



3 Boyutlu Evrişimsel Sinir Ağı Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması

Hüseyin FIRAT^{1*}, Davut HANBAY²

¹ Dicle Üniversitesi, Teknik Bilimler MYO, Bilgisayar Teknolojileri Bölümü, Diyarbakır, Türkiye

² İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Malatya, Türkiye

Hüseyin FIRAT ORCID No: 0000-0002-1257-8518

Davut HANBAY ORCID No: 0000-0003-2271-7865

*Sorumlu yazar: huseyin.firat@dicle.edu.tr

(Alınış: 5.04.2021 Kabul: 25.05.2021, Online Yayınlanma: 25.03.2022)

Anahtar Kelimeler

Hiperspektral görüntü sınıflandırma, Derin öğrenme, 2B ESA, 3B ESA

Öz: Hiperspektral görüntü sınıflandırma, uzaktan algılanan görüntülerin analizi için yaygın olarak kullanılmaktadır. Bir hiperspektral görüntü, uygulamalarda büyük potansiyele sahip olan yer nesnelerinin zengin spektral bilgilerini ve uzamsal bilgilerini içermektedir. Spektral uzamsal bilgi kullanımı hiperspektral görüntü sınıflandırmasının performansını önemli ölçüde arttırmaktadır. Hiperspektral görüntüler, 3B küpler biçiminde gösterilmektedir. Bu nedenle, 3B uzamsal filtreleme, bu tür görüntülerdeki spektral uzamsal özellikleri eşzamanlı olarak çıkarmak için doğal olarak basit ve etkili bir yöntem sunmaktadır. Bu çalışmada, hiperspektral görüntü sınıflandırması için bir 3B evrişimli sinir ağı (3B ESA) yöntemi önerilmiştir. Önerilen yöntem, derin spektral uzamsal birleştirilmiş özellikleri etkin bir şekilde çıkarmaktadır. Aynı zamanda herhangi bir ön işleme veya son işleme dayanmadan hiperspektral görüntü küpü verileri toplu olarak görüntülemektedir. Hiperspektral görüntü küpü önce küçük üst üste binen 3B parçalara bölünmektedir. Daha sonra bu parçalar, spektral bilgileri de koruyan birden çok bitişik bant üzerinde bir 3B çekirdek işlevi kullanarak 3B özellik haritaları oluşturmak için işlenmektedir. Önerilen yöntem Indian pines, Pavia üniversitesi ve Botswana veri setleri ile test edilmiştir. Deneysel çalışmalar sonucunda, Indian pines için %99,35, Pavia üniversitesi için %99,90 ve Botswana için ise %99,59 genel doğruluk sonuçları elde edilmiştir. Sonuçlar, 4 farklı derin öğrenme tabanlı yöntemle karşılaştırılmıştır. Deneysel sonuçlardan, önerilen 3B ESA yöntemimizin daha iyi performans gösterdiği görülmektedir.

Classification of Hyperspectral Images Using 3D Convolutional Neural Network

Keywords

Hyperspectral image classification, Deep learning, 2D CNN, 3D CNN

Abstract: Hyperspectral image classification is commonly used for the analysis of remotely sensed images. A hyperspectral image contains rich spectral and spatial information of ground objects that has great potential in applications. The use of spectral spatial information significantly improves the performance of hyperspectral image classification. Hyperspectral images are shown as 3D cubes. Therefore, 3D spatial filtering offers an inherently simple and effective method to simultaneously extract spectral spatial features in such images. In this study, a 3D convolutional neural network (3D CNN) method is proposed for hyperspectral image classification. The proposed method effectively extracts deep spectral spatially combined features. At the same time, the hyperspectral image cube displays data in aggregate without relying on any pre-processing or post-processing. The hyperspectral image cube is first divided into small overlapping 3D patches. Then these patches are processed to create 3D feature maps using a 3D kernel function on multiple adjacent bands that also preserve spectral information. The proposed method was tested with Indian pines, Pavia university and Botswana datasets. As a result of the experimental studies, the overall accuracy results were obtained 99.35% for Indian pines, 99.90% for the University Pavia, and 99.59% for Botswana. The results were compared with 4 different deep learning-based methods. From the experimental results, it is seen that our proposed 3D CNN method performs better.

1. GİRİŞ

Hiperspektral uzak sensörler, elektromanyetik spektrumun yüzlerce sürekli ve dar bant genişliğinde dijital görüntüler yakalayarak hem spektral hem de uzamsal bilgileri içeren 3 boyutlu hiperspektral görüntüler üretmektedir [1]. Hiperspektral görüntülerin zengin spektral bilgileri güçlüdür. Bu nedenle, tarım, astronomi, madencilik, nesne tespiti, askeri gözetim, çevre bilimleri, arazi yangın takibi ve biyolojik tehdit tespiti gibi bir dizi uygulamada yaygın olarak kullanılmaktadır [2, 3]. Hiperspektral görüntülerde, her pikselin sınıflandırılması bu uygulamalarda çok önemli rol oynamaktadır. Bu nedenle, son yıllarda çok sayıda hiperspektral görüntü sınıflandırma yöntemi önerilmiştir. Geleneksel hiperspektral görüntü sınıflandırma yöntemleri genellikle yalnızca spektral bilgilere dayanmaktadır. Bu sınıflandırıcılar arasında k-en yakın komşu [4], lojistik regresyon [5], destek vektör makinesi [6], rastgele orman [7] ve maksimum olabilirlik kriteri [8] temelli sınıflandırıcılar bulunmaktadır. Bu sınıflandırıcılar, spektral fazlalık ve spektral bantlar arasındaki yüksek korelasyon nedeniyle iyi performans gösterememektedir. Ayrıca, bu sınıflandırıcılar hiperspektral görüntülerin önemli uzamsal değişkenliğini korumada başarısız olmaktadır. Bu da düşük performansla sonuçlanmaktadır. Sınıflandırma performansını iyileştirmenin en basit yolu hem spektral hem de uzamsal bilgileri içeren bir sınıflandırıcı tasarlamaktır. Uzamsal bilgi, farklı yapıların şekli ve boyutu ile ilgili ek ayırt edici bilgiler sağlamaktadır. Bu durum uygun şekilde kullanılırsa daha doğru sınıflandırma haritalarına yol açmaktadır. Spektral uzamsal sınıflandırma yöntemleri genel olarak iki kategoriye ayrılabilir. İlki, spektral ve uzamsal özellikleri ayrı ayrı incelemektedir. Başka bir deyişle, uzamsal özellikler, morfolojik işlemler [9], entropi [10], öznelik profilleri [11] ve düşük dereceli temsil [12] gibi çeşitli uzamsal filtreler aracılığıyla önceden çıkarılmaktadır. Daha sonra bu uzamsal özellikler, piksel düzeyinde sınıflandırmayı gerçekleştirmek için spektral özelliklerle birleştirilmektedir. İkinci kategori, ortak özellikler üretmek için genellikle uzamsal özellikleri spektral özelliklerle birleştirmektedir. Örneğin, farklı ölçek ve frekanslarda üretilen bir dizi 3D dalgacık filtresi [13], 3D Gabor filtresi [14] ve 3D saçılım dalgacık filtresi [15], ortak spektral-uzamsal özellikleri çıkarmak için hiperspektral görüntüye uygulanmaktadır. Hiperspektral görüntüler 3B küpler halinde gösterildiğinden dolayı, ikinci yaklaşım türü daha iyi performans için gerekli olan ortak uzamsal spektral korelasyonu koruyarak daha iyi sonuçlar üretebilmektedir. Bununla birlikte, geleneksel özellik çıkarma yöntemlerinin çoğu, el yapımı özelliklere ve derin olmayan öğrenme modellerine dayanmaktadır. Bu durum sınırlı özellik çıkarma ile sonuçlanmaktadır.

Derin öğrenme tekniklerindeki ilerleme, hiperspektral görüntü sınıflandırmasını yeni bir aşamaya taşımaktadır. Derin öğrenme yönteminin eğitim aşaması, özellikleri otomatik olarak çıkarmakta ve bunları sınıflandırma aşamasında kullanmaktadır. Destek vektör makinesi ve rastgele orman gibi geleneksel hiperspektral görüntü

sınıflandırma yöntemleri, uzamsal özellikleri göz ardı ederken hiperspektral görüntülerin spektral özelliklerini çıkarmaya odaklanmıştır. Tipik bir derin öğrenme modeli olarak, yığılı otokodlayıcı [16] ve derin inaç ağı [17] hem uzamsal hem de spektral bilgiyi çıkarabilmekte ve daha sonra bunları hiperspektral görüntü sınıflandırması için birleştirebilmektedir. Bununla birlikte, yukarıdaki derin öğrenme yöntemlerinin ikisi de girdi olarak tek boyutlu özellik vektörlerini kullanmaktadır. Bu durumda hiperspektral görüntülerdeki uzamsal özellikler tam olarak kullanılmamaktadır. Hiperspektral görüntü sınıflandırma için en sık kullanılan derin öğrenme yöntemlerinden biri de evrişimsel sinir ağlarıdır. Du, Mao ve ark. [18, 19], hiperspektral görüntü sınıflandırması için evrişimsel sinir ağını kullanmıştır. Bu çalışmada, uzamsal özellikler orijinal hiperspektral görüntülerinin ilk birkaç temel bileşen bantlarından yararlanılarak bir 2 boyutlu evrişimsel sinir ağı modeli ile elde edilmiştir. Evrişimsel sinir ağı tabanlı modeller, yığılı otokodlayıcı ve derin inaç ağı modellerine göre gelişmiş sınıflandırma performansı elde edebildiği gösterilen yerel özellikleri tespit etme yeteneğine sahiptir. Ancak, 2 boyutlu evrişimsel sinir ağında (2B ESA), uzamsal ve spektral özellikler genellikle ayrı ayrı çıkarılmaktadır. Bu işlem spektrumdaki bazı ayrıntıları kaybedecek ve bu yöntemlerin farklı nesnelere ayırt etme kapasitesini azaltacaktır. Aynı zamanda, sınıflandırma için önemli olabilecek ortak uzamsal spektral korelasyon bilgilerinden tam olarak yararlanmayı geçersiz kılacaktır. Yani, 2B ESA, spektral boyutlardan iyi ayırt edici özellik haritalarını çıkaramamaktadır.

Bu çalışmada, hiperspektral görüntü sınıflandırması için 3 boyutlu evrişimsel sinir ağı (3B ESA) modeli önerilmektedir. 3B ESA, 3B hiperspektral görüntüye 3B çekirdek uygulayarak, özellik küplerinin hem uzamsal hem de spektral boyutlarındaki yerel sinyal değişikliklerini öğrenebilmektedir. Bu sayede, sınıflandırma için önemli ayırt edici bilgilerden faydalanılmaktadır. Spektral ve uzamsal özellikler eşzamanlı olarak çıkarıldığından, bu çalışma 3B hiperspektral görüntü verilerinin yapısal özelliklerinden tam olarak yararlanmaktadır. Önerilen 3B ESA yöntemi, girdi olarak tüm spektral bantları almaktadır. Herhangi bir ön işlem veya son işlem gerektirmemektedir. Ortaya çıkan derin sınıflandırıcı modeli, uçtan uca bir şekilde eğitilmektedir. Aynı ölçekte, önerilen 3B ESA diğer derin öğrenme tabanlı yöntemlerden daha az parametre içermektedir. Bu, tipik olarak eğitim örneklerine sınırlı erişimi olan hiperspektral görüntü sınıflandırma problemleri için daha uygundur. 3B ESA tabanlı yöntem ile farklı uzak sensörler tarafından yakalanan üç farklı hiperspektral görüntü veri seti üzerinde deneyler gerçekleştirilmiştir. Deneysel sonuçlar literatürdeki farklı derin öğrenme tabanlı tekniklerle karşılaştırılmıştır. Elde edilen deneysel sonuçlar ile önerilen 3B ESA yönteminin karşılaştırılan yöntemlerden daha iyi performans gösterdiği görülmektedir.

Bu çalışmada önerilen yöntemin teorik alt yapısını oluşturan evrişimsel sinir ağı modeli Bölüm 2'de ve

önerilen yöntem Bölüm 3'te anlatılmıştır. Bölüm 4'te kullanılan veri setleri ve deneysel sonuçlar verilmiştir. Bölüm 5'de ise sonuçlar tartışılmıştır.

2. EVRİŞİMSEL SİNİR AĞI (ESA)

Görüntü sınıflandırması için derin öğrenme teknikleri son zamanlarda yaygın olarak kullanılmaktadır. ESA, evrişim katmanı, havuzlama katmanı ve tamamen bağlı katmandan oluşan çok katmanlı bir sinir ağıdır. Evrişim katmanı, giriş verileri üzerinde evrişim işlemi gerçekleştiren ESA'nın temel parçasıdır. Evrişim, iki matris, yani alıcı alan (receptive field) ve çekirdek (kernel) arasındaki bir iç çarpım işlemidir. Genel olarak, çekirdek uzamsal olarak giriş verilerinden daha küçüktür. Çekirdek alıcı alan üzerinde kaymakta ve giriş verilerinin bir özellik haritasını oluşturmaktadır. Havuzlama katmanı, özellik haritasının uzamsal boyutunu azaltmaktadır. Bir dizi çıktıyı, yakındaki özellik değerlerinin istatistiklerine göre tek bir değerle değiştirmektedir. En yaygın kullanılan havuzlama tekniği maksimum havuzlamadır ve bir dizi özelliği maksimum değeriyle değiştirmektedir. Tamamen bağlı katman, tüm nöronların birbirini takip eden her katman nöronuna bağlandığı çok katmanlı bir algılayıcıdır. Bu katman, özellikleri çıktıya haritalamak için kullanılmaktadır [20]. x girdileri için tek nöronun çıktısı (y) Eşitlik 1.'deki gibi hesaplanmaktadır.

$$y = f(w * x + b) \quad (1)$$

Eşitlik 1.'de, w filtre ağırlığı ve b ise bias değeridir. $f(\cdot)$, ağırlıklı bir girdi toplamına uygulanan doğrusal olmayan aktivasyonu ifade etmektedir. 2B ESA modeli, giriş verilerini etkinleştirmeden önce iki boyutlu bir çekirdek kullanarak evrişim işlemini gerçekleştirmektedir. Bu, giriş görüntüsünden uzamsal özellikleri çıkarmaya yardımcı olmaktadır. Her nöronun 2B evrişim çıktısı için Eşitlik 1. yeniden Eşitlik 2.'deki gibi formüle edilmektedir [20].

$$y_{mn} = f \left(\sum_r \sum_{i=0}^{h-1} \sum_{j=0}^{w-1} k_{ij} x_{(i+m)(j+n)} + bias_{mn} \right) \quad (2)$$

Eşitlik 2.'de y_{mn} , (m, n) konumunda çıkarılan özelliştir. k , $h \times w$ boyutundaki 2B evrişim çekirdeğidir. 2B görüntü olması durumunda, bu evrişim işlemi, alıcı alandaki tüm özellik haritalarını (r) üzerinde gerçekleştirilmekte ve doğrusal olmayan aktivasyon için tüm değerlerin toplamını almaktadır. Bu işlem, çok boyutlu veriler durumunda tüm katmanlar için tekrarlanmaktadır. Veriler üç boyutlu olduğunda (örneğin, video, renkli görüntüler, hiperspektral veya multispektral görüntüler), bunların hem uzamsal hem de spektral veya zamansal boyutları vardır. Bu giriş verileri için 2B evrişim başarısız olmaktadır. Çünkü, geleneksel 2B ESA'da, evrişim işlemleri yalnızca uzamsal boyuttaki özellikleri yakalayan 2B özellik haritalarına uygulanmaktadır. 3B ESA, 2B ESA'da 2B evrişim yerine üç boyutlu evrişim gerçekleştiren 2B ESA modellerinin değiştirilmiş şeklidir. Evrişim işlemleri, 3B verilere uygulandığında hem uzamsal hem de spektral

boyutlardan özelliklerin yakalanması istenilmektedir. Bu amaçla, 3B giriş verilerinden ortak uzamsal spektral özellikleri hesaplamak için 3B evrişim işlemlerinin 3B özellik küplerine uygulandığı 3B ESA önerilmektedir. 3B evrişim, üç boyutlu spektral görüntülerden hem uzamsal hem de spektral özelliklerin çıkarılmasına yardımcı olmaktadır. 3B ESA modelinden çıkarılan özellik Eşitlik 3.'teki gibi formüle edilmektedir [20].

$$y_{mnp} = f \left(\sum_r \sum_{i=0}^{h-1} \sum_{j=0}^{w-1} \sum_{l=0}^{b-1} k_{ijl} x_{(i+m)(j+n)(l+p)} + bias_{mnp} \right) \quad (3)$$

Eşitlik 3.'te y_{mnp} , (m, n, p) konumunda çıkarılan özelliştir. b spektral boyut boyunca 3B çekirdeğin boyutudur. Çekirdek (k), üç boyutludur ve özellikler, 3B giriş verileri üzerinde 3B evrişim gerçekleştirilerek hesaplanmaktadır. Evrişimli sinir ağına en sık kullanılan aktivasyon fonksiyonu $f(\cdot)$ ReLU'dur. ReLU, eğitim için gradyan iniş tekniklerini kullanırken diğer aktivasyon işlevlerinden daha hızlıdır. ReLU Eşitlik 4.'teki gibi formüle edilmektedir.

$$ReLU(y) = \max(0, y) \quad (4)$$

Softmax, sınıflandırma için bir derin öğrenme modelinin son katmanında genellikle kullanılan başka bir etkinleştirme işlevidir. Softmax, tüm örneklerin olasılık dağılımını üretmekte ve toplamı bire eşittir. Eğitim verilerini kullanarak ağırlıkları güncellemek için ESA'da farklı optimizasyon teknikleri kullanılmaktadır. En yaygın kullanılan optimizasyon gradyan iniş tekniğidir. Adam (uyarlanabilir momentum tahmini), genellikle konveks olmayan problemler için kullanılan başka bir optimize edicidir. Adam, birinci ve ikinci gradyan momentine bağlı olarak ağıdaki her ağırlık değeri için ayrı bir öğrenme oranı sağlar. Adam optimizer'da kullanılan parametreler öğrenme hızı (lr), beta1 ve beta2 'dir. beta1 ve beta2 , sırasıyla birinci ve ikinci momentlerin üstel azalmasıdır [21]. Özetle, hiperspektral görüntü sınıflandırması için, 2B evrişim işlemi giriş verilerini uzamsal boyutta evrişim işlemine tabi tutarken, 3B evrişim işlemi giriş verilerini hem uzamsal hem de spektral boyutta eş zamanlı olarak evrişim işlemine tabi tutmaktadır. 2B evrişim işlemi ister 2B veriye ister 3B veriye uygulanıp uygulanmadığına bakılmaksızın, çıktısı 2B'dir. Hiperspektral görüntüye 2B evrişim işlemleri uygulandıysa, önemli spektral bilgiler kaybedilirken, 3B evrişim giriş hiperspektral görüntü verilerinin spektral bilgilerini koruyarak bir çıktı hacmi elde edebilmektedir. Bu, zengin spektral bilgi içeren hiperspektral görüntüler için çok önemlidir.

3. ÖNERİLEN YÖNTEM

Geleneksel bir 2B ESA, genellikle evrişimli katmanlardan, havuz katmanlarından ve tamamen bağlantılı katmanlardan oluşmaktadır. 2B ESA'dan farklı olarak, bu çalışmada, hiperspektral görüntü sınıflandırması için önerilen 3B ESA, yalnızca evrişim

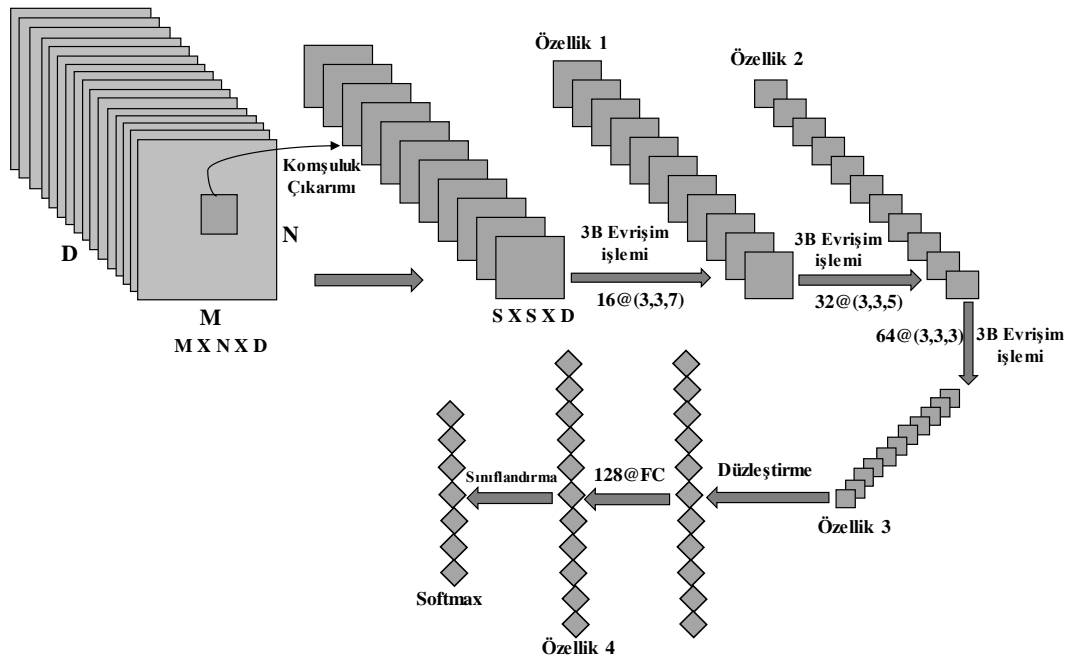
katmanlarından, düzleştirme ve tamamen bağlantılı bir katmandan oluşmaktadır. Hiperspektral görüntülerde uzamsal çözünürlüğü azaltılmasıyla bilinen havuzlama işlemleri önerilen yöntemde uygulanmamaktadır. Önerilen 3B ESA modeli piksel düzeyinde hiperspektral görüntü sınıflandırması için kullanılmaktadır. Spektral uzamsal özellikleri öğrenmek için 3B çekirdeklerle evrişim işlemine tabi tutulmak üzere girdi verileri olarak tüm spektral bantlar boyunca küçük bir uzamsal komşulukta (tüm görüntü değil) piksellerden oluşan görüntü küpleri çıkarılmaktadır. Hiperspektral görüntü X , $M \times N \times D$ boyutunda 3 boyutlu bir küp olarak belirtilmiştir. Burada M ve N , görüntünün uzamsal genişliği ve yüksekliğidir. D ise, spektral bantların sayısını belirtir. Görüntü sınıflandırma tekniklerini kullanmak için, hiperspektral veri küpü, merkezi piksele dayalı gerçek etiketlerin oluşturulduğu küçük üst üste binen 3B uzamsal parçalara bölünmüştür. Uzamsal konumda (a,b) merkezlenmiş ve $S \times S$ penceresini veya uzamsal boyutu ve tüm D spektral bantlarını kapsayan hiperspektral veri küpünden 3B komşu parçaları $S \times S \times D$ oluşturuldu. Hiperspektral veri küpünden üretilen toplam 3B parça sayısı (n), $(M - S + 1) \times (N - S + 1)$ ile bulunur. 3B ESA, 3B evrişim çekirdeğini kullanarak her bir görüntü parçasını 3B evrişim işlemine tabi tutar. Hiperspektral görüntü verileri için önerilen modelde, evrişim katmanının özellik haritaları, giriş katmanındaki çoklu bitişik bantlar üzerinde 3B çekirdek kullanılarak oluşturulur. Böylelikle hem uzamsal hem de spektral özelliklere sahip özellikler çıkarılmış olur. Evrişim işlemi uygulanmış özelliklere doğrusal olmayan bir etkinleştirme işlevi olan ReLU uygulanmaktadır.

Önerilen 3B ESA modelinin akış diyagramı Şekil 1'de gösterilmektedir. Önerilen 3B ESA modelinde üç 3B evrişim katmanı, düzleştirme ve tam bağlantılı bir katman bulunmaktadır. Herhangi bir ön işlem aşaması gerçekleştirilmemektedir. Uygulanan 3B evrişim çekirdeklerinin boyutları ve kullanılan filtreler şu şekildedir. 1. evrişimli katmanda $3 \times 3 \times 7$ (yani; iki

uzamsal ve bir spektral boyut) boyutunda 16 filtre, 2. evrişim katmanında $3 \times 3 \times 5$ boyutunda 32 filtre, 3. evrişim katmanında $3 \times 3 \times 3$ boyutunda 64 filtre kullanılmaktadır. ReLU aktivasyon fonksiyonu tüm evrişim katmanlarında kullanılmaktadır. 3B Evrişim katmanlarından sonra çıkarılan özellikler düzleştirilmektedir. Daha sonra sınıflandırma için tam bağlı katmanlara girdi olarak verilmektedir. Bu modelde, 128 nöron bulunan bir tane tam bağlantılı katman kullanılmaktadır. Tam bağlantılı katmanın (FC) çıktısı, gerekli sınıflandırma sonucunu oluşturmak için basit softmax sınıflandırıcıya verilmektedir. Önerilen model için her katmanda kullanılan çıktı boyutu ve parametre sayısı Tablo 1'de gösterilmektedir. Önerilen modelde, 1.yoğun katmanda en fazla sayıda parametrenin mevcut olduğu görülebilmektedir. Son yoğun katmandaki düğüm sayısı, pavia üniversitesi veri setindeki sınıfların sayısı ile aynı olan 9'dur. Dolayısıyla, önerilen modeldeki toplam parametre sayısı, bir veri setindeki sınıfların sayısına bağlıdır. Pavia üniversitesi veriseti için önerilen yöntemdeki toplam eğitilebilir ağırlık parametresi sayısı 875,369'dur. 0,001 öğrenme oranına sahip kategorik çapraz entropi ve optimizasyon için kullanılan 1e-06 bozunma işlevine sahip Adam optimizyer kullanılmıştır. Eğitim süreci, herhangi bir toplu normalleştirme (batch normalization) ve veri arttırma (data augmentation) olmaksızın 256 batch size 300 döngü (epochs) boyunca tekrar etmektedir.

Tablo 1. Pavia Üniversitesi veriseti için önerilen 3B ESA modelinin özeti

Katman (Tip)	Çıkış Boyutu	Parametre Sayısı
input_1 (Giriş katmanı)	(5,5,103,1)	0
conv3d_1 (Conv3d)	(5,5,103,16)	1024
conv3d_2 (Conv3d)	(3,3,99,32)	23072
conv3d_3 (Conv3d)	(1,1,97,64)	55360
flatten_1 (Flatten)	6208	0
dense_1 (Dense)	128	794752
dense_2 (Dense)	9	1161
Toplam Eğitilebilir Parametreler : 875,369		




Şekil 1. Hiperspektral görüntü sınıflandırması için önerilen 3B ESA modeli

4. DENEYSEL VERİSETLERİ VE SONUÇLAR

4.1. Verisetleri

Önerilen yöntemin etkinliğini göstermek için Indian Pines (IP), Pavia Üniversitesi (PU) ve Botswana (B) veri setlerini içeren üç gerçek hiperspektral veri seti kullanılmıştır [22]. IP veriseti, Kuzeybatı Indiana'daki Indian Pines test alanında Havadan Görünür / Kızılötesi Görüntüleme Spektrometresi (Airborne Visible/Infrared Imaging Spectrometer-AVIRIS) sensörü tarafından elde edilmiştir. Bu verisetindeki her spektral görüntü $145 \times$

145 uzamsal boyutundadır. Sensör, 0.4-2.5 mikrometre dalga boyu aralığında toplam 224 spektral bant elde etmiştir. Bu 224 banttan, 24 bant tam su absorpsiyonu (emme) bölgesindedir ve bunlar sınıflandırma işlemi için yararlı değildir. 24 su emme bandı çıkarıldıktan sonra kalan 200 bant deneyler için kullanılmıştır. Şekil 2'de Indian pines verisetinin sahte-renkli görüntüsü ve temel gerçek (ground truth) haritası gösterilmektedir. Tablo 2'de ise IP veri setinin 16 tür arazi örtüsü ve 10249 örnek içerdiği gösterilmektedir.



Şekil 2. Indian Pines veriseti. (a) Indian pines verisetinin sahte-renkli görüntüsü (b) Indian pines verisetinin temel gerçek (ground truth) haritası

Tablo 2. Indian pines veri seti için sınıflar ve örnek sayıları

Indian Pines (IP) Veriseti					
No.	Sınıf	Örnek Sayısı	No.	Sınıf	Örnek Sayısı
1	Alfalfa	46	9	Oats	20
2	Corn-notill	1428	10	Soybean-notill	972
3	Corn-mintill	830	11	Soybean-mintill	2455
4	Corn	237	12	Soybean-clean	593
5	Grass-pasture	483	13	Wheat	205
6	Grass-trees	730	14	Woods	1265
7	Grass-pasture-mowed	28	15	Buildings-Grass Trees-Drives	386
8	Hay-windrowed	478	16	Stone-Steel-Towers	93

PU veriseti, kuzeydoğu İtalya'daki Pavia Üniversitesi'nden Yansıtıcı Optik Sistem Görüntüleme Spektrometresi (Reflective Optics System Imaging Spectrometer - ROSIS) tarafından toplanan verilerdir. Veriseti, piksel başına 1.3 m uzamsal çözünürlükle 340 piksel genişliğinde ve 610 piksel yüksekliğindedir. 0.43 mikrometre ile 0.86 mikrometre arasında değişen 115 dalga boyuna sahiptir. 12 görüntü bandı çıkarıldıktan sonra, kalan 103 bant deneyde kullanılmıştır. PU veriseti 9 sınıfa ayrılmaktadır. Toplam 42776 örnek içermektedir. Şekil 3'de, PU verisetinin sahte-renkli

görüntüsü ve temel gerçek (ground truth) haritası gösterilmektedir. Ayrıca, PU veriseti için sınıflar ve bu sınıfların içerdiği örnek sayıları Tablo 3'te gösterilmektedir.



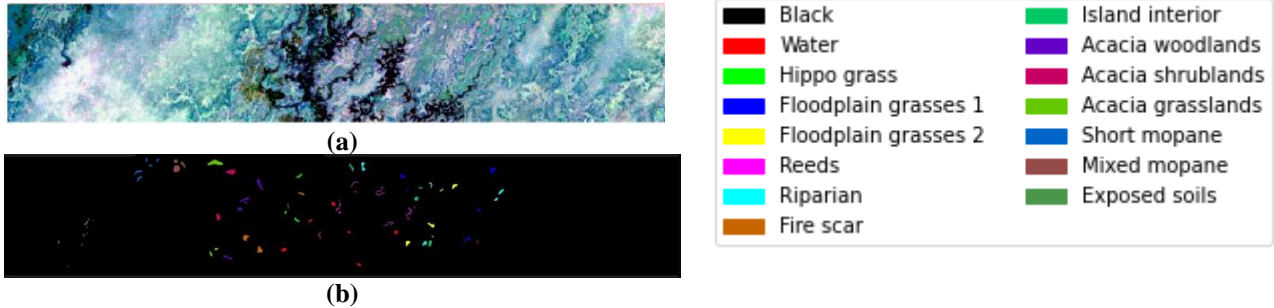
Şekil 3. Pavia üniversitesi veriseti. (a) Pavia üniversitesi verisetinin sahte-renkli görüntüsü (b) Pavia üniversitesi verisetinin temel gerçek (ground truth) haritası

Tablo 3. Pavia üniversitesi veri seti için sınıflar ve örnek sayıları

Pavia Üniversitesi (PU) Veriseti					
No.	Sınıf	Örnek Sayısı	No.	Sınıf	Örnek Sayısı
1	Asphalt	6631	6	Bare Soil	5029
2	Meadows	18649	7	Bitumen	1330
3	Gravel	2099	8	Self-Blocking Bricks	3682
4	Trees	3064	9	Shadows	947
5	Painted Metal Sheets	1345			

B veriseti, 2001 yılında Botswana, Okavango Deltası üzerinde EO-1 üzerinde Hyperion sensörü tarafından toplandı. Elde edilen veriler orijinal olarak 30 m piksel çözünürlüklü 10 nm pencerelerde spektrumun 400–2500 nm bölümünü kapsayan 242 banttan oluşuyordu. Kalibre edilmemiş (Ayarlanmamış) ve su emilimini örten gürültülü bantlar [10-55, 82-97, 102-119, 134-164, 187-220] çıkarıldıktan sonra deneylerde sadece 145 bant

kullanıldı. Kullanılan veriler, arazi örtüsü türlerini temsil eden 14 tanımlanmış sınıftan ve gözlemlerle 1476 x 256 pikselden oluşmaktadır. Toplam 3248 örnek içermektedir. Şekil 4'te, B verisetinin sahte-renkli görüntüsü ve temel gerçek (ground truth) haritası gösterilmektedir. B veriseti için sınıflar ve bu sınıfların içerdiği örnek sayıları ise Tablo 4'te gösterilmektedir.



Şekil 4. Botswana veriseti. (a) Botswana verisetinin sahte-renkli görüntüsü (b) Botswana verisetinin temel gerçek (ground truth) haritası

Tablo 4. Botswana veri seti için sınıflar ve örnek sayıları

Botswana (B) Veriseti					
No.	Sınıf	Örnek Sayısı	No.	Sınıf	Örnek Sayısı
1	Water	270	8	Island interior	203
2	Hippo grass	101	9	Acacia woodlands	314
3	Floodplain grasses 1	251	10	Acacia shrublands	248
4	Floodplain grasses 2	215	11	Acacia grasslands	305
5	Reeds	269	12	Short mopane	181
6	Riparian	269	13	Mixed mopane	268
7	Fire scar	259	14	Exposed soils	95

4.2. Deneysel Kurulum

Tüm deneyler Google Colab olarak bilinen çevrimiçi bir platformda gerçekleştirilmiştir. Google Colab, herhangi bir ortamı çalıştırmak için iyi bir internet hızı gerektiren çevrimiçi bir platformdur. Google Colab, kodların Tensör İşlem Birimi (TPU), 35 GB Rasgele Erişim Belleği (RAM) ve veri hesaplaması için 107,77 GB depolama alanı içeren python 3 masaüstü bilgisayarda

çalıştırılması için bir seçenek sunmaktadır. Tüm deneylerde, test-eğitim seti %30-70 oranına bölünmüştür. 0,001 öğrenme oranına sahip kategorik çaprazentropi ve optimizasyon için kullanılan 1e-06 bozunma işlevine sahip Adam optimizör kullanılmıştır. Eğitim süreci, 256 batch size ve 300 döngü (epochs) boyunca tekrar etmektedir. Softmax'ın kullanıldığı son katman hariç tüm katmanlar için bir aktivasyon işlevi olarak ReLU kullanılmaktadır. Üç verisetinin tümü,

evrişim için 5×5 komşuluk kullanılmaktadır. Herhangi bir ön işlem ve son işlem gerektirmemektedir. Tüm spektral bant alınarak işlemler gerçekleştirilmektedir. Her modelin sınıflandırma performansını değerlendirmek için genel doğruluk (GD), ortalama doğruluk (OD) ve kappa istatistiği (K) kullanılmıştır. GD, test verilerindeki doğru sınıflandırılmış örnekler ile toplam test örneği sayısı arasındaki oranla hesaplanmıştır. OD her kategorinin doğruluğunun ortalama değeridir. K, temel gerçek (ground truth) haritası ile sınıflandırma haritası arasında güçlü bir anlaşma ile ilgili karşılıklı bilgi sağlayan bir istatistiksel ölçüm metriğidir. GD, OD ve K ölçümlerinin yanı sıra, fl skoru (fl-score), hassasiyet (precision) ve geri çağırma (recall) gibi çeşitli istatistiksel testler de dikkate alınmaktadır.

4.3. Deneysel Sonuçlar

Önerilen 3B ESA yönteminin etkinliğini değerlendirmek için, dört derin öğrenme hiperspektral görüntü sınıflandırma yöntemiyle karşılaştırıldı: 3B ESA [1], DBN-LR [17], 2B ESA [19] ve SAE-LR [23]. 3B ESA, 2 tane 3B evrişim katmanı, tam bağlantılı katman ve sınıflandırma katmanından oluşmaktadır. 3B evrişim katmanlarının boyutları pavia üniversitesi için 2 adet $3 \times 3 \times 7$ ve 4 adet $3 \times 3 \times 3$ olarak alınmıştır. Pencere boyutu $S=5$ olarak ayarlanmıştır. Yani, orijinal spektral-uzamsal özellikleri hesaplamak için $5 \times 5 \times 103$ küplerini çıkarılmıştır. Daha sonra bu küpler 3B ESA için girdi olarak kullanılmıştır. Botswana veri seti için, 2 adet $3 \times 3 \times 2$ ardından 4 adet $3 \times 3 \times 2$ evrişim katmanı kullanılmıştır. Indiana pines veri seti için 2 adet $3 \times 3 \times 7$ ve 4 adet $3 \times 3 \times 3$ evrişim katmanı kullanılmıştır. SAE-LR, hiperspektral görüntülerin sınıflandırılması için yığılı otokodlayıcı ile lojistik regresyonun birlikte

kullanılmasını öneren yöntemdir. DBN-LR ise, derin inanç ağları ile lojistik regresyonun birlikte kullanılmasını öneren yöntemdir. SAE-LR ve DBN-LR için, orijinal hiperspektral görüntü, sırasıyla temel bileşen analizi yöntemiyle spektral boyut boyunca dört banda ve beş banda indirgenmiştir. Ardından, uzamsal özellikleri oluşturmak için $5 \times 5 \times 4$ küp ve $5 \times 5 \times 5$ küp kullanılmıştır. Son olarak, ortaya çıkan uzamsal özellikler spektral özellikler ile birleştirilmiştir. 2B ESA için, hiperspektral görüntü, temel bileşen analizi ile spektral boyut boyunca üç banda indirgenmiştir. Orijinal özellikleri oluşturmak için $42 \times 42 \times 3$ küp çıkarılmıştır. Ağ, üç evrişim katmanı ve iki havuzlama katmanı içermektedir. Üç evrişim katmanı sırasıyla birinci, ikinci ve üçüncü katmanlar için 36 adet 5×5 çekirdek, 72 adet 6×6 çekirdek ve 72 adet 4×4 çekirdek içermektedir.

Tablo 5, Pavia üniversitesi verisetinden elde edilen farklı yöntemlerin GD, OD ve K olmak üzere üç değerlendirme göstergesine göre sınıflandırma sonuçlarını vermektedir. Önerilen yöntem ile tüm sınıflarda da en iyi sınıflandırma sonucu elde edilmiştir. Önerilen 3B ESA modeli %99,90 ile iki 3B evrişim katmanından oluşan 3B ESA modelinden %0,51, 2B ESA modelinden %0,87, DBN-LR modelinden %0,91 ve SAE-LR modelinden %1,44 daha iyi genel doğruluk sonucu elde etmektedir. Benzer şekilde önerilen model %99,78 ile sırasıyla, 3B ESA modelinden %0,93, 2B ESA modelinden %1,59, DBN-LR modelinden %1,4 ve SAE-LR modelinden %2,11 daha iyi ortalama doğruluk sonucu elde etmiştir. Kappa istatistiği değerlendirme ölçütünde ise yine önerilen yöntem %99,86 ile diğer tüm yöntemlerden en iyi sonucu elde ettiği görülmektedir. Tablo 5 göz önünde bulundurulduğunda, önerilen yöntemin sınıflandırma sonuçları temel gerçeğe (ground truth) çok benzerdir.

Tablo 5. PU verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları

Sınıf	SAE-LR	DBN-LR	2B ESA	3B ESA	Önerilen 3B ESA
1	98,73	99,05	99,68	99,65	99,90
2	99,55	99,83	99,87	99,83	99,96
3	93,87	95,15	96,31	94,65	99,36
4	98,63	98,83	98,01	99,09	99,89
5	100	99,93	100	100	100
6	97,87	98,71	97,61	99,93	100
7	93,74	96,36	95,63	97,75	99,25
8	96,76	98,20	99,35	99,24	100
9	99,90	99,71	97,25	99,55	99,65
GD	98,46	98,99	99,03	99,39	99,90
OD	97,67	98,38	98,19	98,85	99,78
K	97,98	98,68	98,71	99,20	99,86

Tablo 6, Botswana verisetinden elde edilen çeşitli yöntemlerin GD, OD ve K olmak üzere üç değerlendirme göstergesine göre sınıflandırma sonuçlarını vermektedir. Tablo 6'dan, önerilen yöntemin 6 nolu sınıf için sınıflandırma doğruluğu 3B ESA yönteminden %1,19 daha düşük çıkmıştır. 8 nolu sınıf için sınıflandırma doğruluğu 3B ESA, 2B ESA ve SAE-LR yöntemlerinden %1,64 ve DBN-LR yönteminden ise %1,38 düşük çıkmıştır. 10 nolu sınıf için sınıflandırma doğruluğu DBN-LR ve 2B ESA yöntemlerinden %1,35, 3B ESA yönteminden %1,05 ve SAE-LR yönteminden %1,09 daha düşük çıkmıştır. Geri kalan diğer sınıfların tamamında önerilen yöntem ile başarılı sınıflandırma

sonuçları elde edilmiştir. GD, OD ve K değerlendirme ölçütleri göz önüne alındığında önerilen yöntem ile diğer yöntemlerin tamamından yüksek sonuçlar elde edilmiştir. Önerilen yöntemin %99,59 GD sonucu, SAE-LR, DBN-LR, 2B ESA ve 3B ESA'dan sırasıyla, %1,1, %0,78, %0,71 ve %0,04 daha yüksek olduğu görülmektedir. Önerilen yöntem ayrıca, OD ve Kappa istatistiği açısından sırasıyla, %99,61 ve %99,55 ile diğer yöntemlerin tamamından daha iyi performans gösterdiği görülmektedir. Tablo 6'dan, önerilen yöntemin sınıflandırma sonuçları temel gerçeğe (ground truth) çok benzer olduğu görülmektedir.

Tablo 6. B verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları

Sınıf	SAE-LR	DBN-LR	2B ESA	3B ESA	Önerilen 3B ESA
1	100	100	99,18	99,64	100
2	100	100	100	100	100
3	100	100	100	100	100
4	99,58	100	99,16	99,45	100
5	94,70	94,84	99,54	98,60	100
6	92,96	95,33	97,36	98,72	97,53
7	99,88	100	100	99,68	100
8	100	99,74	100	100	98,36
9	96,68	96,98	94,99	99,67	100
10	99,74	100	100	99,70	98,65
11	99,47	99,67	100	99,87	100
12	100	100	96,63	99,63	100
13	99,52	99,82	100	99,43	100
14	99,26	100	97,44	100	100
GD	98,49	98,81	98,88	99,55	99,59
OD	98,70	99,03	98,88	99,60	99,61
K	98,36	98,72	98,78	99,51	99,55

Tablo 7, Indian pines verisetinden elde edilen çeşitli yöntemlerin GD, OD ve K olmak üzere üç değerlendirme göstergesine göre sınıflandırma sonuçlarını vermektedir. Tablo 7'den, önerilen yöntemin 12 nolu sınıf için sınıflandırma doğruluğu 3B ESA yönteminden %0,12 ve 14 nolu sınıf için sınıflandırma doğruluğu 3B ESA yönteminden %0,08, DBN-LR yönteminden daha % 0,27 daha düşük çıkmıştır. 12 ve 14 nolu sınıflar için sınıflandırma doğruluğu önerilen yöntemde düşük çıkmasına rağmen, GD, OD ve K değerlendirme ölçütleri göz önüne alındığında diğer yöntemlerin tamamından yüksek sonuçlar elde

edilmiştir. Önerilen yöntemin %99,35 olan GD sonucu SAE-LR, DBN-LR, 2B ESA ve 3B ESA yöntemlerinden sırasıyla, %5,37, %3,44, %3,38 ve %0,28 daha yüksek olduğu görülmektedir. Önerilen yöntem ayrıca, OD ve Kappa istatistiği açısından sırasıyla, %99,61 ve %99,21 ile diğer yöntemlerin tamamından daha iyi performans gösterdiği görülmektedir. Tablo 7 göz önünde bulundurulduğunda, önerilen yöntemin sınıflandırma sonuçları 9 sınıf için temel gerçek (ground truth) ile aynı geri kalan 7 sınıf için ise temel gerçeğe yakın sonuçlar elde edildiği görülmektedir.

Tablo 7. IP verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları

Sınıf	SAE-LR	DBN-LR	2B ESA	3B ESA	Önerilen 3B ESA
1	85,56	80,90	86,11	95,89	100
2	90,72	93,97	91,37	98,46	98,59
3	91,58	95,13	95,37	98,99	99,19
4	89,81	85,14	98,54	99,14	100
5	96,16	98,05	91,40	99,29	99,31
6	98,98	100	98,05	99,92	100
7	95,29	94,92	97,73	100	100
8	98,75	100	98,44	100	100
9	100	100	50,87	92,31	100
10	94,52	97,37	93,53	98,12	98,63
11	94,79	97,70	97,62	98,96	99,45
12	86,43	84,72	94,89	98,99	98,87
13	99,80	99,35	100	99,82	100
14	97,48	100	99,29	99,81	99,73
15	84,35	84,64	99,59	99,56	100
16	96,76	95,33	98,88	99,38	100
GD	93,98	95,91	95,97	99,07	99,35
OD	93,81	94,20	93,23	98,66	99,61
K	93,13	95,34	95,40	98,93	99,21

Yukarıda sunulan deneysel sonuçlara göre, ilk olarak, ESA tabanlı yöntemler, SAE ve DBN tabanlı yöntemlerden daha iyi sınıflandırma sonuçları elde etmektedir. SAE-LR ve DBN-LR, derin öğrenme mimarisinin kullanımıyla derin özellikler çıkarabilse de, SAE ve DBN'nin girdi gereksinimini karşılamak için görüntü parçalarının tek boyuta düzleştirilmesi gerekmektedir. Düzleştirme işlemi, orijinal hiperspektral görüntüde bulunan uzamsal bilgiden yararlanmada başarısız olmaktadır. Bu durum da biraz daha kötü bir performansa yol açabilmektedir. Daha da önemlisi, SAE ve DBN, özellikleri denetimsiz bir şekilde öğrenmekte ve etiket bilgilerinden tam olarak yararlanamamaktadır. İkinci olarak, 3B ESA, 2B ESA'ya kıyasla spektral-uzamsal özellik öğrenimi için daha iyi çalışmaktadır. 3B

ESA, 3B evrişim işlemleri ile daha ince spektral bilgileri modelleyebilmektedir. Ayrıca 3B hiperspektral görüntü üzerine 3B çekirdek uygulayarak, bir 3B ESA herhangi bir ön işleme dayanmazken, yöntemin uygulanması kolaydır. SAE-LR, DBN-LR ve 2B ESA'da ise spektral boyutluluğu kabul edilebilir bir düzeye indirmek için temel bileşen analizinin kullanılması gereklidir. Son olarak, SAE-LR, DBN-LR, 2B ESA ve 2 evrişim katmanına sahip 3B ESA ile karşılaştırıldığında, önerilen 3B ESA modeli üç veri kümesinin hepsinde daha iyi bir performans elde etti. Özellikle tüm verisetlerinde de, önerilen 3B ESA ile iki evrişim katmanından oluşan 3B ESA, 2B ESA'dan daha iyi genel doğruluk oranlarıyla en iyi sonuçları elde etti. Bu, 3B yaklaşımın geleneksel 2B evrişimlere kıyasla performansta bir artış sağlamaya

yardımcı olduğunu göstermektedir. Hiperspektral görüntü verilerindeki ortak spektral ve uzamsal bilgilerin 3B evrişim işlemleri yoluyla uygun modellenmesi, sınıflandırma işleminde ayırt edici özelliklerin yakalanması için önemlidir.

5. SONUÇ

Hiperspektral görüntü sınıflandırması için uygun bir derin öğrenme modelinin tasarımı büyük bir zorluktur. Uzamsal ve spektral özelliklerin birleşik kullanımı, sınıflandırma performansını arttırmaktadır. Bu çalışmada, hiperspektral görüntü sınıflandırmasını iyileştirmek amacıyla, hiperspektral görüntü verilerinde bulunan hem spektral hem de uzamsal bilgilerden tam olarak yararlanan yeni bir 3B ESA hiperspektral görüntü sınıflandırma modeli önerilmiştir. 3B ESA modelinin, sınıflandırma için hiperspektral görüntünün 3B yapısına uyacak şekilde uyarlanabileceği gösterilmiştir. Özellikle, önerilen 3B ESA modeli üç hiperspektral görüntü veri setinde, derin öğrenmeye dayalı dört hiperspektral görüntü sınıflandırma yöntemiyle karşılaştırılmıştır. Deneysel çalışmalar sonucunda sırasıyla genel doğruluk, ortalama doğruluk ve Kappa değerleri, Indian pines için %99,35, %99,61 ve %99,21, Pavia üniversitesi için %99,90, %99,78 ve %99,86 ve Botswana için ise %99,59, %99,61 ve %99,55 olarak elde edilmiştir. Sonuçlar, 4 farklı derin öğrenme tabanlı yöntemle karşılaştırılmıştır. Deneysel çalışmalar, önerilen 3B ESA tabanlı hiperspektral görüntü sınıflandırma yönteminin üç veri setinin tümünde en iyi genel doğruluğu, ortalama doğruluğu ve kappa değerini elde ettiğini göstermektedir.

KAYNAKLAR

- [1] Li Y, Zhang H, Shen Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sens.* 2017;9(1). [https://doi: 10.3390/rs9010067](https://doi.org/10.3390/rs9010067).
- [2] Sun H, Ren J, Zhao H, Yan Y, Zabalza J, Marshall S. Superpixel based feature specific sparse representation for spectral-spatial classification of hyperspectral images. *Remote Sens.* 2019;11(5). [https://doi: 10.3390/rs11050536](https://doi.org/10.3390/rs11050536).
- [3] Dou P, Zeng C. Hyperspectral image classification using feature relations map learning. *Remote Sens.* 2020;12(18). [https://doi: 10.3390/rs12182956](https://doi.org/10.3390/rs12182956).
- [4] Ahmad M. Spatial prior fuzziness pool-based interactive classification of hyperspectral images. *Remote Sens.* 2019;11(9):1–19. [https://doi: 10.3390/rs11091136](https://doi.org/10.3390/rs11091136).
- [5] Ahmad M, Khan MA, Mazzara M, Distefano S, Ali M, Sarfraz MS. A Fast and Compact 3-D CNN for Hyperspectral Image Classification. *IEEE Geosci. Remote Sens. Lett.* 2020:1–5. [https://doi: 10.1109/LGRS.2020.3043710](https://doi.org/10.1109/LGRS.2020.3043710).
- [6] Wang Y, Yu W, Fang Z. Multiple Kernel-based SVM classification of hyperspectral images by combining spectral, spatial, and semantic information. *Remote Sens.* 2020;12(1). [https://doi: 10.3390/rs12010120](https://doi.org/10.3390/rs12010120).
- [7] Ham JS, Chen Y, Crawford MM, Ghosh J. Investigation of the random forest framework for classification of hyperspectral data. *IEEE Trans. Geosci. Remote Sens.* 2005;43(3):492–501. [https://doi: 10.1109/TGRS.2004.842481](https://doi.org/10.1109/TGRS.2004.842481).
- [8] Alcolea A, Paoletti ME, Haut JM, Resano J, Plaza A. Inference in supervised spectral classifiers for on-board hyperspectral imaging: An overview. *Remote Sens.* 2020;12(3):1–29. [https://doi: 10.3390/rs12030534](https://doi.org/10.3390/rs12030534).
- [9] Ghamisi P, Dalla Mura M, Benediktsson JA. A survey on spectral-spatial classification techniques based on attribute profiles. *IEEE Trans. Geosci. Remote Sens.* 2015;53(5):2335–53. [https://doi: 10.1109/TGRS.2014.2358934](https://doi.org/10.1109/TGRS.2014.2358934).
- [10] Tuia D, Volpi M, Mura MD, Rakotomamonjy A, Flamary R. Automatic feature learning for spatio-spectral image classification with sparse SVM. *IEEE Trans. Geosci. Remote Sens.* 2014;52(10):6062–74. [https://doi: 10.1109/TGRS.2013.2294724](https://doi.org/10.1109/TGRS.2013.2294724).
- [11] Dalla Mura M, Villa A, Benediktsson JA, Chanussot J, Bruzzone L. Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis. *IEEE Geosci. Remote Sens. Lett.* 2011;8(3):542–46. [https://doi: 10.1109/LGRS.2010.2091253](https://doi.org/10.1109/LGRS.2010.2091253).
- [12] Jia S, Zhang X, Li Q. Spectral-spatial hyperspectral image classification using regularized low-rank representation and sparse representation-based graph cuts. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2015;8(6):2473–84.
- [13] Qian Y, Ye M, Zhou J. Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features. *IEEE Trans. Geosci. Remote Sens.* 2013;51(4):2276–91. [https://doi: 10.1109/TGRS.2012.2209657](https://doi.org/10.1109/TGRS.2012.2209657).
- [14] Hanbay K. Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform. *J. Fac. Eng. Archit. Gazi Univ.* 2020;35(1): 443–56. [https://doi: 10.17341/gazimmfd.479086](https://doi.org/10.17341/gazimmfd.479086).
- [15] Tang YY, Lu Y, Yuan H. Hyperspectral image classification based on three-dimensional scattering wavelet transform. *IEEE Trans. Geosci. Remote Sens.* 2015;53(5):2467–80. [https://doi: 10.1109/TGRS.2014.2360672](https://doi.org/10.1109/TGRS.2014.2360672).
- [16] Zhang L, Kumar V. Deep learning for Remote Sensing Data. *IEEE Geosci. Remote Sens. Mag.* 2016;4(2):22–40.
- [17] Chen Y, Zhao X, Jia X. Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2015;8(6): 2381–92. [https://doi: 10.1109/JSTARS.2015.2388577](https://doi.org/10.1109/JSTARS.2015.2388577).
- [18] Zhao W, Du S. Spectral-Spatial Feature Extraction for Hyperspectral Image Classification: A Dimension Reduction and Deep Learning Approach. *IEEE Trans. Geosci. Remote Sens.* 2016;54(8):4544–54. [https://doi: 10.1109/TGRS.2016.2543748](https://doi.org/10.1109/TGRS.2016.2543748).
- [19] Yue J, Zhao W, Mao S, Liu H. Spectral-spatial

- classification of hyperspectral images using deep convolutional neural networks. *Remote Sens. Lett.* 2015;6(6):468–77. [https://doi: 10.1080/2150704X.2015.1047045](https://doi.org/10.1080/2150704X.2015.1047045).
- [20] Mohan A, Venkatesan M. HybridCNN based hyperspectral image classification using multiscale spatio-spectral features. *Infrared Phys. Technol.* 2020;108:103326 [https://doi: 10.1016/j.infrared.2020.103326](https://doi.org/10.1016/j.infrared.2020.103326).
- [21] Kingma DP, Ba JL. Adam: A method for stochastic optimization. 3rd International Conference for Learning Representations, ICLR 2015. San Diego: May; 2015. p. 1–15.
- [22] Grana M, Veganzons MA, Ayerdi B. Hyperspectral Remote Sensing Scenes [Internet]. (Erişim tarihi: 17.03.2021). Available from: https://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes.
- [23] Data H. Deep Learning-Based Classification of Hyperspectral Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2014;7(6):2094–107.