for support vector machine based land cover classification, *In Proceedings of Map India, 8th Annual International Conference and Exhibition in the Field of GIS, GPS, Aerial Photography and Remote Sensing*, 2005.
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222. doi: 10.1080/01431160412331269698.
- Pal, M., & Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, 86(4), 554-565. doi:10.1016/S0034-4257(03)00132-9.
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67(2012), 93-104. doi:10.1016/j.isprsjprs.2011.11.002.
- Schowengerdt, R. A. (2007). *Remote sensing: Models and methods for image processing*. AP: Elsevier Press.
- Siachalou, S., Mallinis, G., & Tsakiri-Strati, M. (2015). A hidden markov models approach for crop classification: Linking crop phenology to time series of multisensor remote sensing data. *Remote Sensing*, 7(4), 3633-3650. doi:10.3390/rs70403633.
- Skriver, H. (2012). Crop classification by multitemporal C- and L-band single- and dual polarization and fully polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 50(6), 2138-2149. doi: 10.1109/TGRS.2011.2172994.
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N., & Shimamura, H. (2014). Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data. *Remote Sensing Letters*, 5(2), 157-164. doi: 10.1080/2150704X.2014.889863.
- Suwarsono, N., Prasasti, I., Nugroho, J. T., Sitorus, J., & Triyono, D. (2018). Detecting the lava flow deposits from 2018 anak Krakatau eruption using data fusion Landsat-8 optic and Sentinel-1 SAR. *International Journal of Remote Sensing and Earth Sciences*, 15(2), 157-166. doi: 10.30536/j.ijreses.2018.v15.a3078.
- T.C. Tarım ve Orman Bakanlığı. (2021, Mart 30). *T.C. Tarım ve Orman Bakanlığı Anasayfası*, Retrieved from <https://www.tarimorman.gov.tr/>
- Thenkabail, P. S., Hanjra, M. A., Dheeravath, V., & Gumma, M. (2010). A holistic view of global croplands and their water use for ensuring global food security in the 21st century through advanced remote sensing and non-remote sensing approaches. *Remote Sensing*, 2(1), 211-261. doi: 10.3390/rs2010211.
- Thenkabail, P. S., Hanjra, M. A., Dheeravath, V., & Gumma, M. (2011). Global croplands and their water use remote sensing and non-remote sensing perspectives. Weng Q (Ed.), *Advances in Environmental Remote Sensing: Sensors, Algorithms, and Applications*, (pp. 383-419). Florida, CRC Press.
- Turker M., & Arikan, M. (2005). Sequential masking classification of multi-temporal Landsat7 ETM+ images for field-based crop mapping in Karacabey, Turkey. *International Journal of Remote Sensing*, 26(17), 3813-3830. doi: 10.1080/01431160500166391.
- Utgoff, P. E., & Brodley, C. E. (1990). An incremental method for finding multivariate splits for decision trees. In *Machine Learning Proceedings 1990*, (pp. 58-65), Morgan Kaufmann.
- Van Niel, T. G., & McVicar, T. R. (2004). Determining temporal windows for crop discrimination with remote sensing: A case study in south-eastern Australia. *Computers and Electronics in Agriculture*, 45(1-3), 91-108. doi:10.1016/j.compag.2004.06.003.
- Viskovic, L., Kosovic, I. N., & Mastelic, T. (2019, September). Crop classification using multi-spectral and multitemporal satellite imagery with machine learning. In *2019 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)* (pp. 1-5). IEEE. doi: 10.23919/SOFTCOM.2019.8903738
- Witharana, C., Civco, D. L., & Meyer, T. H. (2013). Evaluation of pansharpening algorithms in support of earth observation based rapid-mapping workflows. *Applied Geography*, 37(2013), 63-87. doi: 10.1016/j.apgeog.2012.10.008.
- Yılmaz, V., & Güngör, O. (2013, Mayıs). Görüntü kaynaştırma yöntemlerinde performans analizi. *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu*, 2013. TUFUAB'2013.
- Zhan, X., Sohlberg, R., Townshend, J., Dimiceli, C., Carroll, M., Eastman, J., Hansen, M. C., & DeFries, R. S. (2002). Detection of land cover changes using MODIS 250 m data. *Remote Sensing of Environment*, 83(1-2), 336-350. doi: 10.1016/S0034-4257(02)00081-0.
- Zhang, H., & Xu, R. (2018). Exploring the optimal integration levels between SAR and optical data for better urban land cover mapping in the Pearl River Delta. *International Journal of Applied Earth Observation and Geoinformation*, 64(2018), 87-95. doi: 10.1016/j.jag.2017.08.013.