

## Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması

Mustafa Üstüner<sup>1\*</sup> , Füsün Balık Şanlı<sup>1</sup> 

<sup>1</sup>Yıldız Teknik Üniversitesi, Davutpaşa Kampüsü, İnşaat Fakültesi, Harita Mühendisliği Bölümü, Esenler, İstanbul, Türkiye.

**Öz:** Bu çalışma, çok zamanlı Polarimetrik SAR (Polarimetrik Sentetik Açıklıklı Radar, PolSAR) görüntülerinin tarımsal ürünlerin sınıflandırılmasındaki kullanımını araştırmaktadır. Çok zamanlı PolSAR görüntüleri, özellikle zamansal izlemenin önemli olduğu tarım projelerinde önemli avantajlar sağlamaktadır. Bu çalışma kapsamında, beş farklı ürünün (mısır, patates, buğday, ayçiçeği ve yem bitkisi) sınıflandırılması amacıyla üç farklı makine öğrenme algoritması (hafif gradyan hızlandırma makineleri (Light Gradient Boosting Machines, LightGBM), rastgele orman (RO) ve destek vektör makineleri (DVM)) kullanılmıştır. PolSAR verisi olarak, çok zamanlı Radarsat-2 SAR görüntülerine ait doğrusal geri saçılım değerlerini içeren orijinal bantlar kullanılmıştır. Sınıflandırmalara ilişkin genel doğruluk değerleri LightGBM, RO ve DVM algoritmaları için sırasıyla 0.857 ( $\pm 0.026$ ), 0.855 ( $\pm 0.033$ ) ve 0.834 ( $\pm 0.039$ ) olarak elde edilmiştir. McNemar testi sonuçlarına göre, en yüksek iki sınıflandırma doğruluğu arasındaki farkın istatistiksel olarak anlamlı olmadığı görülmüştür. Sınıflandırma sonuçlarının değerlendirilmesi aşamasında k-katlamalı çapraz doğrulama yöntemi kullanılmıştır. Ayrıca bu sonuçlar, çok zamanlı PolSAR verilerinin tarımsal ürünlerin sınıflandırılmasında etkin bir şekilde kullanılabileceğini göstermiştir.

**Anahtar Sözcükler:** Polarimetrik SAR, Sınıflandırma, Uzaktan algılama, Tarım

### Crop classification using multi-temporal polarimetric SAR data

**Abstract:** This study evaluates the use of multi-temporal Polarimetric SAR (Polarimetric Synthetic Aperture Radar, PolSAR) images for crop classification. Multi-temporal polarimetric SAR images could be very advantageous for crop classification especially in time-critical agricultural projects. Within this research, three types of machine learning algorithms (light gradient boosting machines (LightGBM), random forest (RF) and support vector machines (SVM)) were utilized for the classification of five crops (maize, potato, wheat, sunflower, and alfalfa). From the multi-temporal PolSAR data, the original features (i.e. linear backscatter coefficients) of Radarsat-2 were extracted and incorporated into the classification step. The overall classification accuracies were obtained as 0.857 ( $\pm 0.026$ ), 0.855 ( $\pm 0.033$ ) and 0.834 ( $\pm 0.039$ ) for LightGBM, RF and SVM, respectively. The difference between the accuracies obtained by LightGBM and random forest (RF) was found to be statistically non-significant based upon the McNemar's test. K-fold cross validation was used to assess the classification results. Furthermore, these results showed the added benefits of multi-temporal PolSAR data for crop classification.

**Keywords:** Polarimetric SAR, Classification, Remote sensing, Agriculture

\* Sorumlu Yazar/Corresponding Author: Tel: +90 212 383 5326

Geliş Tarihi/Received: 21.09.2019  
Kabul Tarihi/Accepted: 04.12.2019



0000-0003-0553-2682, mustuner@yildiz.edu.tr (Üstüner M.)\*  
0000-0003-1243-8299, fbalik@yildiz.edu.tr (Balık Şanlı F.)

## 1. Giriş

Bölgesel ve küresel ölçekte tarım alanlarının sistematik ve doğru bir şekilde izlenmesi, birçok tarım uygulaması için önem arz etmektedir. Tarımsal ürünlerin zamana bağlı dinamik olarak değişen yapılarından dolayı, ürün deseni tespiti ve rekolte (yıllık ürün) tahmini gibi uygulamalarda çok zamanlı uydu görüntülerine ihtiyaç duyulmaktadır (McNairn & Shang, 2016; Larrañaga & Álvarez-Mozos, 2016). Zamansal izlemenin kritik öneme sahip olduğu tarım projelerinde optik görüntüleri nazaran, iklim koşullarından bağımsız görüntü elde edilebilme avantajı nedeniyle SAR (Sentetik Açıklıklı Radar) görüntüleri sıklıkla tercih edilmektedir. Tarımsal ürünler farklı büyüme evrelerinde farklı geri saçılım değerlerine sahip olduğundan, ürün türlerinin doğru sınıflandırılmasında çok zamanlı ve çok polarizasyonlu verilere ihtiyaç olduğu çoğu bilimsel çalışmada açıkça ispatlanmıştır (McNairn & Brisco, 2004; Jiao vd., 2014; Huang, Wang, Shang, Liao & Liu, 2017).

Hedef ürün türüne ilişkin geri saçılım değeri, kullanılan SAR algılayıcısının özellikleri ve hedef objenin geometrik/fiziksel yapısı arasındaki ilişkiye bağlıdır. Tam polarimetrik (full polarimetric) SAR verileri (PolSAR), tekli ya da ikili polarizasyona sahip SAR verilerine kıyasla hedef objenin karmaşık yapısı hakkında daha detaylı bir bilgi sağlamaktadır. PolSAR görüntüleri, arazi örtüsü ve kullanımı tespitinden deniz buzularının tespit edilmesine, kentsel alanların sınıflandırılmasından ormanlık ve tarım alanlarının sınıflandırılmasına kadar geniş bir kullanım alanına sahiptir. Niu ve Ban (2013) kentsel arazi örtüsü sınıflandırılması amacıyla çok zamanlı Radarsat-2 verilerinden faydalanmışlardır. Maghsoudi, Collins, ve Leckie (2013) çalışmalarında, destek vektör makinaları (DVM) sınıflandırma algoritması ve Radarsat-2 verilerinden faydalanarak kutupaltı ormanlık alanların sınıflandırılması işlemini gerçekleştirmişlerdir. Çalışmalarında çok zamanlı TerraSAR-X SAR görüntülerinden faydalanan Ressel, Singha, Lehner, Rösel ve Spreen (2016) ise deniz buzu sınıflandırılması amacıyla SAR görüntülerinden üretilen polarimetrik özellikleri kullanmışlardır. Gui, Xu, Wang, Yang ve Pu (2018) ise çalışmalarında, PolSAR verilerinden ve genelleştirilmiş sıfır-atış öğrenmesi (generalized zero-shot learning) tekniğinden faydalanmışlardır.

Radar sinyali, tarımsal ürünlerin geometrik yapısı ve biyofiziksel parametrelerine karşı duyarlıdır ve bu özelliği nedeniyle de ürün deseni tespiti ve izlenmesi vb. çalışmalarda önemli katkılar sağlamaktadır (Lee & Pottier, 2009; Schmillius, Thiel, Pathe & Santoro, 2015; Tamiminia, Homayouni, McNairn & Safari, 2017). Çok zamanlı tam PolSAR verileri (Radarsat-2, UAVSAR, ALOS-2/PALSAR-2) tarımsal ürünlerin sınıflandırılmasında sıklıkla tercih edilmektedir. Ma, Wang, Shang ve Wang (2013) yaptıkları çalışmada, tarımsal ürünlerin sınıflandırılması işleminde çok zamanlı Radarsat-2 PolSAR uydu görüntülerinden faydalanmış ve en çok benzerlik sınıflandırma yöntemini kullanmışlardır. Liu, Shang, Vachon, ve McNairn (2013), test alanı Kanada'nın Ontario eyaletinde yer alan çalışmalarında, çok zamanlı Radarsat-2 PolSAR görüntülerinden üretilmiş Pauli polarimetrik ayrıştırma (polarimetric decomposition) tekniğine dayalı polarimetrik özellikleri (features) kullanmışlardır. Jiao vd. (2014) ise tarımsal ürün sınıflandırılması işleminde, çok zamanlı Radarsat-2 görüntülerinden üretilmiş Cloude-Pottier ve Freeman-Durden polarimetrik ayrıştırma tekniklerine ait polarimetrik özelliklerden faydalanmışlardır. Çalışmaları kapsamında obje tabanlı sınıflandırma yöntemini kullanmışlardır. Larrañaga ve Álvarez-Mozos (2016) ise tarımsal ürünlerin sınıflandırılması amacıyla çok zamanlı Radarsat-2 görüntülerinden ve polarimetrik ayrıştırma tekniklerinden elde edilmiş polarimetrik özelliklerden faydalanmışlardır. Çalışmaları kapsamında obje tabanlı rastgele orman (RO) algoritması kullanılmıştır. Valcarce-Diñeiro, Arias-Pérez, Lopez-Sanchez ve Sánchez (2019) tarımsal ürünlerin sınıflandırılması amacıyla yaptıkları çalışmalarında, çok zamanlı Radarsat-2 ve Sentinel-1 SAR uydu görüntülerinden faydalanmışlardır. Çalışmaları kapsamında C5.0 karar ağaçları sınıflandırma algoritması kullanılmıştır.

Son yıllarda makine öğrenmesi ve bilgisayarlı görü alanlarındaki gelişmeler ile birlikte, yeni nesil makine öğrenme algoritmaları karşımıza çıkmakta ve bu algoritmaların uzaktan algılama alanındaki uygulamaları da giderek artmaktadır. Özellikle bu gelişmeler, yeni nesil topluluk öğrenme (ensemble learning) algoritmalarının ortaya çıkmasına neden olmuştur.

Yeni nesil topluluk öğrenme algoritmalarına Kanonik korelasyon ormanı (canonical correlation forest), aşırı gradyan hızlandırma (extreme gradient boosting), hafif gradyan hızlandırma makinaları (light gradient boosting machines, LightGBM) ve derin orman (deep forest) algoritmaları örnek olarak verilebilir (Xia, Yokoya & Iwasaki, 2017; Georganos vd., 2018; Üstüner & Balık Şanlı, 2019; Boualleg, Farah & Farah, 2019).

Bu çalışmada, çok zamanlı Radarsat-2 PolSAR uydu görüntülerinin tarımsal ürünlerin sınıflandırılmasındaki kullanımı araştırılmıştır. Çalışma kapsamında üç farklı makine öğrenme algoritması kullanılmış ve sınıflandırma performansları karşılaştırılmıştır. Sınıflandırma sonuçlarının analizi aşamasında k-katlamalı çapraz doğrulama (k-fold cross validation) yöntemi kullanılmıştır. Ayrıca, elde edilen sınıflandırma doğrulukları arasındaki farkların istatistiksel olarak anlamlı olup olmadığı ise McNemar testi kullanılarak analiz edilmiştir.

## 2. Çalışma Alanı ve Kullanılan Veri

Çalışma alanı Konya şehir merkezinin 65 km kuzeyinde yer almaktadır ve yaklaşık olarak 42 km<sup>2</sup>'lik bir alana sahiptir. Geniş düzlüklere sahip Konya ovası ülkemizin en büyük ovasıdır ve ülke tarımında önemli bir paya sahiptir. Test alanı tamamen tarım ürünleri ile kaplıdır ve alanda beş farklı ürün türü bulunmaktadır (yem bitkisi, mısır, patates, ayçiçeği ve buğday) (Şekil 1). Uydu görüntülerinin alım tarihi ile eş zamanlı olarak arazi çalışması gerçekleştirilmiş ve tarlalarda tarımsal ürün türlerine ilişkin el GPS'i ile örnek noktalar toplanmıştır. Daha sonra bu noktalar, sınıflandırma işleminde kullanılmak üzere kaydedilmiştir. Çalışma kapsamında dört farklı alım tarihine ait tam polarimetrik Radarsat-2 PolSAR uydu görüntüleri kullanılmıştır (Tablo 1).

**Tablo 1:** Görüntü alım tarihleri

Tarihler
13.06.2016
07.07.2016
31.07.2016
24.08.2016

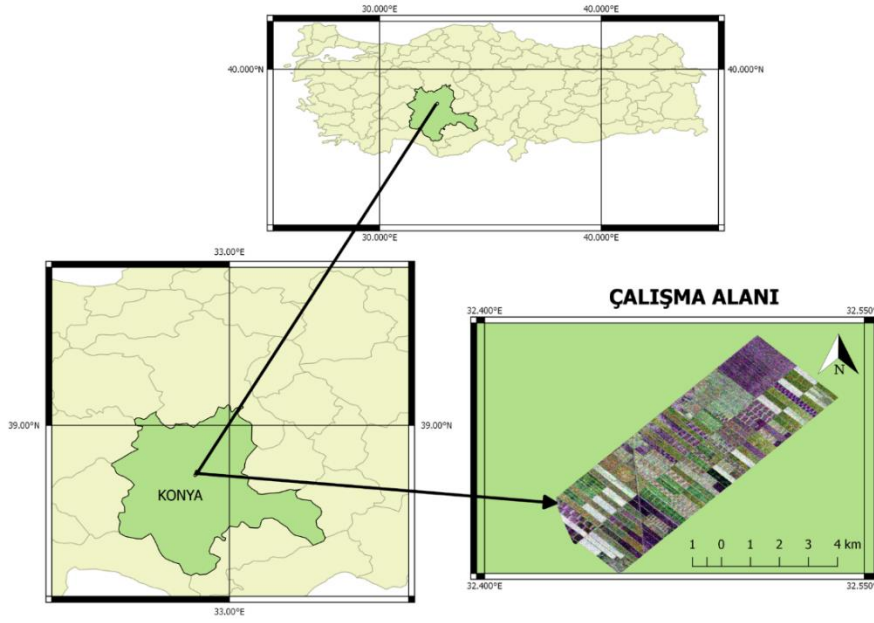
Görüntüler tek bakışlı karmaşık (single look complex) görüntü formatında elde edilmiştir. Çalışmada kullanılan görüntünün özellikleri Tablo 2'de gösterilmiştir.

**Tablo 2:** Radarsat-2 görüntü özellikleri

Algılayıcı	Radarsat-2
Dalga Boyu	C-Band (5.6 cm)
Çözünürlük	4.7 m x 5.1 m (Menzil x Azimut)
Geliş Açısı	40°
Polarizasyon (Alım Modu)	Tam Polarimetrik (DD, YY, DY, YD)
Görüntü Formatı	Tek Bakışlı Karmaşık

Tablo 2'de verinin polarizasyon bilgisine dair olarak D ve Y harfleri, düşey ve yatay polarizasyonları temsil etmektedir.

Sınıflandırma işleminde ve doğruluk analizinde kullanılan yer gerçeklik verisine ilişkin piksel sayıları Tablo 3'te görülmektedir. Sınıflandırma sonuçlarının değerlendirilmesi aşamasında 5-katlamalı çapraz doğrulama yöntemi kullanılmıştır.



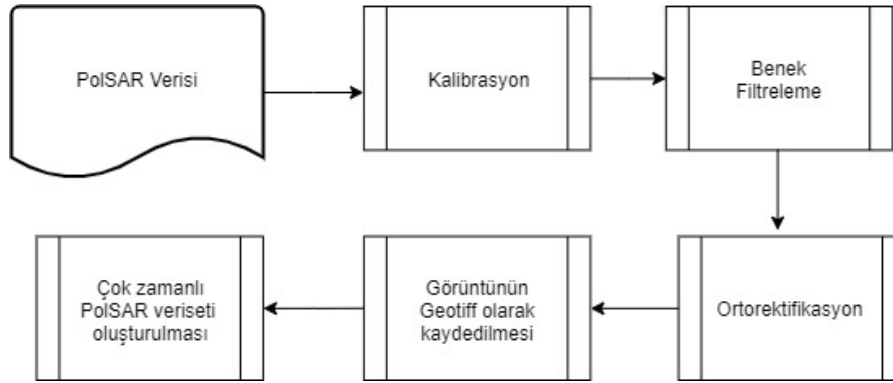
Şekil 1: Çalışma alanı

Tablo 3: Yer gerçekliği verisi

Sınıf	Yer Gerçekliği Verisi (Piksel)
Yem Bitkisi	5460
Mısır	5581
Patates	6093
Ayçiçeği	5361
Buğday	5481

### 3. SAR Verilerinin İşlenmesi

SAR görüntülerden bilgi çıkarımı işleminden önce (sınıflandırma işleminden önce), görüntü ön işleme adımlarının gerçekleştirilmesi gerekmektedir (Şekil 2). Bu işlem adımları Avrupa Uzay Ajansı'nın ücretsiz olarak sağladığı SNAP (Sentinel Application Platform) yazılımı (versiyon 6.0) ile gerçekleştirilmiştir. İlk işlem adımı olarak görüntünün radyometrik (sigma nought) kalibrasyonu yapılmıştır. "Sigma nought" kalibrasyonu, SAR görüntülerinde doğrusal geri saçılım değerlerinin elde edilmesi aşamasında kullanılan temel bir işlem adımdır.



Şekil 2: SAR verilerinin işlenmesi

Bu işlem adımının ardından benek (speckle) etkisini azaltmak amacıyla görüntüye 3x3 Gamma Map filtresi uygulanmıştır. SAR görüntülerinde benek filtreleme amacıyla literatürde sık kullanılan bir filtre olması nedeniyle bu filtre türü seçilmiştir.

Daha sonra ise görüntüye 30 metrelik SRTM (Shuttle Radar Topography Mission) sayısal yükseklik modeli yardımıyla arazi düzeltilmesi (terrain correction) işlem adımı uygulanmıştır. En son işlem adımı olarak ise bantlardaki piksel değerleri, radar geri saçılım (dB) değerine dönüştürülmüş ve görüntüler 10 metreye yeniden örneklenmiştir. Bu temel ön işleme adımları diğer üç farklı tarihe ilişkin görüntüler için de uygulanmış ve çok zamanlı bir veri seti oluşturulmuştur.

#### 4. Sınıflandırma Algoritmaları

Bu çalışma kapsamında, üç farklı makine öğrenme algoritması (LightGBM, RO ve DVM) kullanılmıştır. Kullanılan algoritmalarından LightGBM ve RO algoritmaları karar ağaçları tabanlı topluluk öğrenme algoritmalarındandır (Ke vd., 2017; Saner, Kesici, Mahdı, Yaslan & Genç, 2019). Özellikle son yıllarda uzaktan algılama verilerinin boyut ve hacmindeki artış, araştırmacıları daha hızlı, optimize çalışan ve yüksek başarılı sonuçlar veren yöntemlerin arayışına sokmuştur. LightGBM algoritması da bu amaca yönelik olarak, Microsoft'un "Dağıtık Makine Öğrenmesi Yazılımı (Distributed Machine Learning Toolkit)" isimli projesi kapsamında geliştirilmiştir (URL-1). DVM ise maksimum-marj tabanlı bir öğrenme algoritmasıdır (Melgani & Bruzzone, 2004).

LightGBM algoritması, hızlı, dağıtık ve yüksek başarılı sonuçlar veren gradyan hızlandırma çatısı altında çalışan karar ağacı tabanlı bir makine öğrenme algoritmasıdır (URL-2). Bu algoritmayı diğer karar ağacı tabanlı öğrenme algoritmalarından ayıran bir özelliği, karar ağaçlarının eğitimi aşamasında yaprak odaklı (leaf-wise) büyüme stratejisini kullanmasıdır (Ke vd., 2017; Saner vd., 2019; Li, Ding, Chen, Wang & Yang, 2019). Çoğu karar ağacı tabanlı yöntem, ağacın seviyesine odaklı (level-wise) büyüme stratejisini kullanmaktadır. Microsoft tarafından geliştirilen LightGBM, son yıllarda düzenlenen makine öğrenme yarışmalarında işlem hızı ve doğruluk kriterlerinde en başarılı algoritmalar arasında yer almıştır (URL-3). LightGBM algoritmasının bu başarısının altında, karar ağaçlarının eğitimi aşamasında kullandığı iki özgün teknik yatmaktadır. Bu iki özgün teknik, gradyan tabanlı tek yönlü örnekleme (Gradient-based One-Side Sampling, GOSS) ve ayrıcalıklı özellik desteleme (Exclusive Feature Bundling, EFB) algoritmalarıdır. Gradyan tabanlı tek yönlü örnekleme ile örnek veri sayısının azaltılması (alt-örnekleme, downsampling) ve bu sayede verinin tümü yerine alt örneklem (subsampling) veri kümesinin kullanılması amaçlanmaktadır. Ayrıcalıklı özellik desteleme ise seyrek yapıdaki özellikleri (sparse features) birleştirerek, daha az sayıda yoğun özellikler (dense features) oluşturmaktadır ve bu sayede öğrenme aşamasındaki karmaşıklık seviyesini azaltmaktadır. Bu işlemler de dolaylı olarak, algoritmanın daha hızlı çalışmasını sağlamaktadır (Ke vd., 2017; Li vd., 2019; Üstüner & Balık Şanlı, 2019).

LightGBM algoritmasına ilişkin parametreler Tablo 4'te görülmektedir. Algoritma ve parametrelere ilişkin daha detaylı bilgi Ke vd. (2017)'de mevcuttur. LightGBM algoritmasının uygulanmasında, Microsoft tarafından ücretsiz olarak sağlanan Python paketi (versiyon 2.1.1) kullanılmıştır. Parametre seçimi ise, orijinal LightGBM paketinin ana sayfasındaki "parametre ayarlama (parameter tuning)" sayfasındaki öneriler dikkate alınarak seçilmiştir (URL-4).

**Tablo 4:** LightGBM parametreleri

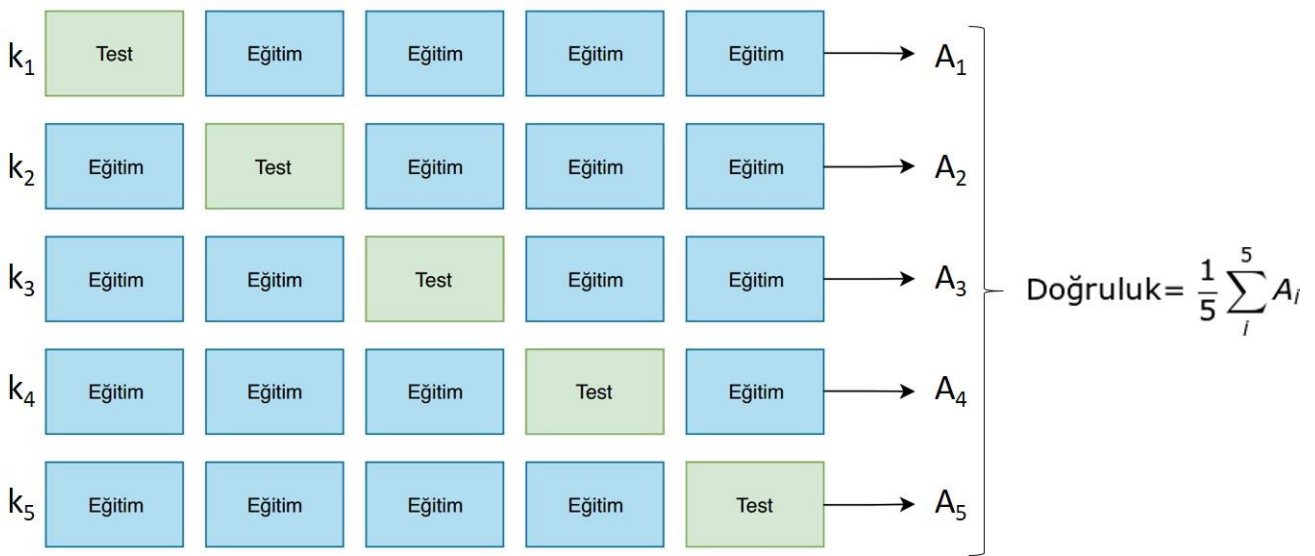
Parametreler	Değer
Hızlandırma Türü	GOSS
Maksimum Derinlik	5
Yaprak Sayısı	100
Öğrenme Oranı	0.1
Amaç (Objective)	Multiclass
Özellik Fraksiyonu	1.0
Yapraktaki Minimum Veri Sayısı	20
İterasyon Sayısı	100

RO algoritması, karar ağacı tabanlı bir topluluk öğrenme algoritmasıdır ve uzaktan algılama verilerinin sınıflandırılmasında hızlı ve uygulanabilirliği kolay bir algoritma olması nedeniyle sıklıkla tercih edilmektedir. RO algoritmasının eğitim aşamasında, torbalama (bagging) yöntemi ile orijinal veri setinden elde edilmiş birbirinden farklı eğitim veri seti kümeleri kullanılmaktadır. Bu yöntem, torbalama yönteminin gelişmiş bir versiyonu olarak kabul edilebilir. RO algoritması için, ağaç sayısı (N) ve değişken sayısı (m) olmak üzere iki parametre gerekmektedir. Bu parametreler, ağaç sayısı ve değişken sayısı için sırasıyla 500 ve 3 olarak alınmıştır (Gislason, Benediktsson & Sveinsson, 2006; Rodriguez-Galiano, Ghimire, Rogan, Chica-Olmo & Rigol-Sanchez, 2012; Ok, Akar & Güngör, 2012).

DVM, kernel tabanlı bir öğrenme algoritmasıdır. Yüksek boyutlu verileri, sınırlı sayıdaki eğitim verisi ile sınıflandırabilme özelliği nedeniyle uzaktan algılamada hiperspektral görüntülerin sınıflandırılması işleminde sıklıkla tercih edilen bir makine öğrenme algoritmasıdır. Temelinde iki sınıflı doğrusal olarak birbirinden ayırabilen en uygun hiperdüzlemin belirlenmesi esasına dayanan DVM, doğrusal en uygun hiperdüzlem ile sınıf ayrımını sağlayamadığı durumlarda kernel fonksiyonlarından faydalanmaktadır. Kerneller yardımıyla, veri daha yüksek boyutlu bir uzaya taşınarak sınıf ayrımının doğrusal hiperdüzlem ile yapılması sağlanır. Bu çalışma kapsamında radyal tabanlı fonksiyon kerneli kullanılmıştır. Radyal tabanlı fonksiyon kerneli için ceza (cost) parametresi 500 ve gamma parametresi 0.1 olarak alınmıştır (Melgani & Bruzzone, 2004; Kavzoğlu & Çölkesen, 2009). DVM ve RO sınıflandırmaları, açık kaynaklı Python Scikit-learn makine öğrenmesi kütüphanesinden (versiyon 0.19) faydalanarak gerçekleştirilmiştir (Pedregosa vd., 2011; Buitinck vd., 2013).

## 5. Değerlendirme

Sınıflandırma sonuçlarının değerlendirilmesi aşamasında k-katlamalı çapraz doğrulama yöntemi kullanılmıştır. k-katlamalı çapraz doğrulama tekniğinde orijinal veri seti k sayıda parçaya bölünür. (k-1) sayıdaki parça sınıflandırıcı modeli eğitmek için kullanılırken, geriye kalan bir parça ise modelin doğruluğunu hesaplamak için kullanılır. Bu işlem k defa tekrar edilir ve her seferinde farklı parça eğitim ve test verisi olarak kullanılır. Elde edilen doğruluk değerlerinin ortalaması alınır. Modelin doğruluğu ise bu ortalama değere eşittir (Kohavi., 1995; Toosi vd., 2019). Bu çalışmada k değeri 5 olarak alınmıştır ve bu işlem Python scikit-learn makine öğrenme kütüphanesi (versiyon 0.19) aracılığıyla gerçekleştirilmiştir (Şekil 3).



Şekil 3: 5-katmanlı çapraz doğrulama

Sınıflandırma sonuçları, genel doğruluk ve Kappa değerlerine bağlı olarak elde edilmiştir (Tablo 5).

**Tablo 5:** Sınıflandırma sonuçları (genel doğruluk ve Kappa değerleri)

Algoritma	Genel Doğruluk (Std Sapma)	Kappa Değeri (Std Sapma)
LightGBM	0.857 ( $\pm 0.026$ )	0.822 ( $\pm 0.033$ )
RO	0.855 ( $\pm 0.033$ )	0.819 ( $\pm 0.040$ )
DVM	0.834 ( $\pm 0.039$ )	0.793 ( $\pm 0.049$ )

Genel doğruluk ve Kappa değerlerine bakıldığında, en yüksek sınıflandırma doğruluğu LightGBM algoritması ile elde edilmiştir. Fakat en yüksek iki sınıflandırma doğruluğu arasındaki farkın (0.002) istatistiksel olarak anlamlı olup olmadığı McNemar testi ile incelendiğinde bu farkın istatistiksel olarak anlamlı olmadığı görülmüştür. Hesaplanan istatistik değeri (1.35) %95 güven aralığındaki kritik değerden ( $\chi^2=3.84$ ) küçük olduğundan aradaki farkın anlamlı olmadığı sonucuna varılmıştır (Kavzoğlu & Çölkesen, 2013). En düşük sınıflandırma doğruluğu ise DVM algoritması ile elde edilmiştir.

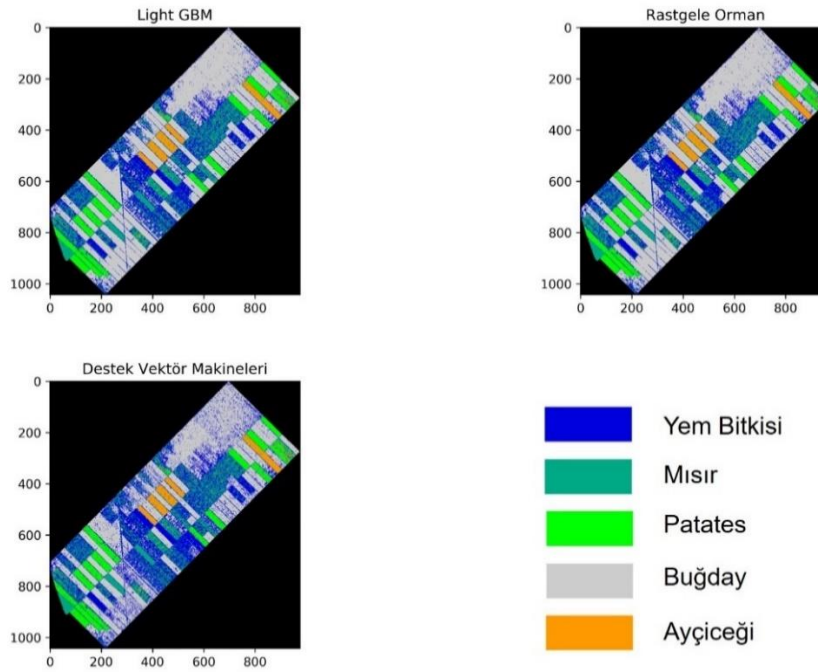
Ayrıca, Tablo 5'teki standart sapma değerleri, 5-katlamalı çapraz doğrulama işlemi sırasında elde edilen sınıflandırma doğruluklarının ortalama değere ne derece yakın/uzak olduğunu ifade etmektedir. 5-katlamalı çapraz doğrulama işleminde, sınıflandırma işlemi beş kez gerçekleştirilir ve her bir sınıflandırma işleminde birbirinden farklı eğitim verisi kullanılır. Bu farklı eğitim veri seti kullanımından en çok etkilenen DVM algoritması olurken (yüksek standart sapma değeri), LightGBM kullanılan algoritmalar arasındaki en robust (dayanıklı) algoritma olarak karşımıza çıkmıştır.

Sınıf bazında doğruluklar incelendiğinde ise buğday sınıfı tüm algoritmalar için en yüksek doğrulukla diğer sınıflardan ayrılan sınıf olarak karşımıza çıkmaktadır. Ayçiçeği ve patates sınıfları da buğday sınıfı gibi diğer sınıflar ile çok karışma göstermeyen ve 0.90 doğruluk değerinin üstünde bir değerle sınıflandırılmış sınıf türleridir (Tablo 6). Mısır sınıfı için LightGBM ve RO algoritmaları 0.73 doğruluk elde ederken DVM algoritması ancak 0.68'lik bir doğruluk ile bu sınıfı sınıflayabilmiştir. Mısır sınıfı tüm algoritmalarda yem bitkisi sınıfı ile karışmıştır. Yem bitkisi sınıfında ise, genel doğruluk değerlerinde en düşük sınıflandırma sonucunu veren DVM algoritması, bu ürün türünde en yüksek doğruluğu elde etmiştir (Tablo 6). Bu sonuç ise kullanılan sınıflandırma algoritmalarının karakteristiğine bağlı olarak, aynı eğitim veri seti kullanılmasına rağmen farklı sonuçlar elde edilebileceğinin bir kanıtıdır.

**Tablo 6:** Normalize edilmiş hata matrisleri

LightGBM					
	Yem Bitkisi	Mısır	Patates	Ayçiçeği	Buğday
Yem Bitkisi	<b>0.70</b>	0.23	0.02	0.01	0.03
Mısır	0.17	<b>0.73</b>	0.03	0.06	0.00
Patates	0.02	0.02	<b>0.95</b>	0.01	0.00
Ayçiçeği	0.01	0.06	0.01	<b>0.92</b>	0.00
Buğday	0.03	0.00	0.00	0.00	<b>0.97</b>
RO					
	Yem Bitkisi	Mısır	Patates	Ayçiçeği	Buğday
Yem Bitkisi	<b>0.68</b>	0.25	0.03	0.01	0.03
Mısır	0.16	<b>0.73</b>	0.04	0.06	0.00
Patates	0.02	0.01	<b>0.96</b>	0.01	0.00
Ayçiçeği	0.00	0.07	0.01	<b>0.92</b>	0.00
Buğday	0.03	0.00	0.00	0.00	<b>0.97</b>
DVM					
	Yem Bitkisi	Mısır	Patates	Ayçiçeği	Buğday
Yem Bitkisi	<b>0.71</b>	0.23	0.03	0.01	0.03
Mısır	0.22	<b>0.68</b>	0.03	0.06	0.00
Patates	0.06	0.03	<b>0.91</b>	0.01	0.00
Ayçiçeği	0.01	0.06	0.01	<b>0.91</b>	0.00
Buğday	0.04	0.00	0.00	0.00	<b>0.96</b>

Çalışmaya ait farklı sınıflandırma modellerine ait sınıflandırılmış görüntüler Şekil 4’te sunulmuştur.



Şekil 4: Sınıflandırılmış görüntüler

Çalışmada veri işleme adımları, Intel Core İ7 işlemci ve 8GB belleğe (RAM) sahip bir bilgisayarda Windows 10 işletim sistemi altında gerçekleştirilmiştir. İşlem süreleri Tablo 7’de verilmektedir.

Tablo 7: Makine öğrenmesi algoritmalarının işlem süreleri

Algoritma	Süre (sn)
LightGBM	5.60
RO	53.08
DVM	49.20

## 6. Sonuçlar ve Öneriler

Bu çalışma kapsamında, çok zamanlı Polarimetrik SAR görüntülerinin tarımsal ürünlerin sınıflandırılmasındaki kullanımı araştırılmış ve bu amaçla kullanılmış makine öğrenme algoritmalarının sınıflandırma performansları karşılaştırılmıştır. En yüksek sınıflandırma doğruluğu LightGBM algoritması ile elde edilmiş olmasına rağmen, RO algoritması ile arasındaki farkın istatistiksel olarak anlamlı olmadığı görülmüştür. Fakat algoritmaların işlem (öğrenme süresi, training time) süreleri karşılaştırıldığında, LightGBM algoritmasının diğer iki algoritmaya kıyasla çok hızlı olduğu görülmüştür (Tablo 7). Ayrıca bu çalışma ile çok zamanlı PolSAR verilerinin tarımsal ürünlerin sınıflandırılmasında etkin bir şekilde kullanılabileceği de test edilmiştir.

Radarsat-2 verisi ile tarımsal ürünlerin sınıflandırılmasına ilişkin çok sayıda çalışma bulunmaktadır fakat yeni nesil topluluk öğrenme algoritmalarından olan LightGBM algoritmasını bu amaca yönelik test eden çalışmalar sınırlı sayıdadır. [Üstüner ve Balık Şanlı \(2019\)](#), tarımsal ürünlerin sınıflandırılmasına yönelik Radarsat-2 verisinden ve LightGBM algoritmasından faydalanmış fakat bu algoritmanın performansını diğer sınıflandırma algoritmaları (DVM ve RO vb.) ile karşılaştırmamıştır. Bu çalışma ile ilk defa, LightGBM algoritmasının tarımsal ürün türlerinin sınıflandırılmasındaki performansı hem RO hem



de DVM ile karşılaştırılmıştır.

Gelecek çalışmalarda, polarimetrik verilerden bilgi çıkarımında sıklıkla kullanılan polarimetrik ayrıştırma tekniklerinden elde edilmiş polarimetrik özelliklerin tarımsal ürünlerin sınıflandırılmasındaki kullanımının araştırılması planlanmaktadır. Ayrıca kullanılan bu algoritmaların yanı sıra, yeni nesil makine öğrenmesi algoritmalarından aşırı gradyan hızlandırma (extreme gradient boosting) ve derin orman (deep forest) algoritmaları da gelecek çalışmalara dâhil edilecektir.

## Teşekkür

Bu çalışma, Yıldız Teknik Üniversitesi (YTÜ) Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından FBA-2017-3062 kodlu proje kapsamında desteklenmiştir. Destekleri için Yıldız Teknik Üniversitesi (YTÜ) Bilimsel Araştırma Projeleri Koordinatörlüğü'ne teşekkür ederiz.

## Kaynaklar

- Boualleg, Y., Farah, M., & Farah, I. R. (2019). Remote Sensing Scene Classification Using Convolutional Features and Deep Forest Classifier. *IEEE Geoscience and Remote Sensing Letters*.
- Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., Vanderplas, J., Joly, A., Holt, B., & Varoquaux, G. (2013). API design for machine learning software: experiences from the scikit-learn project. *arXiv preprint arXiv:1309.0238*.
- Georganos, S., Grippa, T., Vanhuyse, S., Lennert, M., Shimoni, M., Kalogirou, S., & Wolff, E. (2018). Less is more: Optimizing classification performance through feature selection in a very-high-resolution remote sensing object-based urban application. *GIScience & remote sensing*, 55(2), 221-242.
- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300.
- Gui, R., Xu, X., Wang, L., Yang, R., & Pu, F. (2018). A Generalized Zero-Shot Learning Framework for PolSAR Land Cover Classification. *Remote Sensing*, 10(8), 1307.
- Huang, X., Wang, J., Shang, J., Liao, C., & Liu, J. (2017). Application of polarization signature to land cover scattering mechanism analysis and classification using multi-temporal C-band polarimetric RADARSAT-2 imagery. *Remote Sensing of Environment*, 193, 11-28.
- Jiao, X., Kovacs, J. M., Shang, J., McNairn, H., Walters, D., Ma, B., & Geng, X. (2014). Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 38-46.
- Kavzoğlu, T., & Çölkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352-359.
- Kavzoğlu, T., & Çölkesen, I. (2013). An assessment of the effectiveness of a rotation forest ensemble for land-use and land-cover mapping. *International Journal of Remote Sensing*, 34(12), 4224-4241.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems* (s. 3146-3154).
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai 14(2)*, 1137-1145.
- Larrañaga, A., & Álvarez-Mozos, J. (2016). On the added value of Quad-Pol Data in a multi-temporal crop classification framework based on RADARSAT-2 imagery. *Remote Sensing*, 8(4), 335.
- Lee, J. S., & Pottier, E. (2009). *Polarimetric radar imaging: from basics to applications*. CRC press.
- Liu, C., Shang, J., Vachon, P. W., & McNairn, H. (2013). Multiyear crop monitoring using polarimetric RADARSAT-2 data. *IEEE Transactions on Geoscience and Remote Sensing*, 51(4), 2227-2240.
- Li, W., Ding, S., Chen, Y., Wang, H., & Yang, S. (2019). Transfer learning-based default prediction model for consumer credit in China. *The Journal of Supercomputing*, 75(2), 862-884.

- Ma, Q., Wang, J., Shang, J., & Wang, P. (2013). Assessment of multi-temporal RADARSAT-2 polarimetric SAR data for crop classification in an urban/rural fringe area. *2013 Second International Conference on Agro-Geoinformatics (Agro-Geoinformatics)* (s. 314-319). IEEE.
- Maghsoudi, Y., Collins, M. J., & Leckie, D. G. (2013). Radarsat-2 polarimetric SAR data for boreal forest classification using SVM and a wrapper feature selector. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(3), 1531-1538.
- McNairn, H., & Brisco, B. (2004). The application of C-band polarimetric SAR for agriculture: A review. *Canadian Journal of Remote Sensing*, 30(3), 525-542.
- McNairn, H., & Shang, J. (2016). A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. In *Multitemporal Remote Sensing* (pp. 317-340). Springer, Cham.
- Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on geoscience and remote sensing*, 42(8), 1778-1790.
- Niu, X., & Ban, Y. (2013). Multi-temporal RADARSAT-2 polarimetric SAR data for urban land-cover classification using an object-based support vector machine and a rule-based approach. *International journal of remote sensing*, 34(1), 1-26.
- Ok, A. O., Akar, O., & Güngör, O. (2012). Evaluation of random forest method for agricultural crop classification. *European Journal of Remote Sensing*, 45(1), 421-432.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, È. (2011). Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 12(Oct), 2825-2830.
- Ressel, R., Singha, S., Lehner, S., Rösel, A., & Spreen, G. (2016). Investigation into different polarimetric features for sea ice classification using X-band synthetic aperture radar. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(7), 3131-3143.
- 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, 93-104.
- Saner, C. B., Kesici, M., Mahdı, M., Yaslan, Y., & Genç, V. İ. (2019). Güç Sistemlerinde Geçici Hal Kararsızlığının Arıza Öncesi Fazör Ölçümleri Kullanarak Karar Ağacı Tabanlı Kestirimi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(1), 6-14.
- Schmullius, C., Thiel, C., Pathe, C., & Santoro, M. (2015). Radar time series for land cover and forest mapping. *Remote Sensing Time Series* (s. 323-356). Springer, Cham.
- Tamiminia, H., Homayouni, S., McNairn, H., & Safari, A. (2017). A particle swarm optimized kernel-based clustering method for crop mapping from multi-temporal polarimetric L-band SAR observations. *International journal of applied earth observation and geoinformation*, 58, 201-212.
- Toosi, N. B., Soffianian, A. R., Fakheran, S., Pourmanafi, S., Ginzler, C., & Waser, L. T. (2019). Comparing different classification algorithms for monitoring mangrove cover changes in southern Iran. *Global Ecology and Conservation*, e00662.
- Üstüner, M., & Balık Şanlı, F. (2019). Polarimetric Target Decompositions and Light Gradient Boosting Machine for Crop Classification: A Comparative Evaluation. *ISPRS International Journal of Geo-Information*, 8(2), 97.
- Valcarce-Diñeiro, R., Arias-Pérez, B., Lopez-Sanchez, J. M., & Sánchez, N. (2019). Multi-Temporal Dual-and Quad-Polarimetric Synthetic Aperture Radar Data for Crop-Type Mapping. *Remote Sensing*, 11(13), 1518.
- Xia, J., Yokoya, N., & Iwasaki, A. (2016). Hyperspectral image classification with canonical correlation forests. *IEEE Transactions on Geoscience and Remote Sensing*, 55(1), 421-431.
- URL-1: Microsoft Dağıtık Makine Öğrenmesi Yazılımı (Distributed Machine Learning Toolkit), <http://www.dmtk.io/>, (Erişim Tarihi: 21 Eylül 2019).
- URL-2: LightGBM, Light Gradient Boosting Machine, <https://github.com/Microsoft/lightGBM>, (Erişim Tarihi: 21 Eylül 2019).
- URL-3: Machine Learning Challenge Winning Solutions, <https://github.com/microsoft/LightGBM/blob/master/examples/README.md#machine-learning-challenge-winning-solutions> (Erişim Tarihi: 21 Eylül 2019).
- URL-4: Parameters Tuning, <https://lightgbm.readthedocs.io/en/latest/Parameters-Tuning.html> (Erişim Tarihi: 21 Eylül 2019).