

Araştırma Makalesi / Research Article

Farklı Platformlardan Elde Edilen Hiperspektral Görüntülerin Sınıflandırılmasında Evrişimli Sinir Ağları, Destek Vektör Makineleri ve Rastgele Orman Algoritmalarının Performanslarının Karşılaştırılması

Eren Can SEYREK^{1*}, Murat UYSAL^{1,2}¹Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Afyonkarahisar.²Afyon Kocatepe Üniversitesi, Uzaktan Algılama Ve CBS Uygulama Araştırma Merkezi, Afyonkarahisar.Sorumlu yazar *¹e-posta: ecseyrek@aku.edu.tr. ORCID ID: <http://orcid.org/0000-0003-1300-4898>²e-posta: muysal@aku.edu.tr. ORCID ID: <http://orcid.org/0000-0001-5202-4387>

Geliş Tarihi: 20.09.2022

Kabul Tarihi: 23.11.2022

Öz

Hiperspektral Görüntüler (HSG), sağladığı yüksek spektral çözünürlük sayesinde birçok alanda kullanım alanına sahiptir. HSG'lerin sınıflandırılması, görüntülerin yüksek spektral çözünürlüğü sebebiyle zorlayıcı bir süreçtir. Bu bağlamda HSG'lerin sınıflandırılmasında birçok Makine Öğrenme (MÖ) algoritmasının performansı araştırılmıştır. Özellikle Derin Öğrenmenin alt dallarından biri olan Evrişimli Sinir Ağları (ESA) tabanlı birçok ağ mimarisi HSG'lerin sınıflandırılması için özel olarak geliştirilmiştir. Hiperspektral görüntüleme sistemlerinin (HGS) yüksek maliyetleri sebebiyle veri setlerinin elde edilmesi zordur. Son yıllarda insanlı ve insansız hava araçları (İHA) için geliştirilen yeni nesil hiperspektral görüntüleme sistemlerinin maliyetleri giderek düşmekte olup yüksek mekânsal çözünürlüklü ve uygun maliyetli HSG elde edilmesi mümkün hale gelmiştir. Bu çalışmada çeşitli platformlardan elde edilmiş farklı spektral ve uzamsal çözünürlükteki HSG'lerin sınıflandırılmasında çeşitli MÖ algoritmalarının performansının incelenmesi amaçlanmıştır. Bu kapsamda uydu tabanlı HyRANK Loukia, hava aracı tabanlı Chikusei İHA tabanlı WHU-Hi HanChuan isimli görüntüler Destek Vektör Makineleri, Rastgele Orman ve ESA algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma performansları incelendiğinde en yüksek genel doğruluk değerleri veri setleri için sırasıyla %87,78, %99,82 ve %96,89 olarak ESA tarafından elde edildiği görülmüştür.

Anahtar kelimeler

Hiperspektral görüntü;
Görüntü sınıflandırma;
Evrişimli sinir ağları;
Destek vektör
makinelere; Rastgele
orman

Comparison of Performances of CNN, SVM and RF Algorithms in Classification of Hyperspectral Images Obtained from Different Platforms

Abstract

Hyperspectral Images (HSI) are employed in many fields, owing to the high spectral resolution that offer. Classification of HSIs is a challenging process due to the high spectral resolution of the images. In this regard, the performance of various Machine Learning (ML) algorithms in the classification of HSGs have been investigated. Especially, Convolutional Neural Networks (CNN) architectures, have been specially developed for the classification of HSIs. Due to the high cost of hyperspectral imaging instruments, obtaining HSI datasets is challenging. In recent years, the costs of new generation hyperspectral imaging systems developed for manned and unmanned aerial vehicles (UAV) have been decreasing, and it has become possible to obtain high spatial resolution and cost-effective HSIs. In this study, it is aimed to examine the performance of various ML algorithms in the classification of HSIs with different spectral and spatial resolutions obtained from various platforms. In this context, satellite-based HyRANK Loukia, manned aircraft-based Chikusei and UAV-based WHU-Hi HanChuan images were classified using Support Vector Machines, Random Forest and CNN algorithms. When the classification performances were examined, it was seen that the highest overall accuracy values were obtained by CNN as 87.78%, 99.82% and 96.89% for the data sets, respectively.

Keywords

Hyperspectral image;
Image classification;
Convolutional neural
networks; Support
vector machine;
Random forest

1. Giriş

Hiperspektral görüntüleme sensörleri, elektromanyetik spektrum boyunca yüzlerce dar ve bitişik spektral bantta veriyi kaydedebilmektedir. Hiperspektral görüntüler (HSG), sağladığı yüksek spektral çözünürlük sayesinde çok geniş bir ölçekte uygulama alanına sahiptir. Bu uygulamalara arazi örtüsü sınıflandırma (Akar and Tunc Gormus 2021), arazi örtüsü değişiminin tespiti (Erturk *et al.* 2015), hassas tarım uygulamaları (Teke *et al.* 2013, Bhosle and Musande 2020), ormancılık (Adao *et al.* 2017), jeoloji (Van der Meer *et al.* 2012), şehir ve bölge planlama (Heiden *et al.* 2012), medikal görüntüleme (Lu and Fei 2014) ve askeri uygulamalar (Ardouin *et al.* 2007) örnek gösterilebilir. Son otuz yıllık süreçte hiperspektral görüntüleme sistemlerinde yeni gelişmeler kat edilmesi sayesinde HSG işleme ve analizi giderek yaygınlaşan bir araştırma konusu haline gelmiştir.

Görüntü sınıflandırma, HSG'deki her bir pikselin arazi sınıfını tanımlamak için kullanılan, HSG işleme alanında temel ve çok önemli bir tekniktir (Meng *et al.* 2021). HSG sınıflandırması, görüntülerin multispektral görüntülere daha düşük uzamsal çözünürlüğe ve çok daha yüksek spektral çözünürlüğe sahip olması ve uzamsal çözünürlüğe sahip olması sebebiyle daha karmaşık ve zorlayıcı bir süreçtir. Örneğin, HSG'lerin dar aralıklarla kaydedilmiş yüzlerce bant ve veri setlerindeki kısıtla sayıdaki yer doğrulama verisi “çok boyutluluğun laneti” olarak da anılan Hughes fenomeninin ortaya çıkmasına neden olmaktadır. Bu sorunların üstesinden gelmek için literatürde birçok farklı sınıflandırma algoritması ve stratejiler HSG sınıflandırması için kullanılmıştır.

HSG'lerin sınıflandırılmasında spektral eşleştirme tabanlı sınıflandırma ve istatistik tabanlı sınıflandırma olmak üzere iki ana sınıflandırma çeşidi mevcuttur (Chen *et al.* 2020). En bilinen spektral eşleştirme tabanlı sınıflandırma yöntemlerinden Spektral Açık Haritalama, görüntü içeren veriden önemli ölçüde etkilenebilmektedir. İstatistik tabanlı sınıflandırma yöntemleri kontrollü

ve kontrolsüz sınıflandırma olarak ikiye ayrılır. Kontrollü sınıflandırma yaklaşımı eğitim verisinden ampirik riski en ve yapısal riski en aza indirme ilkesine dayalı olarak öğrenme işlemi gerçekleştirerek karar sınırları oluşturmayı hedefler.

Kontrollü sınıflandırma algoritmaları, parametrik ve parametrik olmayan sınıflandırma algoritmaları olarak ikiye ayrılabilir. En bilinenleri En Küçük Mesafe, En Çok Benzerlik ve Fisher Doğrusal Diskriminant yöntemleri olan parametrik algoritmalar eğitim verisinden hesaplanan ortalama, varyans, kovaryans gibi çeşitli istatistiksel parametreleri kullanmakta olup verinin dağılımına dair belirli varsayımlarda bulunmaktadır (Sunar vd. 2011). Parametrik olmayan algoritmalar ise verinin dağılımına dair varsayımlarda bulunmaz. Makine Öğrenme (MÖ) algoritmalarından olan En Yakın Komşuluk, Rastgele Orman (RO), Torbalama (Bagging), Hızlandırma (Boosting), Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları parametrik olmayan algoritmalarıdır.

Yapay zekanın alt dallarından biri olan MÖ kavramı, son yıllarda bilgisayar teknolojilerinin ve buna paralel olarak yeni algoritmaların önerilmesi sayesinde önemli ölçüde popülerleşmiştir. MÖ algoritmaları, temel istatistiksel hesaplamalar ve deneyim yoluyla kendilerini otomatik olarak geliştirerek insanların öğrenme davranışlarını ve karar verme yeteneklerini taklit eder (Jordan and Mitchell 2015). Literatürde DVM (Gualtieri and Cromp 1999), RO (Waske *et al.* 2009), Adaboost (Chan and Paelinckx 2008), Kanonik Korelasyon Orman (Xia *et al.* 2016) ve Aşırı Gradyan Artırma (Loggenberg *et al.* 2018) gibi birçok MÖ algoritması HSG'lerin sınıflandırılması için kullanılmıştır.

Son yıllarda, MÖ'de yeni bir atılım olan Derin Öğrenme, görüntü, video ve ses gibi çeşitli veri kümelerinden farklı düzeyde özellikler çıkarma yeteneği nedeniyle bir araştırma konusu olarak popülerlik kazanmıştır. Özellikle Derin Öğrenmenin temeli olarak kabul edilen Evrişimli Sinir Ağları (ESA), sinyaller, görüntüler ve videolar gibi birden çoklu

dizi biçimindeki verileri işleyebilme yeteneğine sahip olduğu için konuşma tanıma, yüz algılama, nesne algılama ve görüntü sınıflandırmada olağanüstü performanslar sağlayabilmektedir (LeCun *et al.* 2015). Sağladıkları yüksek performans, ESA'ların uzaktan algılama uygulamalarında giderek daha fazla öne çıkmasını sağlamıştır (Ghanbari *et al.* 2021). Özellikle HSG'lerin sınıflandırılması için birçok ESA mimarisi tasarlanmıştır (Luo *et al.* 2018, Roy *et al.* 2019, Chen *et al.* 2020, Hang *et al.* 2020).

Hiperspektral görüntüleme sistemlerinin maliyetleri yüksek olması sebebiyle veri setlerinin edilmesi zordur. Literatürde yer alan çalışmalarda başta Indian Pines, Salinas, Botswana, Pavia ve Data Fusion Contest 2018 olmak üzere kısıtlı sayıda kamuya açık veri seti bulunmaktadır (Audebert *et al.* 2019). Uydu tabanlı hiperspektral görüntüleme sistemlerinden EO-1 Hyperion uydusu, 2000 ile 2017 yılları arasında görüntü sağlamış olup, uzun bir süre sonra 2019 yılında İtalyan Uzay Ajansı tarafından PRISMA; 2022 yılında ise Alman Uzay Ajansı tarafından EnMAP uydusu yörüngeye yerleştirilerek bu alanda yeni gelişmeler kat edilmiştir. İnsanlı hava aracı tabanlı sistemlerde ise AVIRIS, AVIRIS-NG, CASI, Aisa ve Headwall Hyperspec gibi çeşitli hiperspektral görüntüleme sistemleri kullanılmaktadır. Ancak uydu ve insanlı hava aracı sistemlerinde düşük uzamsal çözünürlük, işletim maliyetleri ve olumsuz iklim koşulları (bulutluluk ve tehlikeli rüzgarlar gibi) kısıtlamalar mevcuttur (Salami *et al.* 2014). Son yıllarda İnsansız Hava Araçları ve hafif spektrometre sistemlerindeki teknolojik gelişmeler sayesinde diğer sistemlere göre göreceli olarak düşük maliyetlerle yüksek uzamsal (metre altı) ve zamansal çözünürlüğe sahip veriler elde edilmeye başlanmıştır (Crucil *et al.* 2019). Yukarıda bahsedilen gelişmeler sayesinde başta hassas tarım ve ormancılık uygulamaları olmak üzere birçok alanda hiperspektral sistemlerin kullanımı giderek yaygınlaşmaya başlamıştır.

Bu çalışmada, uydu tabanlı, insanlı hava aracı ve insansız hava aracı kullanılarak elde edilen hiperspektral görüntülerin sınıflandırılmasında üç farklı MÖ algoritmasının sınıflandırma performanslarının kıyaslanması amaçlanmıştır. Bu

kapsamda son yıllarda araştırmacıların kullanımına sunulan uydu tabanlı HyRANK, insanlı hava aracı tabanlı Chikusei ve insansız hava aracı tabanlı WHU-Hi HanChuan HSG veri setleri kullanılmıştır. HSG'lerin sınıflandırılmasında olarak DVM, RO ve ESA kullanılmıştır. Sınıflandırma performansları literatürde de sıklıkla kullanılan genel doğruluk, kappa katsayısı (κ), üretici doğruluğu (ÜD) ve kullanıcı doğruluğu (KD) ile incelenirken algoritmaların genel doğrulukları arasındaki farkların istatistiksel olarak anlamlılığı McNemar testi ile irdelenmiştir.


2. Materyal ve Metot

2.1 Hiperspektral Veri Setleri

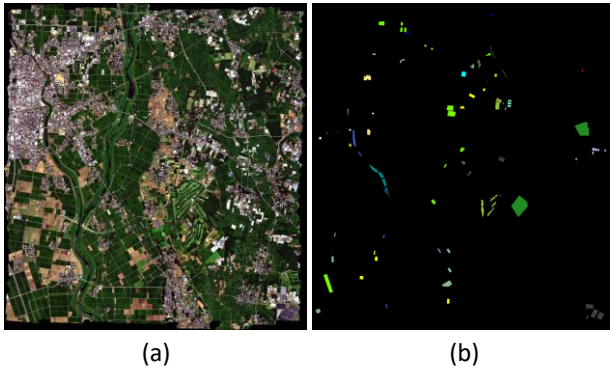
Algoritmaların sınıflandırma performanslarının karşılaştırılması amacıyla üç farklı hiperspektral veri seti kullanılmıştır. Bu veri setlerinden ilki HyRANK Loukia veri setidir. HyRANK Benchmark veri seti Uluslararası Fotogrametri ve Uzaktan Algılama Birliği'nin (International Society for Photogrammetry and Remote Sensing – ISPRS) III/4 numaralı çalışma grubu tarafından hazırlanmıştır (Karantzalos *et al.* 2018). Veri setindeki görüntüler lusal Havacılık ve Uzay Dairesinin (National Aeronautics and Space Administration – NASA) EO-1 Hyperion uydusundan elde edilmiştir. Veri setindeki Dioni ve Loukia isimli görüntüler yer doğrulama verisine sahip olup, çalışma kapsamında Loukia görüntüsü kullanılmıştır. 30 metre uzamsal çözünürlüğe ve 220 spektral banda sahip olan görüntünün ön işleme, su buharı emme bantları ve diğer bozuk bantlarının silinmesinin ardından oluşan görüntünün final boyutu 249×945×176 şeklindedir. Toplamda 14 yer sınıfına sahip olan görüntünün gerçek renkli gösterimi Şekil 1'de; eğitim ve test piksellerinin sayıları ve lejant ise Çizelge 1'de verilmiştir.

Çalışmada kullanılan ikinci veri Chikusei veri setidir. Görüntü Chikusei, Ibaraki, Japonya'daki tarımsal ve kentsel alanlar üzerinde hava aracı tabanlı Headwall Hyperspec-VNIR-C sensörü ile 29 Temmuz 2014 tarihinde elde edilmiştir (Yokoya and Iwasaki 2016). Görüntü 363 ile 1018 nanometre aralığında kaydedilmiş 128 spektral banda ve 2,5 metre yer

örnekleme aralığına sahiptir. Görüntünün boyutu $2517 \times 2335 \times 128$ olup görüntüde 19 yer sınıfı bulunmaktadır. Görüntünün gerçek renkli gösterimi Şekil 2’de; eğitim ve test piksellerinin sayıları ve lejant ise Çizelge 1’de verilmiştir.




Şekil 1. HyRANK Loukia veri setinin (a) gerçek renk kompoziti ve (b) yer doğrulama verisi.



Şekil 2. Chikusei veri setinin (a) gerçek renk kompoziti ve (b) yer doğrulama verisi.

Çalışmada kullanılan üçüncü veri ise WHU-Hi-Han Chuan veri setidir. Görüntü Hubei, Çin’de Aibot X6 insansız hava aracına monte edilmiş Headwall Nano-Hyperspec sensörü ile Haziran 2016’da elde edilmiştir (Zhong *et al.* 2020). Görüntü 400 ile 1000 nanometre aralığında kaydedilmiş 274 spektral banda ve 0,109 metre yer örnekleme aralığına sahiptir. Görüntünün boyutu $1217 \times 303 \times 274$ olup görüntüde 16 yer sınıfı bulunmaktadır. Görüntünün gerçek renkli gösterimi Şekil 3’te; eğitim ve test piksellerinin sayıları ile lejant ise Çizelge 1’de verilmiştir.



Şekil 3. WHU-Hi HanChuan veri setinin (a) gerçek renk kompoziti ve (b) yer doğrulama verisi.

2.2 Sınıflandırma Algoritmaları

DVM, Vapnik (1995) tarafından geliştirilen, istatistiksel öğrenme teorisine dayanan, parametrik olmayan bir eğitimli makine öğrenme algoritmasıdır. İki sınıfa sahip sınıflandırma problemlerinde DVM sonsuz sayıda doğrusal karar sınırı arasından genelleştirme hatasını minimize eden tek bir optimum hiper düzlemi seçmeyi amaçlar. Seçilen hiper düzlem, öznitelik uzayındaki sınıflar arasındaki en büyük marjı sağlar; burada marj, sınıfların en yakın örneklerinden (destek vektörleri) hiper düzleme olan mesafelerin toplamı olarak belirlenir (Vapnik 1995). Sınıflandırma sürecinde karar sınırlarında yer alan destek vektörleri dikkate alındığından, DVM özellikle küçük eğitim veri setleri için kullanışlıdır (Mountrakis *et al.* 2011).

Uzaktan algılama görüntülerindeki piksellerin sınıflandırılması gibi bazı sınıflandırma problemlerinde sınıflar özellik uzayında doğrusal olarak ayrılamazlar (Kavzoglu and Colkesen 2009). Bu durumda Boser *et al.* (1992) veriyi daha yüksek ayrılabilirliğini sağlayan çekirdek fonksiyonlarını önermiştir. DVM için Doğrusal, Polinom, Sigmoid ve Radyal Tabanlı Fonksiyon (RTF) fonksiyonları yaygın olarak kullanılmakta olup, uzaktan algılama görüntülerinin sınıflandırılmasında RTF çekirdek

Çizelge 1. Veri setlerinin sınıfları ve eğitim-test piksel sayıları.

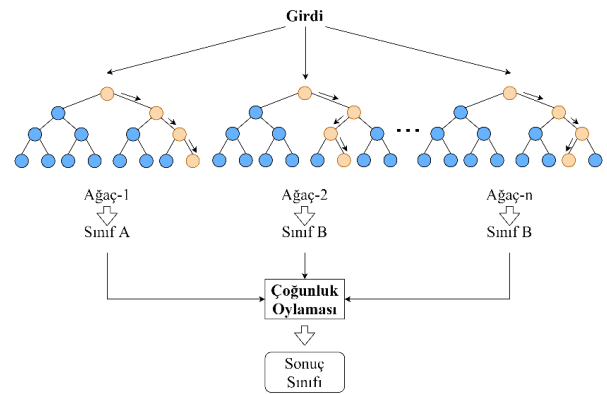
#	HyRANK Loukia				Chisukei			WHU-Hi HanChuan				
	Renk	Sınıf Adı	Eğitim Pikseli Sayısı	Test Pikseli Sayısı	Sınıf Adı	Eğitim Pikseli Sayısı	Test Pikseli Sayısı	Renk	Sınıf Adı	Eğitim Pikseli Sayısı	Test Pikseli Sayısı	
1	■	Sürekli Şehir Yapısı	29	259	■	Su	284	2561	■	Çilek	4473	40262
2	■	Mineral Çıkarım Sahaları	7	60	■	Çıplak Toprak (Okul)	286	2573	■	Börülce	2275	20478
3	■	Sulanmayan Ekilebilir Alanlar	54	488	■	Çıplak Toprak (Park)	29	257	■	Soya Fasulyesi	1029	9258
4	■	Meyve Ağaçları	8	71	■	Çıplak Toprak (Tarım Arazisi)	485	4367	■	Sorgum	535	4818
5	■	Zeytinlikler	140	1261	■	Doğal Bitkiler	430	3867	■	Su Ispanağı	120	1080
6	■	Geniş Yapraklı Ormanlar	22	201	■	Yabani Otlar	111	997	■	Karpuz	453	4080
7	■	İğne Yapraklı Ormanlar	50	450	■	Orman	2052	18464	■	Yeşillik	590	5313
8	■	Karışık Ormanlar	107	965	■	Çimen	651	5864	■	Ağaçlar	1798	16180
9	■	Yoğun Sklerofil Bitki Örtüsü	379	3414	■	Pirinç Tarlası (Yetiştirilmiş)	1337	12032	■	Çim	947	8522
10	■	Seyrek Sklerofil Bitki Örtüsü	280	2523	■	Pirinç Tarlası (Birinci Aşama)	127	1141	■	Kırmızı Çatı	1052	9464
11	■	Seyrek Bitki Alanları	41	363	■	Sıra Mahsulü	596	5365	■	Gri Çatı	1691	15220
12	■	Kayalıklar ve Kumluklar	49	438	■	Plastik Ev	219	1974	■	Plastik	368	3311
13	■	Su	139	1254	■	Yapay (Karanlık Olmayan)	122	1098	■	Çıplak Toprak	912	8204
14	■	Kıyı Suları	45	406	■	Yapay (Karanlık)	766	6898	■	Yol	1856	16704
15					■	Yapay (Mavi)	43	388	■	Parlak Nesne	114	1022
16					■	Yapay (Kırmızı)	22	200	■	Su	7540	67861
17					■	Yapay Çim	104	936				
18					■	Asfalt	80	721				
19					■	Asfaltlanmış Zemin	15	130				

fonksiyonunun daha başarılı olduğu vurgulanmaktadır (Pal and Mather 2005, Mountrakis *et al.* 2011). RTF çekirdek fonksiyonu için çekirdek genişliği (γ) ve regülasyon parametresi (C) olmak üzere iki tane kullanıcı tanımlı parametre bulunmaktadır. Herhangi bir veri seti için en iyi sınıflandırma performansını sağlayan parametre çifti bilinmediğinden optimum parametre araması gereklidir (Hsu *et al.* 2003). Bu çalışma kapsamında önerilen RTF çekirdek fonksiyonu kullanılmış olup optimum kullanıcı tanımlı parametrelerin belirlenmesi için ızgara arama (grid search) çapraz doğrulama metodu kullanılmıştır.

RO algoritması temelde birden fazla karar ağacını kullanan, sınıflandırma, regresyon ve özellik seçimi problemleri için yaygın olarak kullanılan bir toplu öğrenme algoritmasıdır. Breiman (2001) birden fazla sınıflandırıcının tek bir sınıflandırıcıya göre daha iyi bir sınıflandırma performansı göstereceği felsefesiyle Torbalama (Bagging) algoritmasını geliştirerek RO algoritmasını öne sürmüştür. RO budama işlemi gerçekleştirilmeksizin farklı eğitim veri setleri kullanılarak eğitilmiş Sınıflandırma ve Regresyon Ağaçlarını (Classification and Regression

Trees) kombine eder (Breiman 2001, Rodriguez-Galiano *et al.* 2012). Karar ağaçlarının oluşturulması aşamasında bir öznitelik safsızlığını ölçen bir

öznitelik seçim ölçüsü olarak Gini İndeksi kullanılır (Pal 2005).



Şekil 4. RO algoritmasının çalışma prensibi.

RO modelinin eğitimi esnasında girdi eğitim verisinin 2/3'lük kısmı (in-bag) ile rastgele alt eğitim kümeleri oluşturularak karar ağacı ormanındaki karar ağaçları oluşturulur. Eğitim verisinin geriye kalan 1/3'lük kısmı (out-of-bag) dahili bir çapraz doğrulama yöntemi kullanılarak nihai modelin performansını doğrulamak için kullanılır (Sahin *et al.* 2020). Sınıfı bilinmeyen bir pikselin nihai etiketini belirlemek için, Şekil 4'te şematik olarak gösterildiği şekilde ormandaki her karar ağacının sınıflandırma


sonuçları çoğunluk oylaması yapılarak birleştirilir ve her sınıflandırıcı oyu eşit ağırlık taşır (Chan and Paelinckx 2008). Bir RO modeli eğitilirken karar ağacı sayısı (*Ntree*) ve her düğümdeki rastgele seçilen özellik sayısı (*mtry*) olmak üzere iki tane kullanıcı tanımlı parametrenin belirlenmesi gerekir (Sheykhmousa *et al.* 2020). Bu çalışma kapsamında optimum *Ntree* ve *mtry* parametreleri için izgara arama çapraz doğrulama metodu kullanılmıştır.

ESA, yapısında bulunan en az bir katmanında genel matris çarpımı yerine evrişim işlemi kullanılan, sinyaller ve sekanslar, 2 boyutlu dijital görüntüler, videolar gibi grid benzeri topolojiye sahip verileri işlemek için kullanılan özel bir tür sinir ağıdır (LeCun *et al.* 1998, LeCun *et al.* 2015). ESA genellikle evrişim, havuzlama ve tam bağlı katman olmak üzere üç ana bileşenden oluşmakta olup her bir bileşenin farklı bir rolü vardır (Li *et al.* 2018).

Evrişim katmanı her ESA'da en az bir tane bulunmakta olup bu işlem esnasında çeşitli çekirdeklerin (kenar çıkarma filtreleri) tüm görüntü üzerinde gezdirilmesi suretiyle özellik haritaları oluşturulmaktadır (Guo *et al.* 2016). 1 boyutlu (1B), 2 boyutlu (2B) ve 3 boyutlu (3B) olmak üzere çeşitli evrişim operasyonları bulunmaktadır. Evrişim işlemi uygulanmış veriler bir aktivasyon fonksiyonuna tabi tutularak çıktı özellik haritaları üretilmektedir. Aktivasyon fonksiyonu, evrişim katmanından gelen girdi verilerini beklenen çıktıya daha yakın olan anlamlı bir gösterime dönüştüren matematiksel bir işlevdir (Ghatak 2019). Literatürde çeşitli aktivasyon fonksiyonları mevcut olmasına rağmen, gradyan difüzyon sorunu olmadan çok daha hızlı bir hesaplama hızı sağladığı için Rektifiye Doğrusal Birim (Rectified Linear Unit – ReLU) aktivasyon fonksiyonu yaygın olarak kullanılmaktadır (Wang *et al.* 2020). Birçok ESA modelinde bir evrişim katmanının ardından havuzlama katmanı kullanılır. Havuzlama katmanı ile özellik haritalarının boyutluluğu azaltılır. Maksimum havuzlama (max-pooling) ve ortalama havuzlama (average-pooling) yaygın olarak kullanılan havuzlama yöntemleridir. ESA'nın son aşaması olan ve temelde geleneksel bir yapay sinir ağı ile tamamen aynı olan tam bağlı katmanda ise önceki katmanlarda öğrenilen matris formundaki

parametreler vektör forma dönüştürülür (Li *et al.* 2018). Tam bağlı katmanın çıktısı Softmax gibi bir sınıflandırıcıya bağlanarak sınıflandırma işlemi gerçekleştirilir (Krizhevsky *et al.* 2012).

Bu çalışma kapsamında, hiperspektral görüntülerin sınıflandırılması için geliştirilmiş olan HybridSN (Roy *et al.* 2019) isimli ESA mimarisi kullanılmıştır. Modelde 3 tane 3B evrişim katmanı ve 1 tane 2B evrişim katmanı bulunmaktadır. 3B evrişim aşamasında girdi hiperspektral görüntü parçalarından spektral ve konumsal özellikler eş zamanlı olarak çıkarılırken 2B evrişim aşamasında yalnızca konumsal özellikler çıkarılmaktadır. ESA mimarisinin şematik olarak gösterimi Şekil 5'te verilmiştir.



Şekil 5. HybridSN ESA mimarisinin şematik olarak gösterimi.

3. Bulgular

Çalışma kapsamında Intel® Xeon™ E-2136 işlemciye ve NVIDIA GeForce RTX-2070 SUPER grafik işlem birimine sahip bir iş istasyonu kullanılmıştır. Algoritmalar Python 3.7.9 programlama dilinde, NVIDIA CUDA destekli Keras ve Scikit-learn kütüphaneleri kullanılarak kurulmuştur.

HSG'lerin yüksek boyutluluğunu azaltmak için ilk aşamada görüntüye Temel Bileşenler Analizi (TBA) uygulanarak ilk 15 temel bileşen bant olarak kullanılmıştır. Ardından TBA uygulanmış görüntüler $9 \times 9 \times 15$ boyutunda 3B görüntü parçalarına bölünmüştür. Merkez pikselinde yer doğrulama etiketi bulunan 3B görüntü parçaları %10 eğitim ve %90 test veri olacak şekilde ayrılmıştır. Oluşturulan eğitim veri seti ESA için doğrudan kullanılırken DVM ve RO için matris formunda bir girdi oluşturulamadığından, eğitim veri setindeki 3B görüntü parçalarının merkez pikselleri eğitim verisi olarak kullanılmıştır. DVM ve RO algoritmalarının veri setleri için optimum *C*, γ , *Ntree* ve *mtry*

parametrelerinin seçimi için ızgara arama çapraz doğrulama metodu kullanılmıştır. Belirlenen optimum parametreler Çizelge 2’de verilmiştir. ESA modelinde aktivasyon fonksiyonu olarak ReLU, optimizasyon fonksiyonu olarak Adam kullanılırken epok sayısı 500 ve yığın boyutu 256 olarak kullanılmıştır.

Çizelge 2. DVM ve RO algoritmaları için belirlenen optimum kullanıcı tanımlı parametreler.

HSG	C	γ	Ntree	mtry
HyRANK Loukia	10	0,1	100	log2
Chikusei	100	0,01	250	log2
WHU-Hi HanChuan	100	0,01	1000	sqrt

Sınıflandırma algoritmalarının performansının ölçülmesi için literatürde sıklıkla kullanılan, hata matrisi üzerinden hesaplanan GD, κ , ÜD ve KD metrikleri kullanılmıştır (Foody 2004). GD, doğru sınıflandırılan piksel sayısı ile toplam piksel sayısı arasındaki orandır. ÜD modelin sınıflandırma performansının göstergesidir. KD ise sınıflandırılmış haritanın gerçek yeryüzünü ne kadar iyi temsil ettiğinin göstergesidir (Congalton and Green 2019). κ , anlaşma (agreement) ve anlaşmazlık (disagreement) ölçümleri üzerinden hesaplanır. Hesaplanan tüm metrikler 0 ile 1 arasında değer almakta olup, değerlerin 1’e yakın olması sınıflandırma performansının yüksek olduğu anlamına gelmektedir. McNemar testi, sınıflandırma algoritmaları arasındaki tahminlerdeki farklılıkların istatistiksel olarak anlamlılığının incelemesi amacıyla kullanılmıştır. McNemar testi, Ki-kare dağılımına dayalı parametrik olmayan bir testtir ve iki ilişkili grup (yani iki farklı sınıflandırma algoritması tarafından tahmin edilen piksel sınıfları) arasındaki ikili bağımlı değişkeni belirlemek için kullanılır. Test değeri (χ^2), Eşitlik 1’deki denklemle 2x2 boyutlu bir olasılık tablosundan hesaplanır (Foody 2004).

$$\chi^2 = \frac{(|f_{12}-f_{21}|-1)^2}{(f_{12}+f_{21})} \quad (1)$$

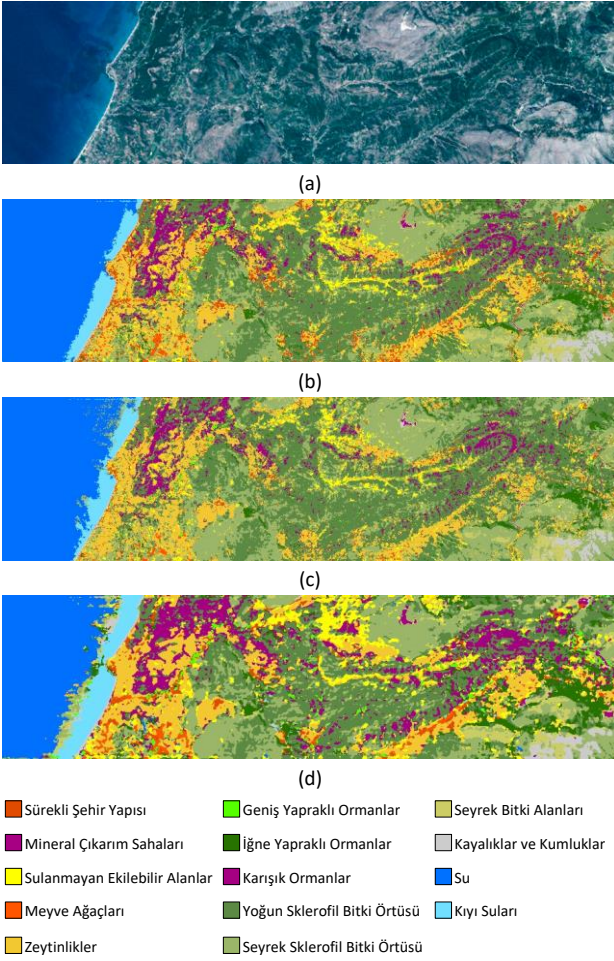
Bu denklemde f_{12} , birinci algoritma tarafından doğru sınıflandırılan ve ikinci algoritma tarafından yanlış sınıflandırılan örneklerin sayısını gösterirken, f_{21} , birinci algoritma tarafından yanlış sınıflandırılan ve ikinci algoritma tarafından yanlış sınıflandırılan örneklerin sayısını gösterir. Elde edilen χ^2 değeri,

%95 güven aralığında χ^2 tablo değerinden ($\chi^2=3,841$) büyükse sıfır hipotezi reddedilir. Başka bir deyişle, model tahminleri arasındaki doğruluk farkının istatistiksel olarak anlamlıdır (Kavzoglu *et al.* 2018).

HyRANK Loukia veri seti için hesaplanan performans metrikleri Çizelge 3’te verilmiştir. Çizelgede kalın karakterlerle gösterilen değerler ilgili kategorideki en yüksek değeri ifade etmektedir. Algoritmalar için hesaplanan GD değerleri sırasıyla %81,61, %80,76 ve %87,78 olarak hesaplanmış olup, GD ve κ metriklerine göre ESA’nın diğer algoritmalarından daha yüksek sınıflandırma performansı gösterdiği görülmüştür. Sınıf bazında hesaplanan ÜD’ler ve KD’ler incelendiğinde ESA’nın 6 sınıfta diğer algoritmalarından daha yüksek doğruluk değerlerine sahip olduğu söylenebilir. ÜD ve KD parametrelerine göre tüm algoritmalar Geniş Yapraklı Ormanlar, İğne Yapraklı Ormanlar ve Karışık Ormanlar sınıfları için düşük performans göstermiştir. Bunun yanı sıra DVM algoritması KD’ye göre Meyve Ağaçları ve Seyrek Bitki Alanları sınıflarında vasat sınıflandırma performansı göstermiştir. Benzer şekilde RO algoritması da Sürekli Şehir Yapısı, Meyve Ağaçları ve Seyrek Bitki Alanları sınıflarında düşük sınıflandırma performansı göstermiştir. Bu durumun orman sınıflarının benzer spektral özelliklere sahip olması ve Meyve Ağaçları sınıfı için az sayıda yer doğrulama verisi bulunmasından kaynaklandığı düşünülmektedir.

Çizelge 3. HyRANK Loukia veri seti için sınıflandırma algoritmalarının performans analizi.

Sınıf Adı	DVM		RO		ESA	
	ÜD	KD	ÜD	KD	ÜD	KD
Sürekli Şehir Yapısı	0,72	0,75	0,78	0,48	0,82	0,75
Mineral Çıkarım Sahaları	0,96	0,83	1,00	0,68	0,86	0,95
Sulanmayan Ekilebilir Alanlar	0,90	0,81	0,88	0,78	0,89	0,85
Meyve Ağaçları	0,80	0,63	0,89	0,23	0,78	0,72
Zeytinlikler	0,91	0,92	0,85	0,87	0,91	0,94
Geniş Yapraklı Ormanlar	0,89	0,35	0,86	0,29	0,85	0,55
İğne Yapraklı Ormanlar	0,88	0,39	0,92	0,55	0,84	0,72
Karışık Ormanlar	0,62	0,55	0,65	0,54	0,75	0,84
Yoğun Sklerofil Bitki Örtüsü	0,72	0,87	0,73	0,87	0,84	0,88
Seyrek Sklerofil Bitki Örtüsü	0,82	0,82	0,78	0,85	0,88	0,86
Seyrek Bitki Alanları	0,83	0,58	0,86	0,53	0,84	0,88
Kayalıklar ve Kumluklar	0,97	0,85	0,91	0,85	1,00	0,88
Su	1,00	1,00	1,00	1,00	1,00	1,00
Kıyı Suları	1,00	1,00	1,00	1,00	0,82	0,75
GD (%)	81,61		80,76		87,78	
κ	77,82		76,75		85,46	



Şekil 6. HyRANK Loukia veri seti için (a) gerçek renkli görüntü, (b) DVM, (c) RO ve (d) ESA için sınıflandırma haritaları.

HyRANK Loukia veri setinin gerçek renkli görüntüsü ve algoritmaların sınıflandırma haritaları Şekil 6'da verilmiştir. Görüntünün düşük konumsal çözünürlüğe sahip olması ve geniş bir alanı kapsamaması sebebiyle görsel açıdan yorumlanması biraz zorlayıcı olsa da bazı piksellerin belirgin bir şekilde yanlış sınıflandırıldığı görülmektedir. Buna örnek olarak, RO ve ESA algoritmalarının sınıflandırma haritalarında Su ve Kıyı Suları sınıflarının kesiştiği bölgede Seyrek Sklerofil Bitki Örtüsü olarak sınıflandırılan pikseller örnek gösterilebilir (Şekil 9).

Chikusei veri seti için hesaplanan performans metrikleri Çizelge 4'te verilmiştir. Algoritmalar için hesaplanan GD değerleri sırasıyla %99,49, %99,12 ve %99,82 olarak hesaplanmış olup, GD ve κ metriklerine göre her üç algoritmanın da çok iyi performans sağladığı, çok küçük farkla ESA'nın diğer algoritmalarından daha yüksek sınıflandırma

performansı gösterdiği görülmüştür. Sınıf bazında hesaplanan ÜD'ler ve KD'ler incelendiğinde ESA'nın Çıplak Toprak (Park) isimli sınıfta diğer algoritmalarından daha yüksek doğruluk değerlerine sahip olduğu görülmektedir.

Çizelge 4. Chikusei veri seti için sınıflandırma algoritmalarının performans analizi.

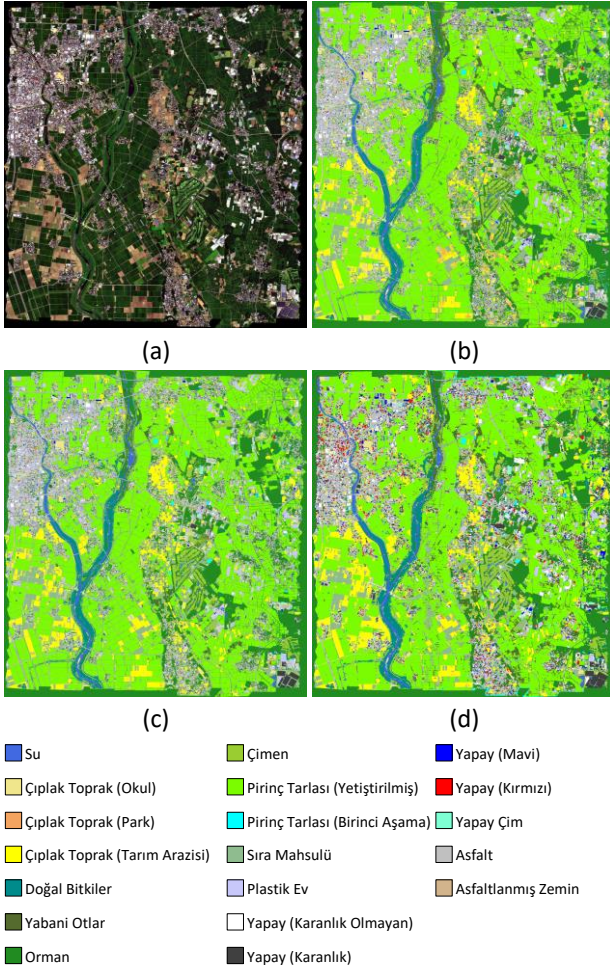
Sınıf Adı	DVM		RO		ESA	
	ÜD	KD	ÜD	KD	ÜD	KD
Su	1,00	1,00	0,99	0,99	1,00	1,00
Çıplak Toprak (Okul)	1,00	0,99	1,00	0,99	1,00	1,00
Çıplak Toprak (Park)	0,77	0,72	0,99	0,28	0,98	0,91
Çıplak Toprak (Tarım Arazisi)	0,98	0,99	0,95	1,00	0,99	1,00
Doğal Bitkiler	1,00	0,99	1,00	0,99	1,00	1,00
Yabani Otlar	0,98	0,98	0,96	0,94	0,98	0,99
Orman	1,00	1,00	1,00	0,99	1,00	1,00
Çimen	1,00	0,99	1,00	1,00	1,00	1,00
Pirinç Tarlası (Yetiştirilmiş)	1,00	1,00	0,99	1,00	1,00	1,00
Pirinç Tarlası (Birinci Aşama)	1,00	1,00	1,00	1,00	1,00	1,00
Sıra Mahsulü	1,00	1,00	0,99	1,00	1,00	1,00
Plastik Ev	0,99	0,98	0,99	0,99	1,00	0,99
Yapay (Karanlık Olmayan)	1,00	0,99	1,00	0,98	0,99	1,00
Yapay (Karanlık)	1,00	1,00	1,00	0,99	1,00	1,00
Yapay (Mavi)	1,00	1,00	1,00	1,00	1,00	1,00
Yapay (Kırmızı)	1,00	1,00	1,00	1,00	1,00	1,00
Yapay Çim	1,00	0,99	0,99	1,00	1,00	1,00
Asfalt	0,96	0,98	0,95	0,99	0,99	0,99
Asfaltlanmış Zemin	0,99	0,95	1,00	0,75	1,00	0,98
GD (%)	99,49		99,12		99,82	
κ	99,41		98,99		99,80	

Chikusei veri setinin sahte renkli görüntüsü ve algoritmaların sınıflandırma haritaları Şekil 7'de verilmiştir. Sınıflandırma haritaları görsel olarak incelendiğinde belirgin bir farklılık görülemediği. Yerleşim alanları daha yakından incelendiğinde ESA'nın Yapay (Kırmızı) isimli sınıfı daha iyi çıkardığı görülmektedir (Şekil 9).

WHU-Hi HanChuan veri seti için hesaplanan performans metrikleri Çizelge 5'te verilmiştir. Algoritmalar için hesaplanan GD değerleri sırasıyla %85,53, %86,84 ve %96,89 olarak hesaplanmıştır. Sınıflar için hesaplanan ÜD ve KD değerleri incelendiğinde ESA algoritmasının başta Su Ispanağı, Karpuz ve Çim sınıfları olmak üzere sınıf bazında daha yüksek başarı oranına sahip olduğu görülmektedir.

WHU-Hi HanChuan veri setinin gerçek renkli görüntüsü ve algoritmaların sınıflandırma haritaları Şekil 8'de verilmiştir. Sınıflandırma haritaları incelendiğinde DVM ve RO algoritmalarının haritalarında daha fazla tuz-biber etkisi görüldüğü


ve aynı sınıfa ait pikseller için sürekli dokunun sağlanmadığı görülmektedir (Şekil 9).




Şekil 7. Chikusei veri seti için (a) gerçek renkli görüntü, (b) DVM (c), RO ve (d) ESA için sınıflandırma haritaları.

Çizelge 5. WHU-Hi HanChuan veri seti için sınıflandırma algoritmalarının performans analizi.

Sınıf Adı	DVM		RO		ESA	
	ÜD	KD	ÜD	KD	ÜD	KD
Çilek	0,86	0,95	0,87	0,97	0,97	0,98
Börülce	0,72	0,74	0,70	0,81	0,97	0,97
Soya Fasulyesi	0,75	0,77	0,77	0,78	0,97	0,93
Sorgum	0,92	0,92	0,94	0,94	0,99	1,00
Su İspanağı	0,40	0,31	0,64	0,18	0,81	0,96
Karpuz	0,40	0,30	0,60	0,20	0,90	0,71
Yeşillik	0,70	0,81	0,73	0,80	0,95	0,94
Ağaçlar	0,74	0,72	0,76	0,77	0,92	0,96
Çim	0,68	0,66	0,74	0,62	0,95	0,96
Kırmızı Çatı	0,97	0,93	0,97	0,91	0,99	1,00
Gri Çatı	0,86	0,95	0,88	0,95	0,98	0,98
Plastik	0,61	0,28	0,81	0,35	0,93	0,89
Çıplak Toprak	0,67	0,53	0,76	0,59	0,93	0,85
Yol	0,85	0,82	0,85	0,85	0,95	0,98
Parlak Nesne	0,86	0,67	0,95	0,60	1,00	0,83
Su	1,00	0,99	0,99	0,99	1,00	1,00
GD (%)	85,53		86,84		96,89	
κ	83,02		84,53		96,36	



Şekil 8. WHU-Hi HanChuan veri seti için (a) gerçek renkli görüntü, (b) DVM, (c) RO ve (d) ESA için sınıflandırma haritaları.



Şekil 9. Görsel yorumlama sonucunda sınıflandırma haritalarında yüksek farklılığın tespit edildiği alanlar; (a) renkli görüntü, (b) DVM, (c) RO ve (d) ESA için sınıflandırma haritaları.

Kullanılan veri seti ve sınıflandırma algoritmalarının sonuçlarının istatistiksel karşılaştırması McNemar testi kullanılarak yapılmıştır (Çizelge 6). Elde edilen sonuçlar incelendiğinde tüm karşılaştırma değerlerinin kritik tablo değeri olan $\chi^2=3,841$ değerinden büyük olduğu görülmektedir. Buradan yola çıkılarak, hesaplanan doğruluk değerleri arasındaki farklılığın istatistiksel olarak anlamlı olduğu söylenebilir.

Çizelge 6. McNemar test sonuçları.

Model 1 – Model 2	HyRANK Loukia	Chikusei	WHU-Hi HanChuan
DVM – RO	9,381	113,188	511,022
DVM – ESA	270,492	135,434	22638,348
RO – ESA	342,246	381,030	19751,364

Sınıflandırma algoritmalarının veri setlerine göre eğitim ve sınıflandırma aşamalarındaki işlem süreleri Çizelge 7’de verilmiştir. Tablodaki eğitim değerlerine DVM ve RO algoritmaları için parametre arama süreci de dahildir. Veri setlerinin boyutları da göz önünde bulundurularak elde edilen işlem süreleri incelendiğinde konumsal çözünürlük arttıkça algoritma bazında işlem süresinin de arttığı söylenebilir. Ancak işlem süreleri genel olarak değerlendirildiğinde belirli bir algoritmanın kesin olarak daha az işlem süresi gerektirdiği yorumu yapılamamıştır.

Çizelge 7. Sınıflandırma algoritmalarının eğitim ve sınıflandırma için hesaplanan işlem süreleri (saniye).

HSG	Süre Türü (s)	DVM	RO	ESA
HyRANK Loukia	Eğitim	4,16	14,97	21,39
	Sınıflandırma	5,89	2,73	11,65
Chikusei	Eğitim	86,75	64,55	97,59
	Sınıflandırma	186,26	199,14	271,63
WHU-Hi HanChuan	Eğitim	1250,95	337,46	314,40
	Sınıflandırma	108,25	55,62	15,58

4. Tartışma ve Sonuç

Bu çalışmada, çeşitli hava platformlarından elde edilen hiperspektral görüntülerin sınıflandırılmasında üç farklı MÖ algoritmasının sınıflandırma performansları kıyaslanmıştır. Bu kapsamda HyRANK Loukia, Chikusei ve WHU-Hi HanChuan HSG veri setleri kullanılmıştır. Görüntülerin sınıflandırılmasında DVM, RO ve ESA algoritmaları kullanılmıştır. Verilerin hazırlanması aşamasında HSG’lerin yüksek spektral boyutunu

azaltmak için TBA dönüşümü uygulanarak her görüntü için ilk 15 temel bileşen görüntü bandı olarak kullanılmıştır. Algoritmaların eğitimi esnasında DVM ve RO’nun kullanıcı tanımlı parametrelerinin belirlenmesi için çapraz doğrulama metodu kullanılmıştır.

Sınıflandırma performansları incelendiğinde HyRANK Loukia için elde edilen doğruluk değerlerinin diğer veri setlerinden daha düşük olduğu görülmüştür. Bu durumun düşük konumsal çözünürlük, yetersiz sayıda yer doğrulama verisi, sınıfların benzer spektral karakteristikleri ve karışık piksel sorunundan kaynaklandığı söylenebilir. Literatürdeki bazı çalışmalarda da (Christovam *et al.* 2019, Si *et al.* 2021) bazı sınıflar için düşük doğruluk değerleri hesaplanmıştır. Yine de bu sınıflar için ESA’nın DVM ve RO’ya göre üstün başarı gösterdiği söylenebilir. Chikusei veri seti için tüm algoritmalar için yüksek doğruluk değerleri elde edilmiştir. Yalnızca Çıplak Toprak (Park) sınıfında DVM ve RO algoritmaları için çok daha düşük ÜD ve KD değerleri hesaplanmıştır. WHU-Hi HanChuan veri seti için hesaplanan doğruluk değerleri incelendiğinde ESA algoritmasının daha yüksek genel doğruluğa sahip olduğu görülmüştür. Sınıf bazında inceleme yapıldığında yine ESA algoritmasının başta Su İspanağı, Karpuz ve Çim sınıfları olmak üzere sınıf bazında daha yüksek başarı oranına sahip olduğu görülmüştür.

Genel bir değerlendirme yapılacak olursa, ESA, görüntüler üzerinden bilgileri öğrenirken parametre sayısını ve genel karmaşıklığı azaltmak için diğer algoritmaların kullanmadığı uzamsal bilgileri kullanması sayesinde HSG gibi büyük ve karmaşık verilerin sınıflandırılmasında üstünlük sağlamaktadır. Sınıflandırma haritaları incelendiğinde ESA’nın sınıflandırma haritalarının daha yüksek doğruluğa sahip olduğu görsel olarak da belirlenebilmektedir.

Tüm algoritmalar için elde edilen doğruluk değerleri McNemar testi kullanılarak incelenmiştir. Yapılan testin sonucunda elde edilen doğruluk değerleri arasındaki farkların istatistiksel olarak anlamlı olduğu tespit edilmiştir. Algoritmaların eğitim ve

sınıflandırma işlemleri esnasında gerektirdiği işlem süreleri incelendiğinde anlamlı bir örüntü tespit edilememiştir.

Teşekkür

Yazarlar HyRANK Benchmark veri setini sağlayan International Society for Photogrammetry and Remote Sensing, Commission III, WG III/4'e; Chikusei Hyperspectral Data veri setini sağlayan Dr. Naoto Yokoya'ya ve Prof. Akira Iwasaki'ye (University of Tokyo); WHU-Hi veri setini sağlayan Intelligent Data Extraction, Analysis and Applications of Remote Sensing (RSIDEA), State Key Laboratory of Information Engineering in Surveying, Mapping, and Remote Sensing (LIESMARS) ve Wuhan University'e teşekkür ederler. Bu çalışma Afyon Kocatepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 20.FEN.BİL.12 numaralı proje kapsamında desteklenmiştir.

5. Kaynaklar

- Adao T., Hruska J., Padua L., Bessa J., Peres E., Morais R. et al., 2017. Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote Sensing*, **9**(11), 1110.
- Akar O. and Tunc Gormus E., 2021. Land use/land cover mapping from airborne hyperspectral images with machine learning algorithms and contextual information. *Geocarto International*, **37**(14), 3963-3990.
- Ardouin J.P., Levesque J. and Rea T.A., 2007. A demonstration of hyperspectral image exploitation for military applications, *2007 10th International Conference on Information Fusion*, 1-8.
- Audebert N., Le Saux B. and Lefevre S., 2019. Deep learning for classification of hyperspectral data: A comparative review. *IEEE Geoscience and Remote Sensing Magazine*, **7**(2), 159-173.
- Bhosle K. and Musande V., 2020, Evaluation of CNN model by comparing with convolutional autoencoder and deep neural network for crop classification on hyperspectral imagery. *Geocarto International*, **1**(15), 813-827.
- Boser B.E., Guyon I.M. and Vapnik V.N., 1992. A training algorithm for optimal margin classifiers. *Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory*, 144-152.
- Breiman L., 2001. Random Forests. *Machine learning*, **45**(1), 5-32.
- Chan J.C.W. and Paelinckx D., 2008. Evaluation of Random Forest and Adaboost Tree-based Ensemble Classification and Spectral Band Selection for Ecotope Mapping Using Airborne Hyperspectral Imagery. *Remote Sensing of Environment*, **112**(6), 2999-3011.
- Chen S., Jin M. and Ding J., 2020. Hyperspectral remote sensing image classification based on dense residual three-dimensional convolutional neural network. *Multimedia Tools and Applications*, **80**(2), 1859-1882.
- Christovam L.E., Pessoa G.G., Shimabukuro M.H. and Galo M.L.B.T., 2019. Land use and land cover classification using hyperspectral imagery: evaluating the performance of spectral angle mapper, support vector machine and random forest. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 10-14 June 2019, Enschede, The Netherlands, 1841-1847.
- Congalton R.G. and Green K., 2019. Assessing the accuracy of remotely sensed data: principles and practices. CRC Press, 328, Boca Raton, FL.
- Crucil G., Castaldi F., Aldana-Jague E., van Wesemael B., Macdonald A. and Van Oost K., 2019. Assessing the performance of UAS-compatible multispectral and hyperspectral sensors for soil organic carbon prediction. *Sustainability*, **11**(7), 1889.
- Erturk A., Iordache M.D. and Plaza A., 2015. Sparse unmixing-based change detection for multitemporal hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **9**(2), 708-719.
- Foody G.M., 2004. Thematic map comparison. *Photogrammetric Engineering & Remote Sensing*, **70**(5), 627-633.
- Ghanbari H., Mahdianpari M., Homayouni S. and Mohammadimanesh F., 2021. A meta-analysis of convolutional neural networks for remote sensing applications. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **14**, 3602-3613.
- Ghatak A., 2019. Deep Learning with R, Springer, 245, Kolkata.
- Gualtieri J.A. and Crompton R.F., 1999. Support vector machines for hyperspectral remote sensing classification. *27th AIPR Workshop: Advances in Computer-Assisted Recognition, Washington DC*, 221-232.
- Guo Y., Liu Y., Oerlemans A., Lao S., Wu S. and Lew M.S., 2016. Deep Learning for Visual Understanding: A Review. *Neurocomputing*, **187**, 27-48.
- Hang R., Li Z., Liu Q., Ghamisi P. and Bhattacharyya S.S., 2020. Hyperspectral Image Classification with Attention Aided CNNs. *arXiv preprint arXiv:2005.11977*.
- Heiden U., Heldens W., Roessner S., Segl K., Esch T. and Mueller A., 2012. Urban structure type characterization using hyperspectral remote sensing and height information. *Landscape and urban Planning*, **105**(4), 361-375.
- Hsu C.W., Chang C.C. and Lin C.J., 2003. A practical guide to support vector classification. Taipei, Taiwan.
- Jordan M.I. and Mitchell T.M., 2015. Machine learning: trends, perspectives, and prospects. *Science*, **349**(6245), 255-260.
- Karantzalos K., Karakizi C., Kandylakis Z. and Antoniou G., 2018. HyRANK Hyperspectral Satellite Dataset I (Version v001).

- Kavzoglu T. and 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.
- Kavzoglu T., Tonbul H., Yildiz Erdemir M. and Colkesen I., 2018. Dimensionality reduction and classification of hyperspectral images using object-based image analysis, *Journal of the Indian Society of Remote Sensing*, **46**(8), 1297-1306.
- Krizhevsky A., Sutskever I. and Hinton G.E., 2012. ImageNet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, Lake Tahoe, Nevada*, 1097-1105.
- LeCun Y., Bengio Y. and Hinton G., 2015. Deep learning. *Nature*, **521**(7553), 436-444.
- LeCun Y., Bottou L., Bengio Y. and Haffner P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86**(11), 2278-2324.
- Li Y., Zhang H., Xue X., Jiang Y. and Shen Q., 2018. Deep learning for remote sensing image classification: a survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, **8**(6), e1264.
- Loggenberg K., Strever A., Greyling B. and Poona N., 2018. Modelling water stress in a Shiraz vineyard using hyperspectral imaging and machine learning. *Remote Sensing*, **10**(2), 202.
- Lu G. and Fei B., 2014. Medical hyperspectral imaging: a review. *Journal of Biomedical Optics*, **19**(1), 010901.
- Luo Y., Zou J., Yao C., Zhao X., Li T. and Bai G., 2018. HSI-CNN: a novel convolution neural network for hyperspectral image. *2018 International Conference on Audio, Language and Image Processing (ICALIP), Beijing*, 464-469.
- Meng Z., Zhao F., Liang M. and Xie W., 2021. Deep residual inconvolution network for hyperspectral image classification. *Remote Sensing*, **13**(16), 3055.
- Mountrakis G., Im J. and Ogole C., 2011. Support vector machines in remote sensing: a review, *ISPRS Journal of Photogrammetry and Remote Sensing*, **66**(3), 247-259.
- Pal M., 2005. Random forest classifier for remote sensing classification. *International Journal of remote sensing*, **26**(1), 217-222.
- Pal M. and Mather P., 2005. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, **26**(5), 1007-1011.
- Rodriguez-Galiano V.F., Ghimire B., Rogan J., Chica-Olmo M. and 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.
- Roy S.K., Krishna G., Dubey S.R. and Chaudhuri B.B., 2019. HybridSN: exploring 3-d-2-d cnn feature hierarchy for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, **17**(2), 277-281.
- Sahin E.K., Colkesen I. and Kavzoglu T., 2020. A comparative assessment of canonical correlation forest, random forest, rotation forest and logistic regression methods for landslide susceptibility mapping. *Geocarto International*, **35**(4), 341-363.
- Salami E., Barrado C. and Pastor E., 2014. UAV flight experiments applied to the remote sensing of vegetated areas. *Remote Sensing*, **6**(11), 11051-11081.
- Sheykhmousa M., Mahdianpari M., Ghanbari H., Mohammadimanesh F., Ghamisi P. and Homayouni S., 2020. Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **13**, 6308-6325.
- Si Y., Gong D., Guo Y., Zhu X., Huang Q., Evans J. et al., 2021. An advanced spectral-spatial classification framework for hyperspectral imagery based on DeepLab v3+. *Applied Sciences*, **11**(12), 5703.
- Sunar F., Özkan C. ve Osmanoğlu B., 2011. Uzaktan Algılama. Anadolu Üniversitesi Yayınları, 210, Eskişehir.
- Teke M., Devenci H.S., Haliloğlu O., Gürbüz S.Z. ve Sakarya U., 2013. A short survey of hyperspectral remote sensing applications in agriculture. *2013 6th International Conference on Recent Advances in Space Technologies (RAST)*, 171-176.
- Van der Meer F.D., Van der Werff H.M., Van Ruitenbeek F.J., Hecker C.A., Bakker W.H., Noomen M.F. et al., 2012. Multi-and hyperspectral geologic remote sensing: A review. *International Journal of Applied Earth Observation and Geoinformation*, **14**(1), 112-128.
- Vapnik V., 1995. The nature of statistical learning theory, Springer - Verlag, 188, New York.
- Wang Y., Li Y., Song Y. and Rong X., 2020. The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, **10**(5), 1897.
- Waske B., Benediktsson J.A., Arnason K., Sveinsson J.R., 2009. Mapping of hyperspectral AVIRIS data using machine-learning algorithms. *Canadian Journal of Remote Sensing*, **35**(sup1), 106-116.
- Xia J., Yokoya N. and Iwasaki A., 2016. Hyperspectral image classification with canonical correlation forests. *IEEE Transactions on Geoscience and Remote Sensing*, **55**(1), 421-431.
- Yokoya N. and Iwasaki A., 2016. Airborne hyperspectral data over Chikusei. *Space Appl. Lab., Univ. Tokyo, Tokyo, Japan, Tech. Rep. SAL-2016-05-27*, 5.
- Zhong Y., Hu X., Luo C., Wang X., Zhao J. and Zhang L., 2020. WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF, *Remote Sensing of Environment*, **250**, 112012.