

Çekirdek Tabanlı Aşırı Öğrenme Makinesi ile Hiperspektral Görüntü Sınıflandırma

Kernel Extreme Learning Machine for Hyperspectral Image Classification

Mustafa Üstüner^{1*} 

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Mustafa Üstüner
mustuner@artvin.edu.tr

doi: 10.48123/rsgis.1237772

Yayın süreci

Geliş tarihi: 17.01.2023
Kabul tarihi: 04.05.2023
Basım tarihi: 28.09.2023

Özet

Hiperspektral görüntüler, zengin spektral bilgi içerdiklerinden dolayı uzaktan algılama başta olmak üzere birçok alanda etkin bir şekilde kullanılmaktadır. Yüksek spektral boyutu ve karmaşık yapılarından dolayı, hiperspektral görüntülerin sınıflandırılmasında bazı sıkıntılar yaşanmaktadır ve bu nedenle sınıflandırma işlemlerinde ileri düzey algoritmalar (topluluk öğrenme algoritmaları, çekirdek tabanlı yöntemler vb.) tercih edilmektedir. Bu çalışma kapsamında, çekirdek tabanlı aşırı öğrenme makinesinin (ÇAÖM) hiperspektral görüntü sınıflandırmadaki kabiliyeti araştırılmış ve sınıflandırma performansı, iki farklı makine öğrenme algoritması (destek vektör makineleri ve rastgele orman) ile karşılaştırılmıştır. Çalışma kapsamında "Indian Pines" hiperspektral veri seti kullanılmıştır ve çalışma alanında 16 adet arazi örtüsü sınıfı bulunmaktadır. Boyut indirgeme amacıyla veriye temel bileşenler analizi yöntemi uygulanmıştır. Sınıflandırma işlemi hem orijinal hiperspektral verisine hem de temel bileşenler analizi ile boyutu indirgenmiş veriye uygulanmıştır. Boyut indirgeme işlemi sonucunda ilk 40 temel bileşen bant olarak seçilmiştir. En yüksek sınıflandırma doğrulukları hem orijinal veri seti için (%91,64) hem de boyutu indirgenmiş veri seti için (%83,45) DVM yöntemi ile elde edilmiştir. Ayrıca, orijinal veri setinin sınıflandırılması ile elde edilen doğrulukların boyutu indirgenmiş verinin sınıflandırması ile elde edilen doğruluklardan daha yüksek olduğu tespit edilmiştir.

Anahtar kelimeler: Uzaktan algılama, Aşırı öğrenme makinesi, Hiperspektral

Abstract

Hyperspectral images have been actively used in many real-life applications, primarily in remote sensing, since it provides detailed and rich spectral information. There are several challenges in hyperspectral image classification because of the high spectral dimension and the complex structure and hence the advanced classification algorithms (ensemble learning and kernel-based methods) are usually preferred. In this study, the ability of kernel extreme learning machine for the classification of hyperspectral image was investigated and the classification performance was compared with two machine learning algorithms (support vector machines and random forest). "Indian Pines" hyperspectral dataset was used in this experimental study and there are 16 land cover classes in the study area. The principal component analysis was used for the dimensionality reduction and first 40 principal components were selected. The classification was performed for both original dataset and dimensionality reduction applied data. Highest classification accuracies were achieved by support vector machines with overall accuracies of 91,64% and 83,45% for the original dataset and dimensionality reduction applied data, respectively. Furthermore, the original data achieved higher performance with respect to dimensionality reduction applied data in terms of overall accuracy for all methods.

Keywords: Remote sensing, Extreme learning machine, Hyperspectral

1. Giriş

Hava araçları ve uydu tabanlı hiperspektral görüntüleme teknolojisi (görüntüleme spektrometreleri) özellikle son yıllarda hızlı bir şekilde gelişmekte ve yüksek spektral, mekânsal ve zamansal çözünürlükte görüntüler sunmaktadır. Hiperspektral görüntülerdeki artan veri hacmi, yer gerçekliği verisinin kısıtlı olması, karışık pikseller ve farklı geometrik bozulmalardan dolayı verinin işlenmesinde çeşitli sıkıntılar yaşanmaktadır. Bu tarz zorlukların üstesinden gelebilmek ve optimum çözümler sunabilmek amacıyla özellikle sinyal işleme ve örüntü tanıma alanlarında ileri düzey yöntem ve algoritmalar kullanılmaya başlanmıştır (Plaza vd., 2006; Bilgin, 2009; Bioucas-Dias vd., 2013; Ghamisi vd., 2017a). Hiperspektral görüntülerden bilgi çıkarımındaki en önemli uygulamaların başında uydu görüntülerinin sınıflandırılması gelmektedir. Bu verilerin yüksek boyutlu olmaları ve aynı zamanda spektral anlamda fazlalık bilgileri bünyesinde barındırması, uzaktan algılamada kullanılan klasik makine öğrenme algoritmalarının performansını olumsuz yönde etkilemektedir. Kontrollü sınıflandırma işleminde kullanılacak olan eğitim verisinin (yer gerçekliği verisinin) sınırlı sayıda olması ve hiperspektral görüntülerdeki yüksek boyutluluk, hiperspektral verilerin işlenmesinde “boyut belası–curse of dimensionality–” olarak adlandırılan problemin ortaya çıkmasına neden olmuştur. Bu problemin çözümü için de temel olarak iki farklı yol izlenmektedir, bunlardan birincisi boyut indirgeme diğeri ise robust (gürbüz) sınıflandırma algoritmasının seçimidir (Melgani ve Bruzzone, 2004; Plaza vd., 2005; Bioucas-Dias vd., 2013).

Boyut indirgeme işlemlerinde, hiperspektral veri daha düşük boyutlu uzayda temsil edilerek, boyut belası olarak adlandırılan problemin etkisi en alt seviyeye düşürülmeye çalışılır. Hiperspektral görüntülerde boyut indirgeme işlemleri, özellik çıkarımı veya özellik seçimi yöntemleri ile yapılır. Bu iki farklı yaklaşım, sınıf bilgilerini (eğitim verisini) kullanma durumuna göre, kontrollü (denetimli) ya da kontrolsüz (denetimsiz) yöntemler olarak ikiye ayrılabilir. (Bilgin, 2009; Bioucas-Dias vd., 2013; Rasti vd., 2020). Uzaktan algılamada kullanılan kontrolsüz (denetimsiz) boyut indirgeme yöntemlerinin başında, temel (ana) bileşenler analizi (TBA) gelmektedir. Bu yöntem, veriyi daha düşük boyutlu uzayda temsil etmeyi (boyut azaltmayı) ve aynı zamanda bilgi kaybını en aza indireyecek şekilde dönüşüm yapmayı hedeflemektedir. Bu sayede, varyans değeri yüksek, birbiri ile korele olmayan ve bilgi kaybının az olduğu, düşük boyutlu veriler oluşturulmuş olur. Kontrollü sınıflandırma işlemindeki yüksek boyutluluk probleminin etkisi de bu sayede azaltılmış olur (Rodarmel ve Shan, 2002; Plaza vd., 2005; Mohan vd., 2007; Datta vd., 2022).

Uydu görüntülerin sınıflandırılması, uzaktan algılama alanındaki aktif araştırma konularından birisidir. Örüntü tanıma ve makine öğrenmesindeki son gelişmeler ile birlikte, özellikle hiperspektral verilerin sınıflandırılması işleminde yeni nesil ve ileri düzey sınıflandırma algoritmaları kullanılmaya başlanmıştır. Bu gelişmiş algoritmalar, klasik makine öğrenme algoritmalarına kıyasla hem işlem gücü ve süresi hem de sınıflandırma başarımları açısından üstünlük sağlamaktadır. En sık kullanılan algoritmaların başında yapay sinir ağları, destek vektör makineleri (DVM) ve rastgele orman (RO) algoritmaları gelmektedir. Yapay sinir ağları yönteminde, ağı eğitilmesinde kullanılan parametrelerin (gizli katman sayısı, her bir gizli katmandaki nöron sayısı, öğrenme oranı vb.) optimizasyonu zahmetli ve zaman alan bir işlem adımı olduğundan DVM ve RO algoritmaları yöntemleri daha sık tercih edilmektedir. Özellikle, yüksek boyutlu verilerin sınıflandırılmasında az sayıda eğitim verisi (örneklem piksel verisi) ile yüksek başarımlar elde etmesi nedeniyle, DVM yöntemi geçmiş yıllarda sıklıkla tercih edilmiştir. Doğrusal olarak ayrılabilen iki sınıfın sınıflandırılması amacıyla geliştirilen DVM, kernel (çekirdek) fonksiyonları aracılığıyla çok sınıflı ve doğrusal olarak ayrılamayan verilerin sınıflandırılması için de başarıyla kullanılmaktadır. Girdi uzayında doğrusal olarak ayrılamayan çok sınıflı verinin, çekirdek fonksiyonları aracılığıyla yüksek boyutlu uzaya taşınarak doğrusal olarak ayrılabilmesi sağlanmaktadır (Foody ve Mathur, 2004; Bazi ve Melgani, 2006; Chen vd., 2014).

Çekirdek (kernel) tabanlı yöntemler, bir öğrenme modelindeki doğrusal olarak ayrılamayan girdi verileri orijinal uzayından çok boyutlu Hilbert uzayına taşıyarak, sınıfların birbirinden ayrılabilirliğini artırmaktadır. Hiperspektral verilerin sınıflandırılmasında kullanılan çekirdek tabanlı yöntemlerin başında DVM ve aşırı öğrenme makinesi (AÖM) yöntemleri gelmektedir (Camps-Valls vd., 2004; Camps-Valls ve Bruzzone, 2005; Pal vd., 2013; Ergül ve Bilgin, 2020). Uydu görüntülerinin sınıflandırılmasında sıklıkla tercih edilen DVM yönteminde, yüksek sınıflandırma doğruluğu elde edebilmek için optimum (en uygun) parametrelerin (düzenleme ve çekirdek parametreleri) bulunması gerekmektedir ve bu işlem adımı da kullanılan çekirdeğin türü ve sınıf sayısı/karmaşıklığına bağlı olarak uzun sürmektedir. Destek vektör makinelerine kıyasla daha hızlı çalışan ve parametre optimizasyonu açısından da diğer yapay sinir ağları tabanlı yöntemlere nazaran önemli avantajlar sağlayan AÖM, son yıllarda hiperspektral verilerin sınıflandırılması işleminde sıklıkla tercih edilmiştir (Chen vd., 2014; Ergül ve Bilgin, 2020). AÖM yöntemi, giriş katmanı ağırlıklarını ve bias değerini rastsal olarak belirler ve çıkış ağırlıklarını ise tekrarlayan (iteratif) arama yerine çözümsel (analitik) yöntemlerle hesaplar. Gizli katman ağırlıklarının belirlenmesine ihtiyaç duymadığından, öğrenme (işlem) süreci de DVM ya da geri beslemeli yapay sinir ağlarına kıyasla daha hızlıdır. Orijinalinde lineer formda olan AÖM, çekirdek fonksiyonları (kernel fonksiyonları) aracılığı ile daha yüksek boyutlu uzaya transfer edilerek doğrusal olmayan (non-lineer) forma dönüştürülür ve bu yapı da çekirdek (kernel) tabanlı aşırı öğrenme makinesi (ÇAÖM) olarak adlandırılmaktadır (Pal vd., 2013; Chen vd., 2014; Samat vd., 2014; Ergül ve Bilgin, 2020).

Özellikle son birkaç yılda hiperspektral görüntü sınıflandırma alanında kullanılmaya başlanan AÖM yöntemi, basit öğrenme yapısı ve diğer yöntemlere nazaran hızlı olması nedeniyle sıklıkla tercih edilmekte ve başarılı sonuçlar vermektedir. Pal (2009) hem multispektral hem de hiperspektral verinin sınıflandırılmasında AÖM yöntemini kullanmış ve geri yayımlı yapay sinir ağları yöntemi ile karşılaştırmıştır. İki yöntemin birbirine yakın sonuçlar verdiği ve aradaki farkın istatistiksel olarak anlamlı olmadığı sonucuna varmıştır. Pal vd. (2013) multispektral ve hiperspektral görüntülerden oluşan farklı veri setlerinin sınıflandırılması amacıyla çekirdek (kernel) tabanlı AÖM yöntemini kullanmış ve diğer bir çekirdek tabanlı yöntem olan DVM ile sonuçları hem doğruluk hem işlem süreleri açısından karşılaştırmıştır. Bazi vd. (2014) ise çalışmalarında hiperspektral verilerin sınıflandırılmasında morfolojik profiller (özellikler) ve AÖM yönteminden faydalanmış ve AÖM yönteminin hiperspektral verileri sınıflandırma yeteneğini araştırmışlardır. Zhou vd. (2015) hiperspektral görüntülerin sınıflandırılmasında kompozit kernel tabanlı AÖM yöntemini kullanmış ve elde ettikleri sınıflandırma sonuçlarını AÖM, DVM ve kompozit kernel tabanlı DVM yöntemleri ile karşılaştırmıştır. Deneysel çalışmalarında, kompozit kernel tabanlı AÖM yönteminin diğer yöntemlerden daha yüksek doğruluk elde ettiği sonucuna varmışlardır. Ergul ve Bilgin (2017) ise hiperspektral görüntülerin melez çekirdek AÖM ile sınıflandırması yaklaşımını önermiş ve sınıflandırma başarımlarını orijinal AÖM ve diğer ÇAÖM yöntemleri ile karşılaştırmıştır. 2018 yılında Li vd. (2018) tarafından gerçekleştirilen çalışmada ise, hiperspektral görüntülerin spektral-uzamsal sınıflandırılması amacıyla derin öğrenme tabanlı kernel AÖM yöntemi önerilmiş ve sonuçlar güncel yöntemler ile karşılaştırılmıştır. Önerilen yöntemin, karşılaştırma amacıyla kullanılan yöntemlere nazaran daha başarılı olduğu sonucuna varılmıştır. Ergul ve Bilgin (2020) başka bir çalışmalarında ise, hiperspektral görüntülerin sınıflandırılmasında çoklu kompozit ÇAÖM yaklaşımını önermişlerdir. Önerilen yöntemin sonuçları, farklı makine öğrenme algoritmaları ile karşılaştırılmış ve sonuçlar irdelenmiştir. Su vd. (2023) ise hiperspektral görüntülerin yarı-güdümlü sınıflandırılması amacıyla normalize edilmiş spektral kümeleme ve ÇAÖM yöntemlerinden faydalanmışlardır. Önerilen yöntem, literatürde kullanılan ileri düzey yöntemlere kıyasla benzer sonuçlar elde etmiştir. Son yıllarda yapılan çalışmalar incelendiğinde, ÇAÖM yönteminin hiperspektral görüntülerin sınıflandırılmasındaki kullanımı dikkat çekmektedir.


Bu çalışma kapsamında, ÇAÖM yönteminin hiperspektral görüntü sınıflandırmadaki performansı, RO algoritması ve DVM ile karşılaştırılmıştır. Sınıflandırma işlemi hem orijinal veriye hem de boyutu indirgenmiş veriye uygulanmıştır. Böylece, kullanılan algoritmaların, yüksek boyutlu verilerin sınıflandırılmasındaki kabiliyeti de test edilmiştir. Elde edilen sonuçlar hem sınıf bazında hem de toplam doğruluk değerleri irdelenerek yorumlanmıştır.

2. Materyal ve Yöntem

Bu bölümde, çalışma kapsamında kullanılan "Indian Pines" hiperspektral veri setinin özellikleri, kullanılan sınıflandırma yöntemleri (ÇAÖM, DVM ve RO) ve uygulaması anlatılacaktır. Ayrıca toplam sınıflandırma doğrulukları ve sınıf bazında F-ölçütü değerleri de bu bölümde paylaşılacaktır.

2.1 Çalışma Alanı ve Kullanılan Veri

Çalışma kapsamında NASA'nın AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) sensörü ile 1992 yılında çekilmiş olan "Indian Pines" veri seti kullanılmıştır. Çalışma alanı Amerika Birleşik Devletleri'nin Indiana eyaletinde yer alan Tippecanoe ilçesi sınırları içerisinde yer almaktadır. Kullanılan hiperspektral veride 220 spektral bant bulunmaktadır ve 20m'lik uzamsal çözünürlüğe sahiptir. Çalışma alanının yaklaşık üçte ikisi tarım alanları (yonca, mısır, çimen, yulaf, soya fasülyesi ve buğday) ile kaplıdır ve 16 adet sınıf (Yonca, Mısır-işlenmemiş, Mısır-az işlenmiş, Mısır, Çimen-otlak, Çimen-ağaç, Çimen-biçilmiş otlak, Saman, Yulaf, Soya fasülyesi- işlenmemiş, Soya fasülyesi-az işlenmiş, Soya fasülyesi, Buğday, Orman, Bina-Çimen-Ağaç-Araç ve Kaya-Çelik-Bina) bulunmaktadır. Çalışma alanında, tarım alanları ile yakın değerlerde spektral yansımaları sahip orman ve bitki örtüsü de bulunduğu için spektral sınıf karışımlarının olması beklenen bir durumdur. Bu nedenle de sınıflandırılması kolay bir veri değildir. Hiperspektral görüntü ve ilişkili olduğu yer gerçekliği verisi Purdue Üniversitesi tarafından ücretsiz olarak kullanıcılara sunulmuştur (Şekil 1) ve uzaktan algılama alanında çok sayıda çalışmada kullanılmıştır. Ayrıca sınıflara ait örnek piksellerin birbirine eşit sayıda olmaması ya da dengesiz bir veri kümesi olması nedeniyle, kullanılacak sınıflandırma algoritmasının sınıflandırma kabiliyetini test etmek açısından da uygun bir veridir (Baumgardner vd., 2015; Maxwell vd., 2018; Gao vd., 2018; Xie vd., 2020). Toplam verinin %70 i eğitim verisi, geri kalanı ise test verisi olarak kullanılmıştır.



Şekil 1. a) Hiperspektral Veri, b) yer gerçekliği verisi (Xie vd. (2020) çalışması referans alınarak düzenlenmiştir.)

Çalışma alanında bulunan sınıflar ve her bir sınıfa ait örnek piksel sayısı Tablo 1’de verilmiştir

Tablo 1. Sınıflar ve örnek piksel sayıları

Sınıf No	Sınıf Adı	Örnek Sayısı
1	Yonca	46
2	Mısır-işlenmemiş	1428
3	Mısır-az işlenmiş	830
4	Mısır	237
5	Çimen-otlak	483
6	Çimen-ağaç	730
7	Çimen-biçilmiş otlak	28
8	Saman	478
9	Yulaf	20
10	Soya fasulyesi- işlenmemiş	972
11	Soya fasulyesi-az işlenmiş	2455
12	Soya fasulyesi	593
13	Buğday	205
14	Orman	1265
15	Bina-Çimen-Ağaç-Araç	386
16	Kaya-Çelik-Bina	93

2.2 Sınıflandırma Algoritmaları

Uydu görüntülerinin sınıflandırılması amacıyla çok sayıda geleneksel ve ileri düzey algoritmalar kullanılmaktadır. Sınıflandırma işlemi uygulanacak olan uydu görüntüsünün boyutu, sınıfların spektral karmaşıklığı, görüntünün uzamsal ve spektral çözünürlüğü, kullanılacak yer gerçekliği verisinin arazi örtüsünü ne derece doğru temsil ettiği vb. kriterler sınıflandırma başarımlarını etkilemektedir. Özellikle son yıllarda yapay sinir ağları tabanlı algoritmalar (AÖM, ÇAÖM, evrimsel sinir ağları, tekrarlayan sinir ağları vb.) sıklıkla kullanılmaya başlanmış ve başarılı sonuçlar vermiştir. Bu bölümde, kullanılan sınıflandırma algoritmaları (ÇAÖM, DVM ve RO) anlatılacaktır.

2.2.1 Çekirdek Tabanlı Aşırı Öğrenme Makinesi

AÖM, tek bir gizli katmana sahiptir ve ileri beslemeli bir yapay sinir ağları modelidir (Pal vd., 2013; Chen vd., 2014; Ergul ve Bilgin, 2017). n sayıda eğitim örneğine sahip (x_i, y_i) eğitim veri seti için, H adet gizli katman düğümü içeren AÖM ve $f(x)$ aktivasyon fonksiyonu aşağıdaki gibi ifade edilebilir.

$$\sum_{i=1}^H \alpha_i f(x_j) = \sum_{i=1}^H \alpha_i f(w_i \cdot x_j + c_i) = y_j \quad j = 1, \dots, n, \quad (1)$$

AÖM çıkış fonksiyonu ise aşağıdaki gibi yazılabilir.

$$F_H(x) = \sum_{i=1}^H \alpha_i f(w_i \cdot x + c_i) = \alpha \cdot h(x) = 1, \dots, n, \quad (2)$$

Burada w_i , giriş katmanı ile i . gizli katman arasındaki, α_i ise i . gizli katman düğümü ile çıkış katman düğümleri arasındaki ağırlık değerlerini göstermektedir. c_i ise i . gizli katman düğümünün karmaşık bias değeridir. $h(x)$ vektörü ise x girdisine ilişkin gizli katman çıkış vektörüdür.

Huang vd. (2012), geri yayımlı öğrenim algoritmasındaki (w_i, α_i) ağırlıklarının iteratif yolla bulunması probleminin üstesinden gelmek için $A \alpha = Y$ denkleminin en küçük norm ve en küçük kareler çözümünü önermiştir. AÖM'in kullanıldığı çoğu durumda, gizli katman sayısı eğitim örneği sayısına kıyasla çok az olmaktadır ve bu da kare olmayan bir A matrisinin oluşumuna neden olmaktadır. Bu durumda da $A \alpha = Y$ koşulu sağlanmamaktadır. Bu sorunun çözümü için de Moore-Penrose genelleştirilmiş matris tersi alma teoremine dayalı olarak α' hesaplanmıştır.

$$\alpha' = A^* Y \quad (3)$$

Burada A^* , A matrisinin Moore-Penrose genelleştirilmiş matris tersini göstermektedir.

Huang vd. (2012) çalışmalarında, AÖM mimarisinin tasarımında çekirdek (kernel) tabanlı yöntemlerin kullanımını önermiş ve bu amaca yönelik olarak, α çıkış ağırlıklarının hesaplanmasında $\frac{1}{\rho}$ pozitif değerinin eklenmesini tavsiye etmişlerdir. Bu durumda α aşağıdaki gibi yazılabilir.

$$\alpha = A^T \left(\frac{I}{\rho} + AA^T \right)^{-1} Y \quad (4)$$

Yine aynı çalışmalarında Huang vd. (2012), gizli katman çıkış vektörü $h(x)$ 'in bilinmemesi durumunda çekirdek fonksiyonların kullanımını önermiştir. AÖM için bir çekirdek fonksiyonu χ aşağıdaki gibi ifade edilebilir.

$$\chi_{ELM} = AA^T: \quad \chi_{ELM_{i,j}} = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (5)$$

Burada $K(x_i, x_j)$ bir çekirdek fonksiyonu temsil etmektedir. Böylece ÇAÖM çıkış fonksiyonu aşağıdaki gibi yazılabilir.

$$\begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix}^T \left(\frac{I}{\rho} + \chi_{ELM} \right)^{-1} Y \quad (6)$$

Girdi ağırlıkları ve bias değeri, eğitim verisinden bağımsız ve rastsal olarak belirlenir. Gradyan temelli yaklaşımlarda ise en uygun parametreler iteratif olarak aranır ve bu süreç uzun sürer (Pal vd., 2013; Chen vd., 2014). Bu nedenle aşırı öğrenme makinesinin öğrenme süreci, klasik gradyan tabanlı yaklaşımlardan (geri yayılım algoritması gibi) daha kolay ve hızlıdır (Pal vd., 2013; Chen vd., 2014; Ergul ve Bilgin, 2017). Fakat, gizli düğüm sayısının sabit bir değerde alınmasına rağmen, girdi ağırlıkları ve bias değerinin her bir sınıflandırma işlemindeki rastsal seçimi sınıflandırma doğruluğunda varyasyonlara neden olmaktadır. Bu sorunun çözümü için, Huang vd. (2012) aşırı öğrenme makinesinin gizli katmanı yerine bir çekirdek fonksiyonu kullanımını önermişlerdir ve böylece girdi ve gizli katmanlar arasındaki ağırlıkların rastsal seçimine gerek kalmamıştır (Pal vd., 2013; Chen vd., 2014; Ergul ve Bilgin, 2017; Zhou ve Ma, 2019; Cao vd., 2019).

ÇAÖM yönteminin diğer önemli avantajı ise, çekirdek tabanlı diğer bir yöntem olan DVM gibi Mercer's teoremi şartını sağlamasına gerek olmamasıdır (Pal vd., 2013; Chen vd., 2014; Ergul ve Bilgin, 2017; Zhou ve Ma, 2019). Bu çalışma kapsamında Radyal Tabanlı Fonksiyon kerneli kullanılmıştır (ELM, 2023).

2.2.2 Rastgele Orman Algoritması

Topluluk öğrenme algoritmalarından birisi olan RO algoritması, karar ağacı tabanlı bir yöntemdir ve uzaktan algılama verilerinin sınıflandırma ve regresyon problemlerinde kolay uygulanabilirliği ve başarılı sonuçlar vermesi nedeniyle sıklıkla tercih edilmektedir (Waske vd., 2012; Belgi ve Drăguț, 2016; Ghamisi vd., 2017b).


RO algoritması, tek bir ağaç kullanmak yerine, çok sayıda karar ağacından faydalanarak karar verme sürecini tamamlar. Karar verme sürecinde, torbalama ve rastgele alt uzay metotlarından faydalanır. 2001 yılında Breiman tarafından, artırma algoritmalarına daha fazla rastsallık sağlamasından dolayı önerilmiştir. İlk olarak çok sayıda ikili sınıflandırma ağaçları üretir ve bu ağaçları üretirken bootstrap örnekleme yöntemiyle elde edilen örneklem verileri kullanır (Waske vd., 2012; Belgiu ve Drăguț, 2016; Ghamisi vd., 2017b). Karar ormanında her bir ağaç bir birim oya sahiptir ve sonuç sınıf, çoğunluk oylama yöntemine göre belirlenir. Özellikle eşit sayıda örnek piksel (eğitim verisi) barındırmayan hiperspektral veri setlerinin sınıflandırılmasında başarılı sonuçlar vermektedir (Pal, 2005; Gislason vd., 2006; Rodriguez-Galiano vd., 2012; Akar ve Güngör, 2012; Adam vd., 2014; Ghamisi vd., 2017a).

2.2.3 Destek Vektör Makineleri

Hiperspektral görüntülerin sınıflandırılmasında sıklıkla tercih edilen DVM yöntemi, parametrik olmayan yapıdadır ve istatistiksel öğrenme teorisine, diğer bir deyişle Vapnik-Chervonenkis (VC) teorisine, dayalı bir sınıflandırma algoritmasıdır (Huang vd., 2002; Melgani ve Bruzzone, 2004; Dixon ve Candade, 2008). Görüntü verisi için herhangi bir olasılık dağılım kabulü ya da varsayımı yapmaz. Doğrusal olarak iki sınıfı birbirinden ayıran optimum hiperdüzlemin belirlenmesi esasına dayanan DVM yöntemi, sınıfların doğrusal olarak ayrılabilmesi durumunda ise çekirdek fonksiyonlarından faydalanır. Çekirdek fonksiyonu aracılığı ile veriyi özellik uzayına (daha yüksek boyutlu uzaya) taşıyarak, sınıfların çok boyutlu uzayda doğrusal olarak ayrılmasına olanak sağlar (Huang vd., 2002; Melgani ve Bruzzone, 2004; Dixon ve Candade, 2008). DVM yönteminde en sık kullanılan çekirdek fonksiyonları ise radyal tabanlı fonksiyon ve polinom çekirdek fonksiyonlarıdır. DVM sınıflandırma performanslarında, seçilecek çekirdek fonksiyonların türünün ve bu fonksiyonlara ait kullanıcı tarafından belirlenmesi gereken parametrelerin kritik önemi vardır (Huang vd., 2002; Melgani ve Bruzzone, 2004; Dixon ve Candade, 2008; Kavzoglu ve Colkesen, 2009; Adam vd., 2014).

2.3 Uygulama

Bu çalışma kapsamında ise, ÇAÖM, RO ve DVM yöntemleri kullanılmıştır. Sınıflandırma işlemi hem orijinal hiperspektral veriye hem de boyutu indirgenmiş veriye uygulanmıştır ve sınıflandırma sonuçları analiz edilmiştir. Veri analizine dair iş akış şeması Şekil 2'de verilmiştir.

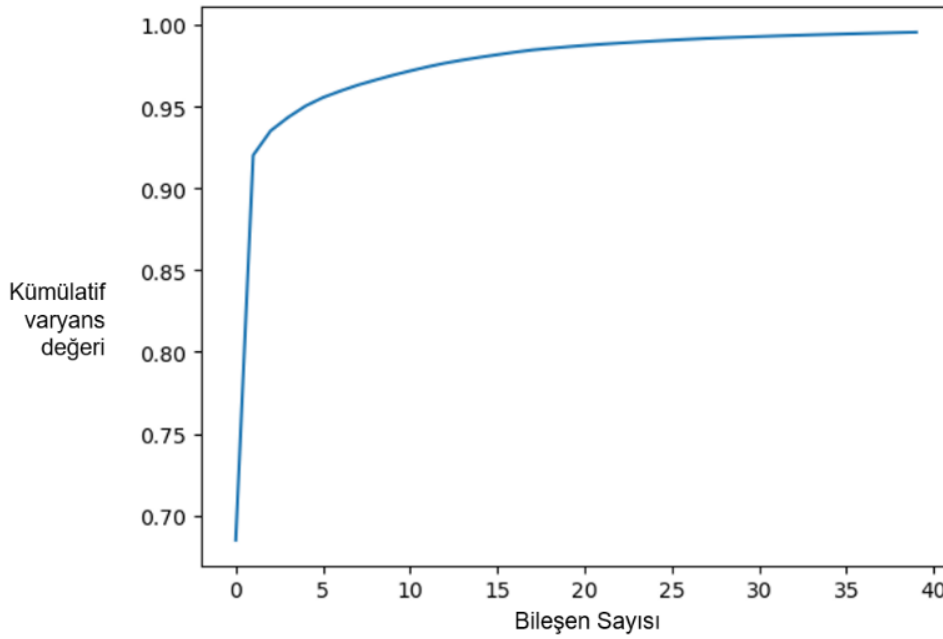


Şekil 2. İş akış şeması

Hem ÇAÖM yönteminde hem de DVM yönteminde, radyal tabanlı fonksiyon kerneli seçilmiştir. Literatür incelendiğinde, uzaktan algılama verilerinin sınıflandırılmasında en sık kullanılan kernel türünün radyal tabanlı fonksiyon kerneli olduğu görülmüştür (Foody ve Mathur, 2004; Mathur ve Foody, 2008; Kavzoglu ve Colkesen, 2009; Kavzoğlu ve Çölkesen, 2010; Dihkan vd., 2013; Adam vd., 2014). Ayrıca, radyal tabanlı fonksiyon kernelinin, diğer kernel türlerine kıyasla daha üstün performansa sahip olduğu da birkaç bilimsel çalışmada ispatlanmıştır (Kavzoglu ve Colkesen, 2009; Kavzoğlu ve Çölkesen, 2010; Waske vd., 2012; Adam vd., 2014).

O nedenle çalışmamızda radyal tabanlı fonksiyon kerneli tercih edilmiştir. İki yöntem için de belirlenmesi gereken iki adet parametre vardır, bunlar DVM için ceza parametresi (C) ve çekirdek boyutu (γ), ÇAÖM için ise düzenleme katsayısı ve çekirdek boyutu (ρ , γ) parametreleridir (Pal vd., 2013; Wang vd., 2017). Bu parametreler DVM için C=500 ve $\gamma=0,01$ olarak, ÇAÖM için ise $\rho=300$ ve $\gamma=0,1$ seçilmiştir. Parametrelerin seçiminde grid arama (grid search) tekniği kullanılmıştır (Kavzoglu ve Colkesen, 2009; Dihkan vd., 2013).

Boyut indirgeme işleminde TBA yöntemi kullanılmıştır. Burada amaç, orijinal veride gereksiz bilgi tekrarına neden olan yüksek korelasyonlu bantların (fazlalık bilginin) tespit edilip uzaklaştırılmasıdır. Bu işlem için, orijinal veri setinin doğrusal kombinasyonları olan temel bileşenler kullanılmaktadır (Rodarmel ve Shan, 2002; Mohan vd., 2007; Hidalgo vd., 2021). Her bir temel bileşen birbirine ortogonal yani 90° diktir. Böylece spektral bilgi tekrarının önüne geçilmektedir (Hidalgo vd., 2021). Boyut indirgeme işlemi sonucunda ilk 40 temel bileşen bant olarak seçilmiş ve sınıflandırma işlemine dahil edilmiştir (Şekil 3). Şekil 3'ten de açık bir şekilde görüldüğü üzere, kümülatif varyans değerinin 1.00'e en yakın olduğu değerdeki bileşen sayısı, TBA'da girdi bant sayısı olarak seçilmiştir.



Şekil 3. Temel bileşenler analizi

3. Bulgular ve Tartışma

Sınıflandırma işlemi hem orijinal hiperspektral verisine hem de boyutu indirgenmiş veriye uygulanmıştır. Sınıflandırma sonuçları (toplam doğruluk değerleri) Tablo 2'de sunulmuştur.

Tablo 2. Sınıfların sınıflandırma doğrulukları

Yöntem	Sınıflandırma doğruluğu (Orijinal Veri)	Sınıflandırma doğruluğu (TBA uygulanmış veri)
ÇAÖM	%78,86	%68,85
DVM	%91,64	%83,45
RO	%87,67	%82,11

Hem orijinal veri seti için hem de boyutu indirgenmiş veri seti için en yüksek sınıflandırma doğrulukları sırasıyla, %91,64 ve %83,45 toplam doğruluk değeri olarak DVM algoritması ile elde edilmiştir. Tüm sınıflandırma sonuçları incelendiğinde ise, en düşük sınıflandırma doğruluklarının (toplam doğruluk) ÇAÖM ile elde edildiği görülmüştür.

Toplam doğruluk (overall accuracy) değeri, doğru sınıflandırılmış toplam piksel sayısının (hata matrisindeki köşegen elemanların toplamı) referans piksellerinin toplamına bölünmesiyle elde edilir. Uydu görüntülerinin sınıflandırılmasında en yaygın kullanılan doğruluk ölçütü toplam doğruluk (genel doğruluk) değeridir (Congalton, 1991; Foody, 2002; Foody, 2009; Congalton ve Green, 2019). Tablo 3'te görülen 3 sınıflı bir sınıflandırma işlemine ait hata matrisinden, doğruluk ölçütlerinin nasıl hesaplandığı gösterilmiştir.

Tablo 3. Üç sınıflı bir sınıflandırmaya ait hata matrisi (confusion matrix)

Sınıf	A	B	C	Toplam
A	a_{11}	a_{12}	a_{13}	x_a
B	a_{21}	a_{22}	a_{23}	x_b
C	a_{31}	a_{32}	a_{33}	x_c
Toplam	y_a	y_b	y_c	z

Doğruluk Ölçütleri

$$\text{Toplam Doğruluk} = (a_{11} + a_{22} + a_{33})/z \quad (7)$$

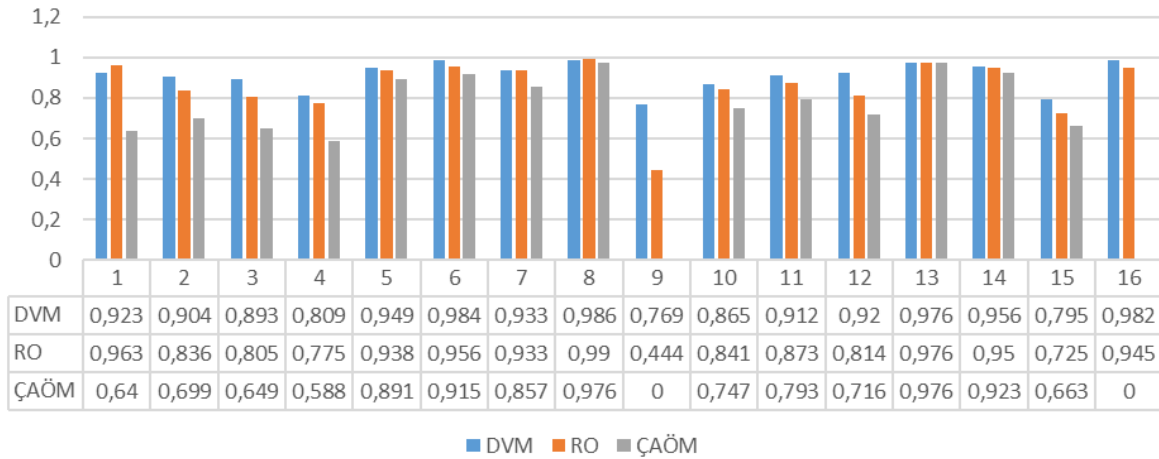
$$\text{Üretici Doğruluğu (ÜD)} = (a_{11})/y_a \text{ (A sınıfı için)} \quad (8)$$

$$\text{Kullanıcı Doğruluğu (KD)} = (a_{11})/x_a \text{ (A sınıfı için)} \quad (9)$$

$$F - \text{Ölçütü} = 2 \times ((\text{ÜD} \times \text{KD}) / (\text{ÜD} + \text{KD})) \quad (10)$$

Orijinal veri setine dair, sınıflara ilişkin F-ölçütü değerleri ve sınıf karışımlarını gösteren hata matrisleri Şekil 4 ve Şekil 5 de verilmiştir. Sınıf bazlı başarımların analiz edilmesinde, kullanıcı ve üretici doğruluğu değerlerinin harmonik ortalamasına eşit olan F-ölçütü değerleri kullanılmıştır.

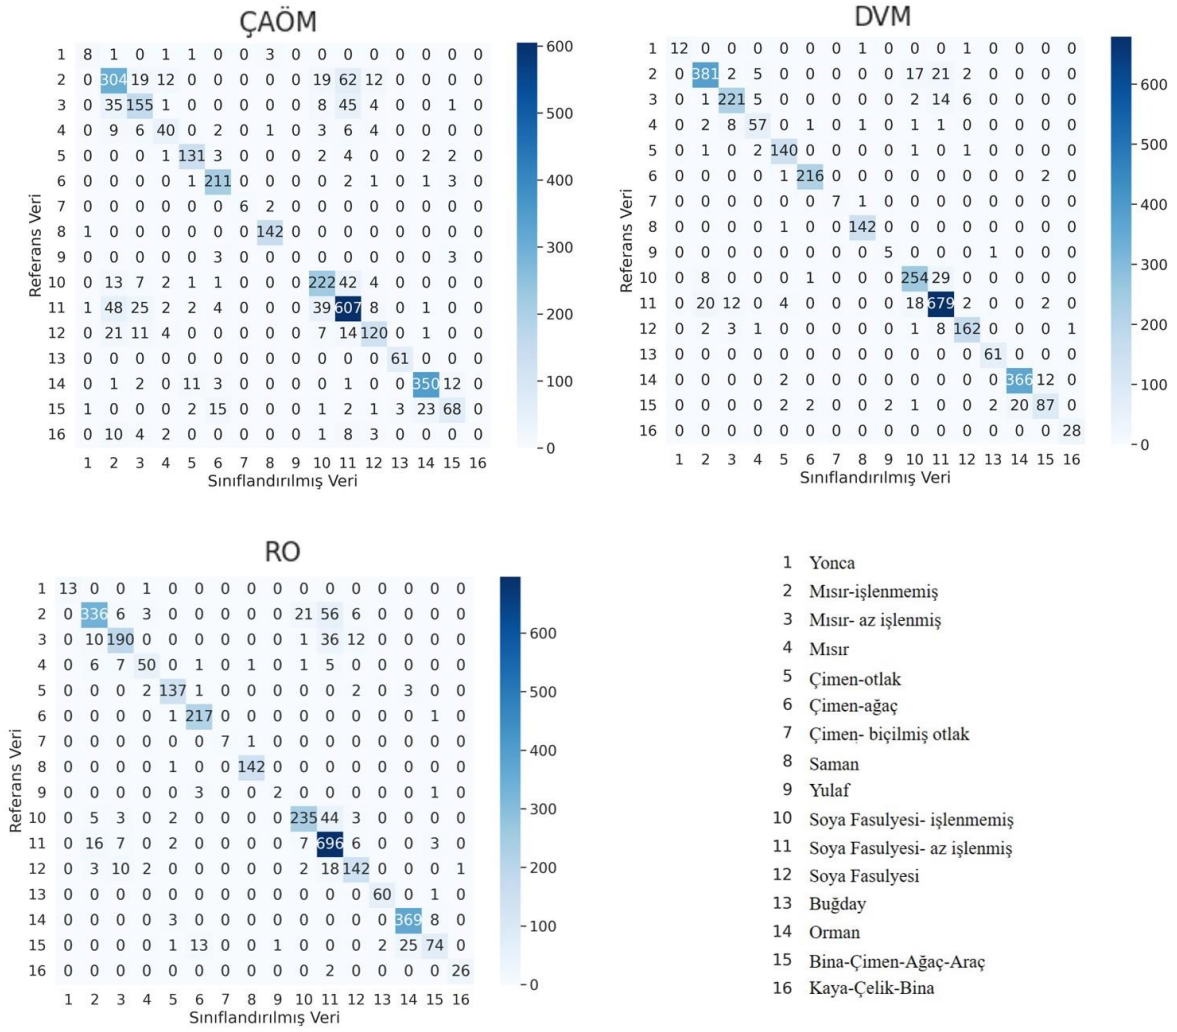
Sınıflara ait F-ölçütü Değerleri (Orijinal Veri)



Şekil 4. Sınıflara ait F-ölçütü değerleri (orijinal veri)

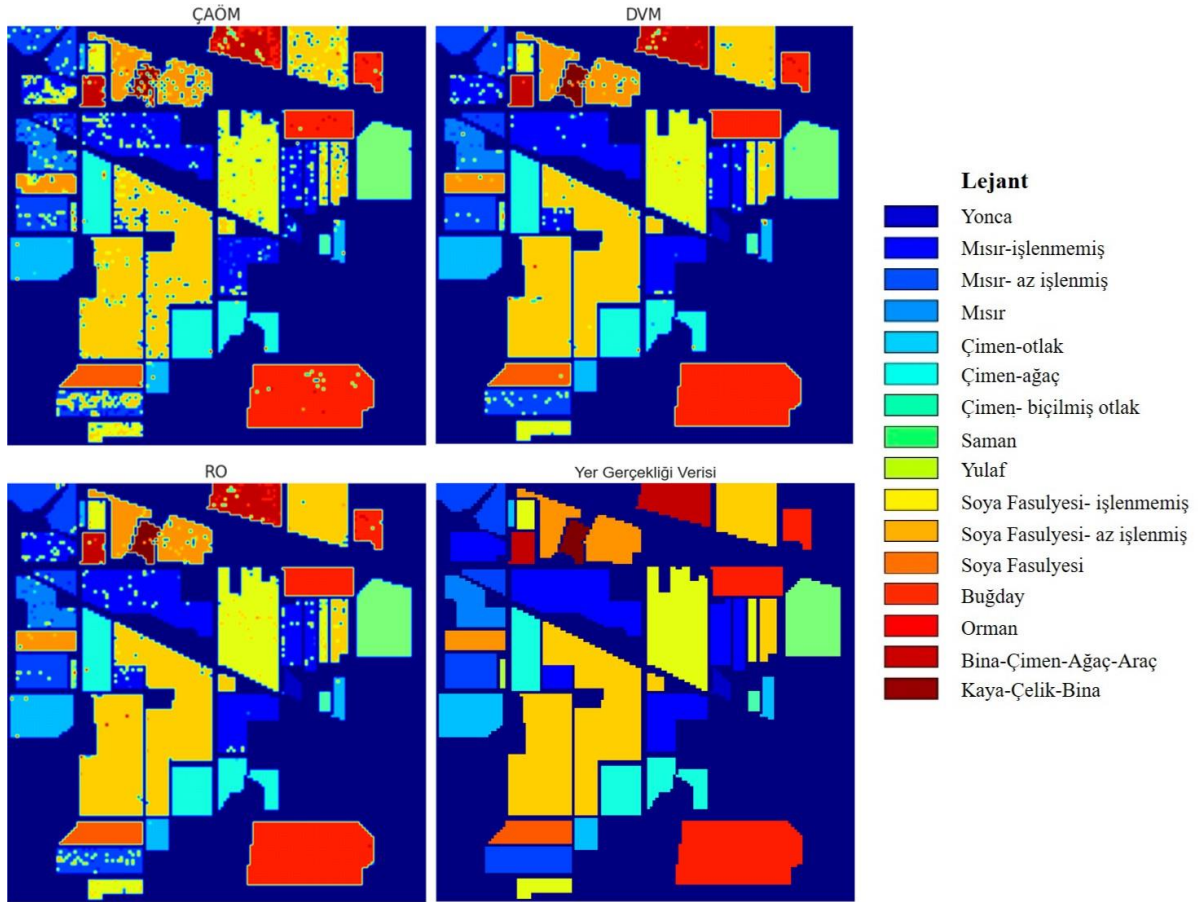
Orijinal veri setinde, sınıf bazında F-ölçütü değerleri incelendiğinde, en yüksek F-ölçütü değerlerine sahip sınıfların saman, çimen-ağaç ve kaya-çelik-bina sınıfları olduğu tespit edilmiştir. Genel doğruluk değerlerine bakıldığında RO algoritması DVM yönteminden düşük olmasına rağmen, yonca ve saman sınıfları için DVM yönteminden daha yüksek F-ölçütü değerleri elde etmiştir. DVM yöntemi özellikle az işlenmiş mısır, mısır, yulaf ve soya fasulyesi sınıfları için RO yöntemine kıyasla daha yüksek sınıflandırma başarımı (F-ölçütü değeri) göstermiştir. Yulaf ve kaya-çelik-bina sınıfları ÇAÖM yönteminde doğru tespit edilememiş ve tamamen yanlış sınıflara atanmıştır. Ayrıca yulaf sınıfı DVM ve RO yöntemlerinde, diğer sınıflara nazaran düşük F-ölçütü değerleri ile sınıflandırılmıştır. Bunun muhtemel nedeni, yulaf sınıfına ait örnek piksel sayısının az olmasıdır.

Ayrıca, Şekil 5'teki hata matrisleri incelendiğinde, yulaf sınıfının ÇAÖM yönteminde çimen-ağaç ve bina-çimen-ağaç-araç sınıfları ile RO yönteminde ise çimen-ağaç sınıfı ile karıştığı gözlenmiştir. ÇAÖM yönteminde doğru tespit edilememiş diğer bir sınıf olan kaya-çelik-bina sınıfı, DVM ve RO algoritmaları ile 0,90 F-ölçütü değerinin üzerinde değerlerle tespit edilmiştir. ÇAÖM'ye ilişkin hata matrisi (Şekil 5) incelendiğinde, kaya-çelik-bina sınıfının büyük bir kısmının işlenmemiş mısır, az işlenmiş soya fasulyesi ve az işlenmiş mısır sınıfı ile karıştığı tespit edilmiştir. ÇAÖM yönteminde, düşük F-ölçütü değerleri olan az işlenmiş mısır ve mısır sınıflarına bakıldığında ise, az işlenmiş mısır sınıfının az işlenmiş soya fasulyesi ve işlenmemiş mısır sınıfları ile mısır sınıfının ise az işlenmiş mısır, işlenmemiş mısır ve az işlenmiş soya fasulyesi ile karıştığı görülmüştür. Mısır sınıfının, az işlenmiş mısır ve işlenmemiş mısır sınıfı ile beklenen bir durumdur. Diğer sınıflara nazaran kısmen daha düşük F-ölçütü değerlerine sahip olan bina-çimen-ağaç-araç sınıfı, ÇAÖM, RO ve DVM yöntemleri için sırasıyla 0,663, 0,725 ve 0,795 değerlerini elde etmiştir. Şekil 5'teki hata matrisleri incelendiğinde, bina-çimen-ağaç-araç sınıfının ÇAÖM ve RO sınıflandırmalarında orman ve çimen-ağaç sınıfları ile DVM yönteminde ise sadece orman sınıfı ile karıştığı gözlenmiştir.



Şekil 5. Hata matrisleri (orijinal veri)


Orijinal verinin sınıflandırılması ile elde edilen sınıflandırılmış görüntüler ve yer gerçekliği verisinin görsel hali Şekil 6'da sunulmuştur. Yer gerçekliği verisinin sınıflandırılmış görüntülerin yanında sunulmasının temel nedeni, görsel yorumlamanın daha kolay yapılmasını sağlamaktır.



Şekil 6. Sınıflandırılmış görüntüler (orijinal veriden) ve yer gerçekliği verisi

Boyutu indirgenmiş veri setine dair, sınıflara ilişkin F-ölçütü değerleri ve sınıf karışımlarını gösteren hata matrisleri Şekil 7 ve Şekil 8 de verilmiştir.

Sınıflara ait F-ölçütü Değerleri (Boyutu İndirgenmiş Veri)




Şekil 7. Sınıflara ait F-ölçütü değerleri (boyut indirgenmiş veri)

Boyutu indirgenmiş veri setinde, sınıf bazında F-ölçütü değerleri (Şekil 7) incelendiğinde, en yüksek F-ölçütü değerlerine sahip sınıfların saman, buğday ve kaya-çelik-bina sınıfları olduğu tespit edilmiştir. Bu en yüksek F-ölçütü değerleri DVM yöntemi ile elde edilmiştir. Genel doğruluk değerlerine bakıldığında RO algoritması DVM yönteminden düşük olmasına rağmen, çimen-ağaç ve bina-çimen-ağaç-araç sınıfları için DVM yönteminden daha yüksek F-ölçütü değerleri elde etmiştir.

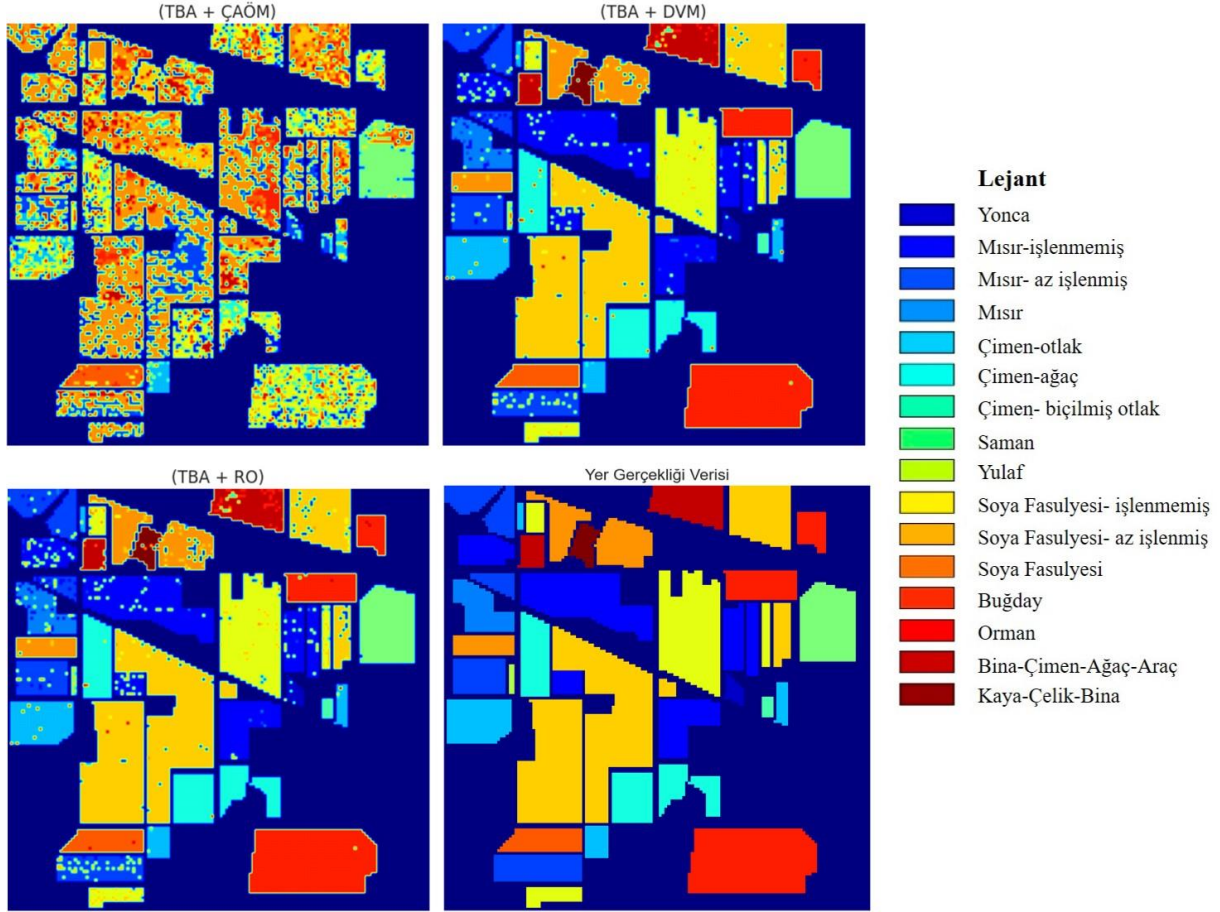
DVM yöntemi özellikle yonca, mısır ve soya fasulyesi sınıfları için RO yöntemine kıyasla daha yüksek sınıflandırma başarımı (F-ölçütü değeri) göstermiştir. Orijinal veri setine benzer şekilde yulaf sınıfı ÇAÖM yönteminde doğru tespit edilememiş ve tamamen farklı sınıflara atanmıştır. Ayrıca yulaf sınıfı DVM ve RO yöntemlerinde, diğer sınıflara nazaran düşük F-ölçütü değeri (0,667) ile sınıflandırılmıştır. Bunun muhtemel nedeni, yulaf sınıfına ait örnek piksel sayısının az olmasıdır. Kaya-çelik-bina sınıfı, orijinal veri setinin ÇAÖM ile sınıflandırılmasında, 0 F-ölçütü değeri ile tamamen yanlış sınıflara atanmış iken, boyutu indirgenmiş veri setinin ÇAÖM ile sınıflandırılmasında ise 0,926 gibi yüksek bir F-ölçütü değeri elde edilmiştir. Bu noktada farklı bir sonuç elde edilmesi, sınıflandırma algoritmalarına girdi olarak kullanılacak verinin sınıf bazlı doğruluklara olan etkisini göstermiştir.

Ayrıca, Şekil 8’deki hata matrisleri incelendiğinde, yulaf sınıfının ÇAÖM yönteminde çimen-ağaç ve buğday sınıfları ile karıştığı gözlenmiştir. Yulaf sınıfının örnek piksel sayısı az olduğu için, F-ölçütü değeri de diğer sınıflara nazaran daha düşük çıkmıştır. Bu sınıf için, DVM ve RO algoritmaları aynı F-ölçütü değerini elde etmişlerdir. ÇAÖM yönteminde diğer sınıflara kıyasla en düşük F-ölçütü değeri ile sınıflandırılan (0,323) mısır sınıfı, DVM algoritması ile 0,70 F-ölçütü değerinin üzerinde değerlerle tespit edilmiştir. ÇAÖM’ye ilişkin hata matrisi (Şekil 8) incelendiğinde, mısır sınıfının büyük bir kısmının işlenmemiş mısır ve az işlenmiş soya fasulyesi sınıfları ile karıştığı tespit edilmiştir. Mısır sınıfının, işlenmemiş mısır sınıfı ile karışması beklenen bir durumdur. Diğer sınıflara nazaran kısmen daha düşük F-ölçütü değerlerine sahip olan mısır sınıfı, ÇAÖM, RO ve DVM yöntemleri için sırasıyla 0,323 0,542 ve 0,729 değerlerini elde etmiştir. Şekil 8’deki hata matrisleri incelendiğinde, mısır sınıfının ÇAÖM ve RO sınıflandırmalarında işlenmemiş mısır ve az işlenmiş soya fasulyesi sınıfları ile DVM yönteminde ise sadece az işlenmiş mısır sınıfı ile karıştığı gözlenmiştir.



Şekil 8. Hata matrisleri (boyut indirgenmiş veri)

Boyutu indirgenmiş verinin sınıflandırılması ile elde edilen sınıflandırılmış görüntüler ve yer gerçekliği verisinin görsel hali Şekil 9’da sunulmuştur.



Şekil 9. Sınıflandırılmış görüntüler (boyut indirgenmiş veriden) ve yer gerçekliği verisi

4. Sonuç ve Öneriler

Bu çalışma kapsamında, ÇAÖM yönteminin hiperspektral görüntü sınıflandırmadaki kabiliyeti araştırılmış ve sınıflandırma performansı (toplam doğruluk değerleri), iki farklı makine öğrenme algoritması (DVM ve RO) ile karşılaştırılmıştır. Sınıflandırma işlemi hem orijinal veriye hem de boyutu indirgenmiş veriye uygulanmıştır. Sınıflandırma işlemine dair sınıf bazında F-ölçütü değerleri karşılaştırılmış ve elde edilen sonuçlar detaylı bir şekilde analiz edilmiştir. Sınıf bazındaki F-ölçütü değerleri incelendiğinde, RO algoritmasının genel doğruluk değeri DVM yönteminden daha düşük gelmesine rağmen bazı sınıf türlerini (orijinal veride yonca, boyutu indirgenmiş veride ise çimen-ağaç ve bina-çimen-ağaç-araç) daha yüksek F-ölçütü değeri ile sınıflandırdığı tespit edilmiştir. Toplam doğruluk (genel doğruluk) değerlerine bakıldığında ise, her iki veri seti için de en yüksek sınıflandırma doğrulukları DVM algoritması ile %91,64 ve %83,45 olarak elde edilmiştir. ÇAÖM iki veri seti için de en düşük toplam doğruluk değerlerini (%78,86 ve %68,85) elde etmiştir.

Sınıf bazında F-ölçütü değerleri incelendiğinde, yulaf sınıfı örnek piksel sayısının az olması nedeniyle ÇAÖM tarafından yanlış (0 F-ölçütü değeri ile) sınıflandırılmış ve tespit edilememiştir. Fakat DVM yöntemi ile orijinal veride 0,77 F-ölçütü değeri ile sınıflandırılmıştır. Bu farklılık, makine öğrenme algoritmalarının kontrollü (denetimli) öğrenme sürecinde eğitim verilerinin ne derece önem arz ettiğini ve aynı veriden farklı sonuçlar elde edilebileceğini göstermiştir.

Gelecek çalışmalarımızda, farklı hiperspektral veri setleri (Salinas, Pavia Üniversitesi vd.) ve diğer çekirdek tabanlı makine öğrenme algoritmaları (Tuia vd., 2010; Gu vd., 2017) kullanılarak, sınıflandırma başarımlarının karşılaştırmalı olarak analiz edilmesi planlanmaktadır.

Teşekkür

Bu çalışma kapsamında kullanılan AVIRIS sensöründen elde edilmiş Indian Pines hiperspektral verisinin ücretsiz erişimine olanak sağladıkları için Purdue Üniversitesi araştırmacıları Marion F. Baumgardner, Larry L. Biehl ve David A. Landgrebe'ye teşekkür ederiz.

Kaynaklar

- Adam, E., Mutanga, O., Odindi, J., & Abdel-Rahman, E. M. (2014). Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, 35(10), 3440-3458.
- Akar, Ö., & Güngör, O. (2012). Classification of multispectral images using Random Forest Algorithm. *Journal of Geodesy and Geoinformation*, 1(2), 105-112.
- Baumgardner, M. F., Biehl, L. L., & Landgrebe, D. A. (2015). 220 band aviris hyperspectral image data set: June 12, 1992 Indian pine test site 3. *Purdue University Research Repository*, 10(7), 991. doi:/10, 4231, R7RX991C.
- Bazi, Y., & Melgani, F. (2006). Toward an optimal SVM classification system for hyperspectral remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 44(11), 3374-3385.
- Bazi, Y., Alajlan, N., Melgani, F., AlHichri, H., Malek, S., & Yager, R. R. (2014). Differential evolution extreme learning machine for the classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 11(6), 1066-1070.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.
- Bioucas-Dias, J. M., Plaza, A., Dobigeon, N., Parente, M., Du, Q., Gader, P., & Chanussot, J. (2012). Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 354-379.
- Bioucas-Dias, J. M., Plaza, A., Camps-Valls, G., Scheunders, P., Nasrabadi, N., & Chanussot, J. (2013). Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2), 6-36.
- Bilgin, G. (2009). *Hiperspektral görüntülerin eğitimsiz bölütlenmesi* (Doktora tezi). Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
- Camps-Valls, G., Gómez-Chova, L., Calpe-Maravilla, J., Martín-Guerrero, J. D., Soria-Olivas, E., Alonso-Chordá, L., & Moreno, J. (2004). Robust support vector method for hyperspectral data classification and knowledge discovery. *IEEE Transactions on Geoscience and Remote Sensing*, 42(7), 1530-1542.
- Camps-Valls, G., & Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6), 1351-1362.
- Cao, F., Yang, Z., Ren, J., Chen, W., Han, G., & Shen, Y. (2019). Local block multilayer sparse extreme learning machine for effective feature extraction and classification of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 5580-5594.
- Chen, C., Li, W., Su, H., & Liu, K. (2014). Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine. *Remote Sensing*, 6(6), 5795-5814.
- 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. (2019). *Assessing the accuracy of remotely sensed data: Principles and practices, Third Edition*. Boca Raton, FL: CRC Press.
- Datta, D., Mallick, P. K., Bhoi, A. K., Ijaz, M. F., Shafi, J., & Choi, J. (2022). Hyperspectral Image Classification: Potentials, Challenges, and Future Directions. *Computational Intelligence and Neuroscience*, 2022, 3854635. doi: 10.1155/2022/3854635.
- Dihkan, M., Guneroglu, N., Karsli, F., & Guneroglu, A. (2013). Remote sensing of tea plantations using an SVM classifier and pattern-based accuracy assessment technique. *International Journal of Remote Sensing*, 34(23), 8549-8565.
- Dixon, B., & Candade, N. (2008). Multispectral landuse classification using neural networks and support vector machines: one or the other, or both?. *International Journal of Remote Sensing*, 29(4), 1185-1206.
- ELM. (2023, January 17). *Basic ELM algorithms*. Retrieved from http://www.extreme-learning-machines.org/elm_codes.html.
- Ergul, U., & Bilgin, G. (2017, May). Hyperspectral image classification with hybrid kernel extreme learning machine. In *2017 25th Signal Processing and Communications Applications Conference (SIU), 2017. Proceedings*. (pp. 1-4). IEEE.
- Ergul, U., & Bilgin, G. (2020). MCK-ELM: multiple composite kernel extreme learning machine for hyperspectral images. *Neural Computing and Applications*, 32(11), 6809-6819.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote sensing of Environment*, 80(1), 185-201.
- Foody, G. M., & Mathur, A. (2004). A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(6), 1335-1343.
- Foody, G. M. (2009). Sample size determination for image classification accuracy assessment and comparison. *International Journal of Remote Sensing*, 30(20), 5273-5291.

- Gao, F., Wang, Q., Dong, J., & Xu, Q. (2018). Spectral and spatial classification of hyperspectral images based on random multi-graphs. *Remote Sensing*, 10(8), 1271. doi: 10.3390/rs10081271.
- Ghamisi, P., Yokoya, N., Li, J., Liao, W., Liu, S., Plaza, J., ... & Plaza, A. (2017a). Advances in hyperspectral image and signal processing: A comprehensive overview of the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 37-78.
- Ghamisi, P., Plaza, J., Chen, Y., Li, J., & Plaza, A. J. (2017b). Advanced spectral classifiers for hyperspectral images: A review. *IEEE Geoscience and Remote Sensing Magazine*, 5(1), 8-32.
- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300.
- Gu, Y., Chanussot, J., Jia, X., & Benediktsson, J. A. (2017). Multiple kernel learning for hyperspectral image classification: A review. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6547-6565.
- Hidalgo, D. R., Cortés, B. B., & Bravo, E. C. (2021). Dimensionality reduction of hyperspectral images of vegetation and crops based on self-organized maps. *Information Processing in Agriculture*, 8(2), 310-327.
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725-749.
- Huang, G. B., Zhou, H., Ding, X., & Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513-529.
- Kavzoglu, T., & Colkesen, 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, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- Li, J., Xi, B., Du, Q., Song, R., Li, Y., & Ren, G. (2018). Deep kernel extreme-learning machine for the spectral-spatial classification of hyperspectral imagery. *Remote Sensing*, 10(12), 2036. doi: 10.3390/rs10122036.
- Mathur, A., & Foody, G. M. (2008). Crop classification by support vector machine with intelligently selected training data for an operational application. *International Journal of Remote Sensing*, 29(8), 2227-2240.
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817.
- 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.
- Mohan, A., Sapiro, G., & Bosch, E. (2007). Spatially coherent nonlinear dimensionality reduction and segmentation of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 4(2), 206-210.
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.
- Pal, M. (2009). Extreme-learning-machine-based land cover classification. *International Journal of Remote Sensing*, 30(14), 3835-3841.
- Pal, M., Maxwell, A. E., & Warner, T. A. (2013). Kernel-based extreme learning machine for remote-sensing image classification. *Remote Sensing Letters*, 4(9), 853-862.
- Plaza, A., Benediktsson, J. A., Boardman, J., Brazile, J., Bruzzone, L., Camps-Valls, G., ... & Trianni, G. (2006, July). Advanced processing of hyperspectral images. In *2006 IEEE International Symposium on Geoscience and Remote Sensing, 2006. Proceedings.* (pp. 1974-1978). IEEE.
- Plaza, A., Martínez, P., Plaza, J., & Pérez, R. (2005). Dimensionality reduction and classification of hyperspectral image data using sequences of extended morphological transformations. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 466-479.
- Rasti, B., Hong, D., Hang, R., Ghamisi, P., Kang, X., Chanussot, J., & Benediktsson, J. A. (2020). Feature extraction for hyperspectral imagery: The evolution from shallow to deep: Overview and toolbox. *IEEE Geoscience and Remote Sensing Magazine*, 8(4), 60-88.
- Rodarmel, C., & Shan, J. (2002). Principal component analysis for hyperspectral image classification. *Surveying and Land Information Science*, 62(2), 115-122.
- 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.
- Samat, A., Du, P., Liu, S., Li, J., & Cheng, L. (2014). E²LMs: Ensemble Extreme Learning Machines for Hyperspectral Image Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(4), 1060-1069.
- Su, Y., Gao, L., Jiang, M., Plaza, A., Sun, X., & Zhang, B. (2023). NSCKL: Normalized Spectral Clustering With Kernel-Based Learning for Semisupervised Hyperspectral Image Classification. *IEEE Transactions on Cybernetics*, 53(10), 6649-6662.

- Tuia, D., Camps-Valls, G., Matasci, G., & Kanevski, M. (2010). Learning relevant image features with multiple-kernel classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10), 3780-3791.
- Wang, M., Chen, H., Yang, B., Zhao, X., Hu, L., Cai, Z., ... & Tong, C. (2017). Toward an optimal kernel extreme learning machine using a chaotic moth-flame optimization strategy with applications in medical diagnoses. *Neurocomputing*, 267, 69-84.
- Waske, B., Benediktsson, J. A., & Sveinsson, J. R. (2012). Random forest classification of remote sensing data. In C.H. Chen (Eds.), *Signal and Image Processing for Remote Sensing* (pp. 365-374), New York, NY: CRC Pres.
- Xie, F., Lei, C., Jin, C., & An, N. (2020). A novel spectral-spatial classification method for hyperspectral image at superpixel level. *Applied Sciences*, 10(2), 463. doi: 10.3390/app10020463.
- Zhou, Y., Peng, J., & Chen, C. P. (2015). Extreme learning machine with composite kernels for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2351-2360.
- Zhou, L., & Ma, L. (2019). Extreme learning machine-based heterogeneous domain adaptation for classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 16(11), 1781-1785.