



4CF-Net: New 3D convolutional neural network for spectral spatial classification of hyperspectral remote sensing images

Hüseyin Fırat^{1*} , Davut Hanbay² 

¹Vocational School of Technical Sciences, Dicle University, Diyarbakır, 21200, Turkey

²Department of Computer Engineering, Inonu University, Malatya, 44280, Turkey

Highlights:

- Spectral spatial feature extraction using 3D CNN
- PCA method used as preprocessing step of hyperspectral image classification
- Use of indian pines, pavia university, salinas and kennedy space center datasets

Graphical/Tabular Abstract

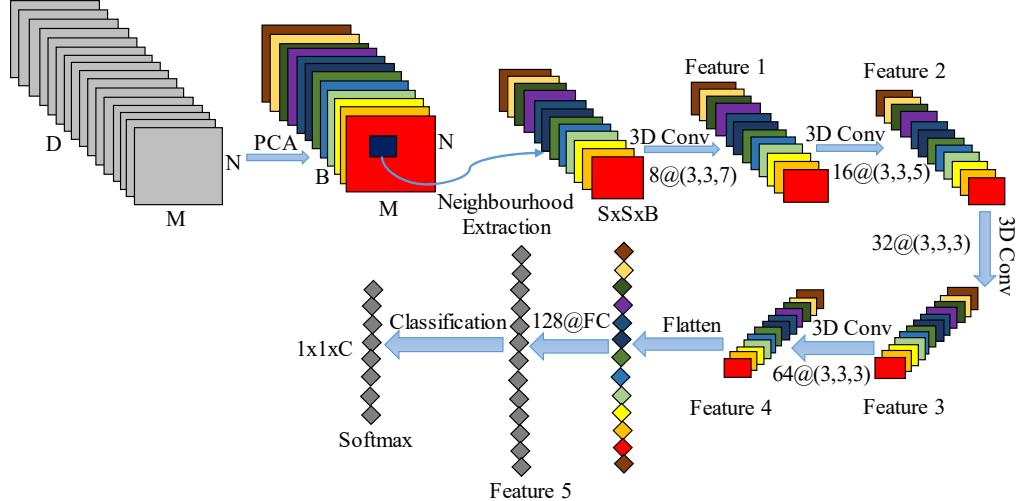


Figure A. Proposed 4CF-Net model for hyperspectral image classification

Article Info:

Research Article

Received: 22.03.2021

Accepted: 18.06.2021

DOI:

10.17341/gazimmd.901291

Correspondence:

Author: Hüseyin Fırat
e-mail:
huseyin.fırat@dicle.edu.tr
phone: +90 412 241 1000 / 7751

Theory and Methods:

In this study, a new 3D CNN method for hyperspectral remote sensing image classification is proposed. 3D CNN extracts spectral and spatial features from hyperspectral remote sensing images simultaneously to achieve better classification accuracy. The 3D CNN method chooses the neighborhood block as the input of the network model. PCA is applied on the hyperspectral image cube as a pre-processing step to remove the spectral band redundancy. Then, the hyperspectral cube is divided into small overlapping 3D patches. These patches are processed to create 3D feature maps using the 3D core function on multiple adjacent bands to preserve common spatial spectral information. Finally, the resulting deep classifier model is being trained end-to-end.

Results&Conclusion:

Experimental studies were conducted on Indian pines, Pavia University, Salinas and Kennedy Space Center datasets to evaluate the performance of the proposed 3D CNN method. Overall accuracy, average accuracy and Kappa values for the Indian pines data set were obtained as 99.93%, 99.72% and 99.92%, respectively. It was achieved as 99.99%, 99.96% and 99.99% for Pavia University. For the Salinas data set, 100% results were found in all evaluation metrics. For the Kennedy Space Center dataset, 99.81%, 99.68% and 99.78% results were obtained. The proposed 4CF-Net method was compared with 7 hyperspectral image classification methods based on deep learning. Experimental studies show that the proposed 4CF-Net method achieves the best overall accuracy, average accuracy, and kappa coefficient in all four data sets.



4CF-Net: Hiperspektral uzaktan algılama görüntülerinin spektral uzamsal sınıflandırılması için yeni 3B evrişimli sinir ağları

Hüseyin Fırat^{1*} , Davut Hanbay²

¹Dicle Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, 21200 Sur Diyarbakır, Türkiye

²İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 44280, Malatya, Türkiye

Ö N E Ç I K A N L A R

- 3B evrişimli sinir ağları kullanarak spektral uzamsal özellik çıkarma
- Hiperspektral görüntü sınıflandırmanın ön işleme adımı olarak kullanılan TBA yöntemi
- Indian pines, Pavia üniversitesi, Salinas ve Kennedy uzay merkezi verisetlerinin kullanımı

Makale Bilgileri

Araştırma Makalesi

Geliş: 22.03.2021

Kabul: 18.06.2021

DOI:

10.17341/gazimmd.901291

Anahtar Kelimeler:

Hiperspektral görüntü
sınıflandırma,
derin öğrenme,
3B evrişimli sinir ağları,
uzaktan algılama

ÖZ

Hiperspektral görüntüler (HG), uzaktan algılama yaygın olarak kullanılan bitişik bant görüntüleridir. Derin öğrenme HG sınıflandırmasında kullanılan etkili bir yöntemdir. Evrişimli sinir ağları (ESA) ise HG sınıflandırmasında kullanılan derin öğrenme yöntemlerinden biridir. Spektral-uzamsal alanlardan HG'lerin soyut özelliklerini öğrenebilen otomatik yaklaşımlar sağlamaktadır. HG'lerin yüksek boyutsallığı hesaplama karmaşıklığını artırmaktadır. Bu nedenle, geliştirilen ESA modellerinin çoğu, ön-isleme adımı olarak boyut indirgeme gerçekleştirmektedir. HG sınıflandırmasındaki diğer bir problem ise, doğru sonuçlar elde etmek için spektral-uzamsal özelliklerin dikkate alınması gerekliliğidir. Çünkü, HG sınıflandırma performansı büyük ölçüde spektral-uzamsal bilgilere bağlıdır. Bu çalışmada, HG sınıflandırması için yeni bir 3B ESA modeli önerilmiştir. Önerilen yöntem, HG'lerdeki spektral-uzamsal özellikleri eşzamanlı olarak çıkarmak için etkili bir yöntem sağlamaktadır. Ağ, girişte 3B hiperspektral küpü kullanmaktadır. Hiperspektral küpteki boyutsal fazlalığı gidermek için temel bileşen analizi kullanılmaktadır. Daha sonra komşuluk çıkarımı kullanılarak, spektral-uzamsal özellikler etkin bir şekilde çıkarılmaktadır. Önerilen yöntem 4 veriseti ile test edilmiştir. Uygulama sonuçları 7 farklı derin öğrenme tabanlı yönteme karşılaştırılmış ve 4CF-Net yöntemimizin daha iyi sınıflandırma performansı gösterdiği görülmüştür.

4CF-Net: New 3D convolutional neural network for spectral spatial classification of hyperspectral remote sensing images

H I G H L I G H T S

- Spectral spatial feature extraction using 3D convolutional neural network
- PCA method used as preprocessing step of hyperspectral image classification
- Use of Indian pines, Pavia university, Salinas and Kennedy space center datasets

Article Info

Research Article

Received: 22.03.2021

Accepted: 18.06.2021

DOI:

10.17341/gazimmd.901291

Keywords:

Hyperspectral image
classification,
deep learning,
3D convolutional neural
network,
remote sensing

ABSTRACT

Hyperspectral images (HSI) are contiguous band images commonly used in remote sensing. Deep learning (DL) is an effective method used in HSI classification. Convolutional neural networks (CNN) are one of the DL methods used in HSI classification. It provides automated approaches that can learn abstract features of HSIs from spectral-spatial fields. The high dimensionality of the HSIs increases the computational complexity. Therefore, most of the developed CNN models perform dimensionality reduction as a preprocessing step. Another problem in HSI classification is that spectral-spatial features must be considered in order to obtain accurate results. Because, HSI classification performance is highly dependent on spectral-spatial information. In this study, a new 3D CNN model is proposed for HSI classification. The proposed method provides an effective method to simultaneously extract spectral-spatial features in HSIs. The network uses the 3D hyperspectral cube as the input. Principal component analysis is used to eliminate the dimensional redundancy in the hyperspectral cube. Then, using neighborhood extraction, spectral-spatial features are extracted effectively. The proposed method has been tested with 4 datasets. The application results were compared with 7 different DL-based methods and it was seen that our 4CF-Net method showed better classification performance.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *huseyin.firat@dicle.edu.tr, davut.hanbay@inonu.edu.tr /

Tel: +90 412 241 1000 / 7751

1. GİRİŞ (INTRODUCTION)

Uzaktan algılama (UA) sensörlerinin spektral çözünürlüğü gelişikçe, hiperspektral teknoloji, iyi kalitede arazi kullanım bilgisi elde etmek için büyük bir potansiyel sergilemektedir. Hiperspektral UA görüntüleri (HUAG), yüzlerce sürekli ve dar bantta gözlemlenen bir dizi görüntüdeki her pikselin spektrumunu yakalamaktadır. Geniş dalga boyuna sahip multispektral görüntülerle karşılaşıldığında, hiperspektral görüntüler, tespit edilmesi zor nesneleri ayırt etmek için dar dalga boylarında gizlenmiş özellikler sağlayabilmektedir [1]. Bu durumda, tanımlanması zor olan nesneler hiperspektral görüntülerdeki yüksek spektral çözünürlük sayesinde tanınabilir hale gelmektedir. HUAG'ın zengin spektral bilgileri güçlündür. Bu nedenle, bitki örtüsü analizi, hassas tarım, jeolojik haritalama, çevresel izleme, biyolojik ve kimyasal algılama, nesne tespiti, kaynak arama ve madencilik gibi pek çok uygulamada yaygın olarak kullanılmaktadır [2, 3]. HUAG'de her pikselin sınıflandırılması bu uygulamalarda çok önemli bir rol oynamaktadır. HUAG sınıflandırma, hiperspektral bilgiyi öznitelik bilgisine dönüştürmek için önemli bir işlemidir. Benzersiz bir sınıfı bir piksel atamayı amaçlayan geleneksel çoklu spektral UA görüntü sınıflandırmasının bir uzantısıdır [4]. HUAG, yüksek boyutlu özelliklere sahiptir. Aynı zamanda, bitişik bantlar arasındaki korelasyon genellikle yüksek olduğu için çoklu spektral görüntülerden önemli ölçüde farklılık göstermektedir. Gürültü ve karışık pikseller gibi yönlerinin yanı sıra, hiperspektral görüntü sınıflandırmasında büyük hacim nedeniyle hesaplama açısından karmaşıklık ve yüksek boyutsallık sınıflandırmayı daha zor hale getirmektedir [5]. Yüksek boyutluluuk, HUAG sınıflandırmalarının verimliliğini azaltmaktadır. Bu nedenle, boyut indirgeme HUAG sınıflandırmada oldukça önemlidir. Temel bileşen analizi (TBA) [6] ve doğrusal diskriminant analizi [7] gibi boyut indirgeme yöntemleri ile hiperspektral görüntülerdeki yararlı özellikleri çıkarmak amaçlanmaktadır. Bu işlem sonucunda veri boyutu düşürülerek ve işlem maliyeti azaltılmaktadır [8].

Son yıllarda kendi kendine öğrenen sınıflandırıcıların yardımıyla veya manuel olarak gerçekleştirilen çok sayıda hiperspektral sınıflandırma yöntemi önerilmiştir. Geleneksel hiperspektral sınıflandırma yöntemleri, genellikle yalnızca spektral bilgilere dayanmaktadır. Bu sınıflandırıcılar arasında en yakın komşu [9], lojistik regresyon [9], destek vektör makinesi (DVM) [10] ve maksimum olabilirlik [11] temelli sınıflandırıcılar bulunmaktadır. Bu sınıflandırıcılar arasında DVM, basit ama güçlü bir son sınıflandırıcı olarak kullanılmaktadır. Ancak bu sınıflandırıcılar, spektral fazlalık ve spektral bantlar arasındaki yüksek korelasyon nedeniyle iyi performans gösterememektedir. Çünkü, çok sayıda spektral bant için yeterli sayıda eğitim örneği bulunmayabilir. Bu durum, spektral bantların yüksek boyutluluğu ile sınırlı sayıda eğitim örneği arasında bir dengesizlik oluşmasına neden olmaktadır [12]. Ayrıca, yalnızca spektral bilgileri kullanan bu sınıflandırma algoritmaları, yüksek çözünürlüklü veriler için algılanan

önemli uzamsal değişkenlikleri yakalayamamaktadır. Bu da, genellikle daha düşük sınıflandırma performansıyla sonuçlanmaktadır. Sınıflandırma performansını iyileştirmenin en basit yolu, hem spektral hem de uzamsal bilgileri içeren bir sınıflandırıcı tasarlamaktır. Uzamsal bilgi uygun bir şekilde kullanılırsa, farklı yapıların şekli ve boyutu ile ilgili ek ayırt edici bilgiler sağlanmaktadır. Bu durum, daha doğru sınıflandırma haritalarına yol açmaktadır. Spektral uzamsal sınıflandırıcılar genel olarak iki grupta sınıflandırılmaktadır. Birinci grup, spektral ve uzamsal bilgileri ayrı ayrı kullanmaktadır. Uzamsal bilgi, morfolojik işlemler, entropi, öznitelik profilleri ve düşük dereceli temsil gibi çeşitli uzamsal filtreler aracılığıyla önceden çıkarılmaktadır [12]. Daha sonra bu bilgiler, piksel düzeyinde sınıflandırmayı gerçekleştirmek için spektral bilgilerle birleştirilmektedir. İkinci grup, ortak özelliklerini elde etmek için genellikle uzamsal bilgiyi spektral özelliklerle birleştirmektedir. Örneğin, farklı ölçek ve frekanslarda üretilen bir dizi 3B dalgacık filtresi, 3B Gabor filtresi ve 3B saçılım dalgacık filtreleri, sınıflandırma için spektral uzamsal birleşik özelliklerini çıkarmak için hiperspektral verilere uygulanmaktadır [13]. Bununla birlikte, geleneksel özellik çıkarma yöntemlerinin çoğu, hem uzamsal hem de spektral özellikler dikkate alındığında sınıflandırma doğruluğunu artırmaktadır. Ancak yukarıda bahsedilen yöntemlerin çoğu, özellikleri manuel olarak çıkarmakta ve bir uzmanın yardımına ihtiyaç duymaktadır.

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 [14]. Tipik bir derin öğrenme yöntemi olarak, yiğilmiş oto-kodlayıcı hem uzamsal hem de spektral bilgileri çıkarabilmektedir [15]. Daha sonra bu bilgileri hiperspektral görüntü sınıflandırması için birlestirebilmektedir. Chen vd. [16], derin öğrenme kavramını ilk kez hiperspektral görüntü sınıflandırması alanına uygulamışlardır. Spektral uzamsal özellik çıkarma ve sınıflandırma için, TBA, yiğilmiş oto-kodlayıcı ve lojistik regresyonun birlikte kullanıldığı bir yöntem geliştirmiştir. Her pikselin baskın uzamsal özelliklerini seçerek ve spektral özellikleri bunlarla birleştirerek ortak bir spektral uzamsal sınıflandırıcı ortaya çıkarmışlardır. Tao vd. [17], derin spektral özelliklerin çıkarılması için, yiğilmiş oto-kodlayıcı ve lojistik regresyonun beraber kullanıldığı yiğilmiş oto-kodlayıcı tabanlı lojistik regresyon önermiştir. Ma vd. [18], hiperspektral görüntü sınıflandırması için, yiğilmiş oto-kodlayıcı ailesinden olan bağlamsal bir derin öğrenme tekniği önermiştir. Bağlamsal derin öğrenme yoluyla hem uzamsal hem de spektral özellikleri öğrenerek, sınıflandırıcının doğruluğu önemli ölçüde geliştirilmiştir. Derin inanç ağı tabanlı sınıflandırma, hiperspektral görüntü analizi için kullanılan diğer bir derin öğrenme yaklaşımıdır. Hiperspektral görüntülerin uzamsal bilgileri ile spektral bilgilerini birleştirmek için önerilmiştir. Jia vd. [19], derin inanç ağına dayalı hiperspektral görüntü analizi için, TBA, hiyerarşik

öğrenme tabanlı özellik çıkarma ve lojistik regresyonun birlikte kullanıldığı bir yöntem önermişlerdir. Li vd. [20], bir optimal derin inanç ağı ve yeni bir doku özelliği geliştirmeye dayalı hiperspektral görüntü sınıflandırma yöntemi önermişlerdir. Bant gruplama, örnek bant seçimi ve kılavuzlufiltreleme yoluyla, hiperspektral görüntülerin doku özellikleri iyileştirilmektedir. Daha sonra, özellik çıkarma ve sınıflandırma için hiperspektral yeniden yapılandırılmış veriler üzerinde optimal derin inanç ağı kullanılmaktadır. Yığılmış oto-kodlayıcı ve derin inanç ağı, katman bazlı eğitim tarzında derin özellikleri hiyerarşik olarak çıkarılabilirken, görüntü parçalarından oluşan eğitim örneklerinin, bu tür modellerin girdi gereksinimlerini karşılamak için tek boyuta düzleştirilmesi gerekmektedir. Bu durumda hiperspektral görüntülerdeki uzamsal özellikler tam olarak kullanılamamaktadır. Evrişimsel sinir ağları (ESA), HUAG sınıflandırma için kullanılan bir başka derin öğrenme yöntemidir. ESA, daha yüksek kalitede hiperspektral görüntü sınıflandırması için daha ayırt edici özellikler sağlayabilen güçlü bir özellik öğrenmeye sahiptir. Öğrenilen özellikler ne kadar ayırt edici ise, sınıflandırma problemlerinin çözümü o kadar kolay olacaktır. Bu durum sınıflandırma doğruluğunu büyük ölçüde artırmaktadır. Bu nedenle, HUAG sınıflandırmada, ESA tabanlı yöntemler, spektral, uzamsal veya hem uzamsal hem de spektral alanlardan gizli özelliklerin çıkarılmasında en etkili yöntemlerden biridir. ESA tabanlı yöntemler, HUAG sınıflandırma performansını etkili bir şekilde iyileştirdiği için giderek daha fazla uygulanmaktadır. Mohan vd. [14], HUAG sınıflandırması için çok öbekli uzamsal spektral özellik tabanlı hibrit bir ESA modeli önermişlerdir. Optimum bant çıkarımı için, doğrusal gauss rastgele projeksyonu ve doğrusal olmayan çekirdek temel bileşen analizi gerçekleştiren hibrit boyut indirgeme yöntemini kullanmışlardır. Önerilen hibrit ESA sınıflandırma yöntemi, 3B ESA kullanarak farklı pencere boyutları için spektral ve uzamsal özelliklerini çıkarmaktadır. Bu özellikler, daha fazla özellik çıkarma ve sınıflandırma için bir 2B ESA ile birleştirilmiştir. Bu yöntemin performansını test etmek için, Indian pines, Pavia Üniversitesi, Salinas ve Houston veri setleri üzerinde deneyler gerçekleştirilmiştir. Indian pines veri seti için %99,8, Pavia Üniversitesi veri seti için %99,99, Salinas veri seti için %100 ve Houston veri seti için %99,12 genel doğruluk sonuçları elde edilmiştir. Chen vd. [21], HUAG sınıflandırması için, hiperspektral görüntülerden spektral ve uzamsal özelliklerin birlikte kullanıldığı yeni bir ESA yöntemi önermişlerdir. İlk olarak, uzamsal özelliklerindeki benzerlik göz önünde bulundurularak, hiperspektral görüntüsünden görüntü blokları elde etmek için büyük bir uzamsal pencere kullanılmaktadır. İkinci olarak, görüntü bloğunun her bir spektral kanalı, uzamsal ve spektral özelliklerini çıkarmak için filtrelenmektedir. Daha sonra özellikler evrişimli katmanlarla birleştirilmektedir. Son olarak, sınıflandırma sonucunu elde etmek için tamamen bağlantılı katmanlar kullanılmaktadır. Indian pines ve Pavia Üniversitesi veri setleri üzerinde deneyler gerçekleştirilmiştir. Indian pines veri setinde %98,02, Pavia Üniversitesi veri setinde ise %98,26 genel doğruluk sonuçları elde edilmiştir. Roy vd. [22], HUAG sınıflandırması için

hibrit bir spektral ESA önermişlerdir. Önerilen yöntem, bir spektral-uzamsal 3 boyutlu ESA ve ardından uzamsal 2 boyutlu ESA'dan oluşmaktadır. 3B ESA, bir spektral bant yığınından ortak uzamsal-spektral özelliklerini çıkarmaktadır. 3B ESA'nın üstündeki 2B ESA, uzamsal özelliklerini çıkarmaktadır. Bu hibrit yöntemin performansını test etmek için, Indian Pines, Pavia Üniversitesi ve Salinas UA veri setleri üzerinde deneyler gerçekleştirilmiştir. Genel doğruluk sonuçları sırasıyla, Indian Pines veri seti için %99,75, Pavia Üniversitesi veri seti için %99,98 ve Salinas veri seti için %100 olarak elde edilmiştir. Zhong vd. [23], uçtan-ucca spektral uzamsal artık ağ kullanarak HUAG sınıflandırma için bir yöntem önermişlerdir. Yöntem, orijinal 3 boyutlu hiperspektral küpü girdi verileri olarak almaktadır. Artık bloklar, gradyanların geri yayılmasını kolaylaştırın kimlik haritalama yoluyla her 3B evrişimli katmanı birbirine bağlamaktadır. Indian pines, Kennedy uzay merkezi ve Pavia üniversitesi veri setleri kullanılarak önerilen yöntemin etkinliği incelenmiştir. Gerçekleştirilen deneyler sonucunda sırasıyla, %99,19, %99,61 ve %99,79 genel doğruluk sonuçları elde edilmiştir. Song vd. [24], HUAG sınıflandırması için derin özellikli bir füzyon ağı önermişlerdir. Önerilen yöntem, kimlik haritalama olarak birkaç evrişimli katmanı optimize etmek için, derin ağını eğitimi kolaylaştırabilecek ve artan derinlikten faydalananabilen artık öğrenmeyi kullanmaktadır. Bu sayede ağı, daha derin özelliklerini çıkarabilecektir. Ayrıca, farklı hiyerarşik katmanların çıktılarını birleştirerek sınıflandırma doğruluğunu daha da artırmaktadır. Indian pines, Pavia üniversitesi ve Salinas veri setleri üzerinde gerçekleştirilen deneyler sonucunda sırasıyla, %98,52, %98,73 ve %98,87 genel doğruluk sonuçları elde edilmiştir. Meng vd. [25], diğer mevcut derin öğrenme tabanlı HUAG sınıflandırma modellerinden daha geniş olan yeni bir ESA modeli önermişlerdir. Önerilen yöntem, ağı katmanlarının derinleştirilmesinin sınıflandırma doğruluğunu yavaş yavaş artmasına neden olduğu problemi çözmek için tasarlanan yeni birçok yolu artık ağı olarak adlandırılmıştır. Ağ, orijinal artık ağıda birden çok artık bloğu istiflemek yerine paralel olarak çok yolu bir artık işlevi kullanmaktadır. Bu yolla, ağı daha derin değil daha geniş hale getirmektedir. Indian pines, Houston ve Kennedy uzay merkezi veri setleri üzerinde gerçekleştirilen deneyler sonucunda sırasıyla, %99,16, %98,88 ve %96 genel doğruluk sonuçları elde edilmiştir. Mu vd. [26], HUAG sınıflandırması için çok öbekli ve çok seviyeli spektral-uzaysal özellik füzyon ağı önermişlerdir. Ağ, giriş verileri olarak orijinal 3B hiperspektral küpü kullanmaktadır. Önerilen yöntemde, ağını girdisi olarak farklı öbekli komşuluk blokları kullanılarak, farklı öbeklerin spektral-uzamsal özelliklerini etkin bir şekilde çıkarılabilmektedir. Önerilen 3B – 2B alternatif artık blok, 3B ESA tarafından çıkarılan spektral özelliklerini, 2B ESA tarafından çıkarılan uzamsal özelliklerle birleştirmektedir. Önerilen yöntemin performansını test etmek için, Indian pines, Pavia Üniversitesi, Salinas ve Kennedy uzay merkezi veri setleri üzerinde deneysel çalışmalar gerçekleştirilmiştir. Gerçekleştirilen deneyler sonucunda sırasıyla, %99,12, %99,94, %99,84 ve %99,68 genel doğruluk sonuçları elde edilmiştir.

HUAG sınıflandırma için yapılan ESA tabanlı çalışmalar ile başarılı sonuçlar elde edilmiştir. ESA'lar hiperspektral görüntü sınıflandırması için en etkili yöntemlerden biri olduğu ve spektral tabanlı, uzamsal tabanlı ve spektral-uzamsal tabanlı dahil olmak üzere uygulamalarında farklı bakış açıları göstermektedir [27]. Spektral tabanlı yöntemler kavramsal olarak basit ve uygulaması kolaydır, çoğu tek boyutlu ESA (1B ESA) mimarilerini spektral bantlardan özellik çıkarmak için kullanmaktadır. Ancak, bu yöntemler spektral bağlamları göz ardı ederek yetersiz bir sınıflandırma performansı ile sonuçlanmaktadır [28]. Uzamsal tabanlı yaklaşım, iki boyutlu ESA (2B ESA) mimarilerini kullanarak uzamsal bilgileri çıkarmak için taramadaki belirli bir pikselin komşu piksellerini dikkate almaktadır. Uzamsal bağamlara daha fazla odaklandıklarından, bu yöntemlerin çoğu, ilk önce görüntü boyutunu azaltmak için PCA ve otokodlayıcı gibi ön işleme yöntemlerini kullanmaktadır. Uzamsal özellikler ve spektral özellikler ayrı ayrı çıkarıldıklarından, sınıflandırma için önemli olabilecek ortak uzamsal spektral korelasyon bilgilerinden tam olarak yararlanamayabilirler. Bu işlem spektrumdaki bazı bilgileri kaybedecek ve bu yöntemlerin farklı nesneleri ayırt etme kapasitesini azaltacaktır [29]. Uzamsal spektral yaklaşım, üç boyutlu ESA (3B ESA) mimarilerini kullanarak, uzamsal ve spektral bilgileri birleştirmektedir. 3B ESA yöntemi, ağ modelinin girdisi olarak komşuluk bloğunu seçmektedir. Aynı zamanda daha iyi sınıflandırma doğruluğu elde etmek için eşzamanlı olarak orijinal hiperspektral UA görüntülerden spektral ve uzamsal özellikleri çıkarmaktadır. Hiperspektral küplerin hem uzamsal hem de spektral alanlarındaki özellikleri ögrenebildikleri için, hiperspektral görüntü sınıflandırma kalitesini iyileştirmek için bu yöntemler giderek daha fazla ilgi görmektedir [30].

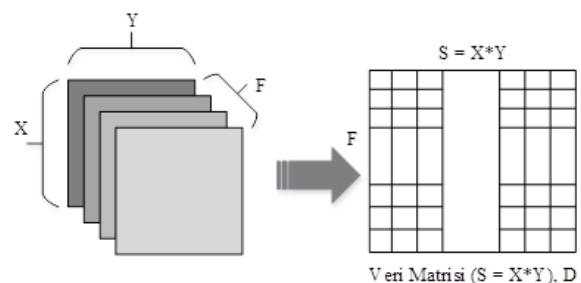
Artan hesaplama karmaşıklığı nedeniyle çok az yöntem 3B ESA kullanmaktadır. Bu çalışmada, hiperspektral UA görüntü sınıflandırma için yeni bir 3B ESA yöntemi önerilmektedir. Spektral ve uzamsal özellikler eşzamanlı olarak çıkarıldığından, bu çalışma 3B hiperspektral UA görüntülerinin yapısal özelliklerinden tam olarak yararlanmaktadır. Hiperspektral UA görüntü sınıflandırma diğer bir problem ise, spektral bant fazlalığının olmasıdır. Bu çalışmada ilk olarak, bant fazlalığını gidermek için ön işleme adımı olarak, orijinal hiperspektral görüntüküne TBA uygulanmaktadır. TBA ile önemli olan uzamsal bilgiyi koruyacak şekilde yalnızca spektral bantlar azaltılmaktadır. Daha sonra, hiperspektral küp üst üste binen küçük 3B parçalara bölünmektedir. Bu parçalar, ortak uzamsal spektral bilgileri korumak için birden fazla bitişik bant üzerinde 3B çekirdek işlevini kullanarak 3B özellik haritaları oluşturmak üzere işlenmektedir. Bu durumda 3B ESA, özellik küplerinin hem uzamsal hem de spektral boyutlarındaki yerel sinyal değişikliklerini ögrenebilmekte ve sınıflandırma için önemli ayırmalık bilgilerinden faydalananabilmektedir. Son olarak, ortaya çıkan derin sınıflandırıcı modeli, uçtan uca bir şekilde eğitilmektedir. Aynı ölçekte, 3B ESA'mız diğer derin öğrenme tabanlı yöntemlerden daha az parametre içermektedir. Bu, tipik olarak eğitim örneklerine sınırlı

erisimi olan hiperspektral UA görüntü sınıflandırma problemleri için daha uygundur. Önerilen 3B ESA yönteminin performansını değerlendirmek için Indian pines, Pavia üniversitesi, Salinas ve Kennedy uzay merkezi veri setleri üzerinde deneyel çalışmalar gerçekleştirılmıştır. Gerçekleştirilen deneyler sonucunda sırasıyla, %99,94, %99,99, %100 ve %99,81 genel doğruluk sonuçları elde edilmiştir. Önerilen 3B ESA tabanlı yöntem literatürden farklı derin öğrenme tabanlı yöntemlerle karşılaştırılmıştır. Elde edilen sonuçlar, önerilen yöntemin daha iyi performans gösterdiğini ortaya koymuştur.

Bu çalışmada önerilen yöntemin teorik alt yapısı oluşturan Temel bileşen analizi Bölüm 2'de ve 3B ESA Bölüm 3'te anlatılmıştır. Bölüm 4'te önerilen yöntem detaylandırılmıştır. Bölüm 5'te kullanılan veri setleri ve deneyel sonuçlar verilmiştir. Bölüm 6'da ise sonuçlar tartışılmıştır.

2. TEMEL BİLEŞEN ANALİZİ (PRINCIPAL COMPONENT ANALYSIS-PCA)

Basit ama etkili bir ön işleme yöntemi olan temel bileşen analizi (TBA), HUAG'nın sınıflandırılması uygulamaları için en yaygın kullanılan boyut indirgeme tekniklerinden biridir [31]. Özellikle, TBA, verilerin boyutunu azaltmayı ve en büyük varyansa sahip orijinal spektral bantların birkaç ortogonal doğrusal kombinasyonunu (temel bileşenler) bularak boyutsal fazlalığı düşürmeyi amaçlamaktadır [32]. Genel olarak, hiperspektral görüntüler, iki boyutun (X ve Y) uzamsal bilgiyi ifade ettiği ve üçüncü boyutun (F) spektral bilgiyi gösterdiği bir hiperküp ($X * Y * F$) ile temsil edilmektedir. F spektral bilgiyi, X ve Y ise hiperküpte uzamsal bilgiyi ifade etmektedir. Hedeflenen uzaktan algılama uygulamalarını sağlamak için hiperspektral UA hiperküpünün daha ileri analizi için, hiperspektral görüntü genellikle Şekil 1'de gösterildiği gibi hiperküpü ilk olarak, D olarak gösterilen ve $S = X * Y$ olan $F * S$ boyutunda bir veri matrisine dönüştürmektedir.



Şekil 1. Hiperspektral görüntü hiperküpünün 2B veri matrisine dönüştürülmesi
(Conversion of hyperspectral image hypercube to 2D data matrix) [33].

$X * Y$ boyutundaki hiperspektral görüntünün her bant görüntüsü bir satır matrisine dönüştürilmektedir. Ardından, toplam F satırı matrisleri birbirini ardına yerleştirilerek $F * S$ boyutlu bir veri matrisi D oluşturulmaktadır [33]. Hiperküp veya veri matrisinde x_n olarak belirtilen bir pikselin spektral vektörü $x_n = [x_{n1} x_{n2} \dots \dots x_{nF}]^T$, $n \in [1, S]$ olarak

tanımlanmaktadır. Daha sonra I olarak belirtilen sıfır ortalama görüntü $I = [I_1 I_2 \dots \dots I_n]$ olacak şekilde I_n 'den, ortalama görüntü vektörü $M = \frac{1}{S} \sum_{n=1}^S x_n$ ve ortalama düzeltilmiş spektral vektörler $I_n = x_n - M = [I_{n1} I_{n2} \dots \dots I_{nF}]^T$ üretilmektedir. Hiperspektral görüntüler için kovaryans matrisi $C = \frac{1}{S} II^T$, temel bileşenler olarak da bilinen öz vektörler ($V_1 V_2 \dots \dots V_F$) ve karşılık gelen öz değerler ($E_1 E_2 \dots \dots E_F$), TBA'nın çekirdeğini temsil ettiği öz değer ayrışımı için hesaplanmaktadır. Öz vektörler, yeni özellik uzayının yönlerini ve özdeğerler büyülüklüklerini belirlemektedir. Ayrıca, özdeğerler yeni özellik eksenleri boyunca verilerin varyansını açıklamaktadır. $E = \text{diagonal}(E_1 E_2 \dots \dots E_F)$, C 'nin karşılık gelen öz değerlerinden E_1, E_2, \dots, E_F oluşan bir köşegen matris ise ve V tüm ilgili özvektörlerin matrisini gösteriyorsa, V Eş. 1 kullanılarak hesaplanmaktadır.

$$C = VEV^T \quad (1)$$

Daha sonra, k öz vektörleri $F \times k$ boyutlu bir matris oluşturmak (w) için seçilmektedir. $k, k \leq F$ ve genellikle $k \ll F$ ile yeni özellik alt uzayındaki boyutların sayısını ifade etmektedir. En yüksek k öz vektörünü seçmek için ortak yaklaşım, öz değerleri en yüksektan en düşüğe doğru sıralamaktır. Diğer yaklaşımalar arasında diskriminant analizi, sapma analizi, örneğin bhattacharyya mesafesi, karşılıklı bilgi tabanlı seçim yöntemleri yer almaktadır. Son olarak izdüşüm matrisi Y , $Y = w^T * I$ olarak elde edilmektedir [33].

3. 3B EVRİŞİMLİ SİNİR AĞI (3D CONVOLUTION NEURAL NETWORK)

2B ESA'yı HUAG'ye doğrudan uygulamak, ağıın 2B girişlerinin her birinin evrişimini ve her birinin bir dizi öğrenilebilir parametreye sahip olmasını gerektirmektedir. Hiperspektral görüntülerin spektral boyutu boyunca yüzlerce kanal, artan hesaplama maliyetleriyle aşırı uyuma eğilimli olabilen çok sayıda parametre gerektirmektedir. Bu problemin üstesinden gelmek için boyut indirgeme yöntemleri genellikle özellik çıkarma ve sınıflandırma için 2B ESA kullanılmadan önce spektral boyutluluğu azaltmak için uygulanmaktadır. Ancak, 2B ESA ile hiperspektral görüntüdeki sadece uzamsal bilgiler korunacağı için, spektral boyutlardan iyi ayırt edici özellik haritaları çıkarılamamaktadır. 2B evrişim işlemi için, ister 2B veriye ister 3B veriye uygulanıp uygulanmadığına bakılmaksızın, çıktıtı 2B'dir. Hiperspektral görüntülerde 2B evrişim işlemleri uygulandıysa, önemli spektral bilgiler kaybedilmektedir. Öte yandan, hiperspektral görüntü sınıflandırma performansı büyük ölçüde hem uzamsal hem de spektral bilgilere bağlıdır. Yani, hiperspektral görüntü sınıflandırma, doğru sonuçlar elde etmek için hem uzamsal hem de spektral özelliklerin dikkate alınması gerekmektedir. Bu, zengin spektral bilgi içeren hiperspektral görüntüler için çok önemlidir. 3B ESA, her iki özelliği de dikkate alarak, bu özelliklerden ortak yararlanmaya yardımcı olmaktadır. 3B ESA, 3B evrişim işlemi için 3B çekirdekler kullanmakta ve aynı anda uzamsal ve spektral özelliklerini çıkarabilmektedir.

2B konvolusyon işleminde, giriş verileri, çıktı verilerini (yani özellik haritalarını) oluşturmak için aktivasyon işlevinden geçmeden önce 2B çekirdeklerle evrişim işlemeye tabi tutulmaktadır. Bu işlem Eş. 2'deki gibi formüle edilmektedir.

$$v_{lj}^{xy} = f \left(\sum_m \sum_{h=0}^{H_j-1} \sum_{w=0}^{W_j-1} k_{ljm}^{hw} v_{(l-1)m}^{(x+h)(y+w)} + b_{lj} \right) \quad (2)$$

Eş. 2'de, l dikkate alınan katmanı göstermektedir. j , bu katmandaki özellik haritalarının sayısıdır. v_{lj}^{xy} , l inci katmandaki j . özellik haritasında (x, y) konumundaki çıktıyı belirtmekte, b bias değeridir ve $f(.)$ aktivasyon fonksiyonudur. m , mevcut özellik haritasına bağlı ($l-1$). katmandaki özellik haritaları kümesi üzerindeki indeksleri ifade etmektedir. k_{ljm}^{hw} , j . özellik haritasına bağlı çekirdeğin (h, w) konumundaki değeridir. H_j ve W_j , sırasıyla çekirdeğin yüksekliğini ve genişliğini belirtmektedir. Geleneksel 2B ESA'da, evrişim işlemleri yalnızca uzamsal boyuttaki özelliklerini yakalayan 2B özellik haritalarına uygulanmaktadır. 3B verilere uygulandığında hem uzamsal hem de spektral boyutlardan özelliklerin yakalanması istenilmektedir. Bu amaçla, 3B giriş verilerinden ortak uzamsal spektral özelliklerini hesaplamak için 3B evrişim işlemlerinin 3B özellik küpelerine uygulandığı 3B ESA önerilmektedir. Biçimsel olarak, l inci katmandaki j . özellik kübü üzerindeki (x, y, z) konumundaki değer Eş. 3'teki gibidir.

$$v_{lij}^{xyz} = f \left(\sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} \sum_{r=0}^{R_{l-1}} k_{ljm}^{hwr} v_{(l-1)m}^{(x+h)(y+w)(z+r)} + b_{lj} \right) \quad (3)$$

Eş. 3'te, R_l , spektral boyut boyunca 3B çekirdeğin boyutudur. j , bu katmandaki çekirdek sayısıdır. k_{ljm}^{hwr} , önceki katmandaki m . özellik küpüne bağlı çekirdeğin (h, w, r) konumundaki değerini ifade etmektedir. 3B ESA tabanlı hiperspektral UA görüntü sınıflandırma modelimizde, her özellik küpü bağımsız olarak ele alınmaktadır. Böylece, Denklem 3'de m 1'e ayarlanmakta ve 3B evrişim işlemi Eş. 4'teki gibi yeniden formüle edilmektedir.

$$v_{lij}^{xyz} = f \left(\sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} \sum_{d=0}^{D_{l-1}} k_{lj}^{hwd} v_{(l-1)i}^{(x+h)(y+w)(z+d)} + b_{lj} \right) \quad (4)$$

Eş. 4'te, D_l , 3B çekirdeğin spektral derinliğidir. i , önceki katmandaki özellik küpelerinin sayısıdır. j , bu katmandaki çekirdek sayısıdır. v_{lij}^{xyz} , önceki katmanın i . özellik küpünün l . katmanın j . çekirdeği ile evrişim işlemeye tabi tutulmasıyla hesaplanan (x, y, z) konumundaki çıktıyı ifade etmektedir. k_{lj}^{hwd} , önceki katmandaki i . özellik küpüne bağlı çekirdeğin (h, w, d) konumundaki değeridir. Bu nedenle, l inci evrişim katmanın çıktı verileri $i \times j$ 3B özellik küpelerini içermektedir. ESA'da en sık kullanılan aktivasyon fonksiyonu ReLU'dur. ReLU, eğitim için gradyan iniş tekniklerini kullanırken diğer aktivasyon işlevlerinden daha hızlıdır. ReLU Eş. 5'teki gibi formüle edilmektedir.

$$\text{ReLU}(v) = \max(0, v) \quad (5)$$

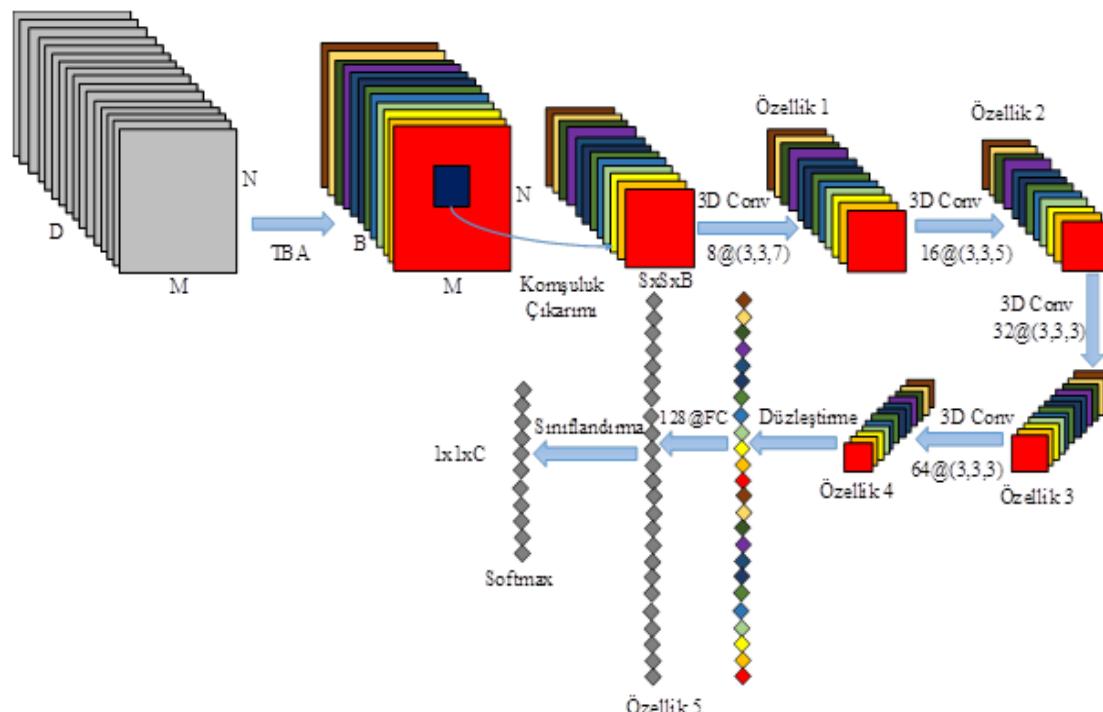
Softmax, sınıflandırma için bir derin öğrenme modelinin son katmanında genellikle kullanılan başka bir etkinleştirme işlevidir. Softmax, tüm örneklerin olasılık dağılımını üretir ve toplamı bire eşittir.

4. ÖNERİLEN YÖNTEM (PROPOSED METHOD)

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. Giriş görüntüsünün ground truth'u Y , one-hot encoding kullanılarak dönüştürülür ve $Y = (y_1, y_2, \dots, y_C)$ olarak gösterilir. Burada C , girdi görüntüsünde bulunan sınıfların sayısını belirtmektedir. Hiperspektral UA görüntü pikselleri, herhangi bir sınıflandırma modeli için yoğun çaba gerektiren yüksek sınıflar arası benzerlik, yüksek sınıf içi değişkenlik, üst üste binen ve iç içe bölgeler sergilemektedir. Bu sorunların üstesinden gelmek için spektral fazlalığı gidermek gerekmektedir. Spektral fazlalığını gidermek için ilk önce orjinal hiperspektral UA görüntüsüne spektral bantlar boyunca geleneksel temel bileşen analizi (TBA) uygulanır. TBA, aynı uzamsal boyutları (yani, genişlik M ve yükseklik N) korurken spektral bant sayısını D 'den B' ye düşürür. Herhangi bir nesneyi tanıtmak için çok önemli olan uzamsal bilgiyi koruyacak şekilde yalnızca spektral bantları azaltılmış oldu. Böylelikle, istenilen bant sayısına indirgenmiş oldu. 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 $S \times S \times B$ penceresini veya uzamsal boyutu ve tüm B spektral bantlarını kapsayan hiperspektral veri

küpünden 3B komşu parçaları $S \times S \times B$ oluşturuldu. Hiperspektral veri küpünden üretilen toplam 3B parça sayısı (n), $(M - S + 1)x(N - S + 1)$ ile bulunur. 3B ESA, 3B evrişim çekirdeğini kullanarak her bir görüntü parçasını 3B evrişim işlemeye 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 uygulanmaktadır [13, 14, 22]. Önerilen 4CF-Net modelinin akış diyagramı Şekil 2'de gösterilmektedir.

4CF-Net modeli, 4 3B ESA, düzleştirme ve bir tam bağlı katmandan oluşmaktadır. Maksimum spektral ve uzamsal bilgiyi korumak için ESA'daki havuz katmanı kullanılmamaktır. Uygulanan 3B evrişim çekirdeklерinin boyutları ve kullanılan filtreler şu şekildedir. 1. evrişim katmandada $3 \times 3 \times 7$ (yani; iki uzamsal ve bir spektral boyut) boyutunda 8 filtre, 2. evrişim katmanında $3 \times 3 \times 5$ boyutunda 16 filtre, 3. evrişim katmanında $3 \times 3 \times 3$ boyutunda 32 filtre ve 4. evrişim katmanında $3 \times 3 \times 3$ boyutunda 64 filtre kullanılmaktadır. Tüm evrişim katmanlarında padding = 'valid' kullanılır, böylece her evrişimden sonra özellik haritasının boyutu azaltılmış olur. ReLU aktivasyon fonksiyonu tüm evrişim katmanlarında kullanılır. 3B Evrişim katmanlarından sonra çıkarılan özellikler düzeltirilir ve sınıflandırma için tam bağlı katmanlara girdi olarak verilir. Bu modelde, 128 nöron bulunan bir tane tam bağlı katman kullanılmaktadır. Tam bağlı katmanın (FC) çıktısı, gerekli sınıflandırma sonucunu oluşturmak için basit



Şekil 2. Hiperspektral görüntü sınıflandırması için önerilen 4CF-Net modeli
(Proposed 4CF-Net model for hyperspectral image classification)

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, Salinas veri kümesindeki sınıfların sayısı ile aynı olan 16'dır. Dolayısıyla, önerilen modeldeki toplam parametre sayısı, bir veri kümesindeki sınıfların sayısına bağlıdır. Salinas veri seti için 4CF-Net'teki toplam eğitilebilir ağırlık parametresi sayısı 2,445,184'tür. 0.001 öğrenme oranına sahip kategorik çaprazentropi ve optimizasyon için kullanılan 1e-06 bozunma işlevine sahip Adam optimizer kullanılmıştır. Eğitim süreci, herhangi bir batch normalization ve veri artırımı (data augmentation) olmaksızın 256 batch size 100 epoch boyunca tekrar etmektedir.

5. DENEYSEL VERİ SETLERİ VE SONUÇLAR (EXPERIMENTAL DATASETS AND RESULTS)

Önerilen yöntemin etkinliğini göstermek için Indian Pines (IP), Pavia Üniversitesi (PU), Salinas (SA) ve Kennedy Uzay Merkezi (KUM) veri setlerini içeren dört gerçek hiperspektral veri kümesi kullanılmıştır [34]. Indian pines veriseti, Kuzeybatı Indiana'daki Indian Pines test alanında Havadan Görünür / Kızılıötesi Görüntüleme Spektrometresi (Airborne Visible/Infrared Imaging Spectrometer-AVIRIS) sensörü tarafından elde edilmiştir. Bu verisetindeki her spektral görüntü 145×145 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) bölgesinde ve bunlar sınıflandırma işlemi için yararlı değildir. 24 su emme bandı çıkarıldıkten sonra kalan 200 bant deneyler için kullanılmıştır. IP veri seti 16 tür arazi örtüsü ve 10.249 örnek içermektedir. Şekil 3'te,

(a) Indian Pines veri setinin yanlış renkli bir görüntüsü ve (b) Indian Pines veri setinin bir temel gerçek haritası gösterilmektedir.

Pavia Üniversitesi 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 gürültü bandı çıkarıldıktan sonra, kalan 103 bant deneyde kullanılmıştır. PU veriseti, 9 tür arazi örtüsü ve 42.776 örnek içermektedir. Şekil 4'te, (a) PU verisetinin yanlış renkli bir görüntüsü ve (b) PU verisetinin temel doğruluk haritası gösterilmektedir.

KUM veriseti, Florida üzerinden AVIRIS tarafından toplanmıştır. Veriseti, piksel başına 18 metre uzamsal çözünürlüğe sahip, 614 piksel genişliğinde ve 512 piksel yüksekliğinde bir uzaktan algılama görüntüsündür. Düşük sinyal-gürültü oranına sahip bantlar ve su emme bantları kaldırıldıktan sonra, deneyde kalan 176 bant verisi kullanılmıştır. KUM veri seti, toplam 13 tür arazi örtüsü ve 5211 örnek içermektedir. Şekil 5'te, (a) KUM veri setinin yanlış renkli bir görüntüsü ve (b) KUM veri setinin bir temel gerçek haritası gösterilmektedir.

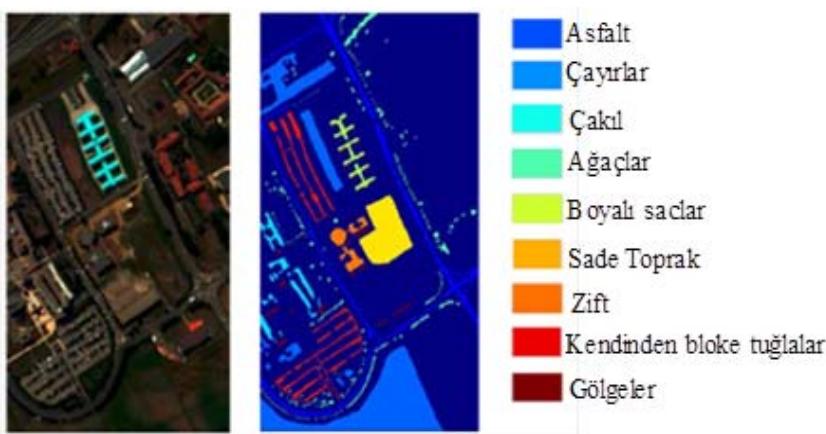
Salinas veriseti, California, Salinas Valley üzerinden AVIRIS sensörü tarafından toplanmıştır. Veriseti, piksel başına 3.7 metre uzamsal çözünürlüğe sahiptir. 224 bant içeren, 217 piksel genişliğinde ve 512 piksel yüksekliğinde bir uzaktan algılama görüntüsündür. 20 su emme bandı çıkarıldıktan sonra kalan 204 bant deneyde kullanılmıştır.

Tablo 1. SA veriseti için önerilen 4CF-Net modelinin özeti (Summary of the proposed 4CF-Net model for the SA dataset)

Katman (Tip)	Çıkış Boyutu	Parametre Sayısı
input_1 (Giriş katmanı)	(25,25,15,1)	0
conv3d_1 (Conv3d)	(23,23,9,8)	512
conv3d_2 (Conv3d)	(21,21,5,16)	5776
conv3d_3 (Conv3d)	(19,19,3,32)	13856
conv3d_4 (Conv3d)	(17,17,1,64)	55360
flatten_1 (Flatten)	18496	0
dense_1 (Dense)	128	2367616
dense_2 (Dense)	16	2064
Toplam Eğitilebilir Parametreler : 2,445,184		

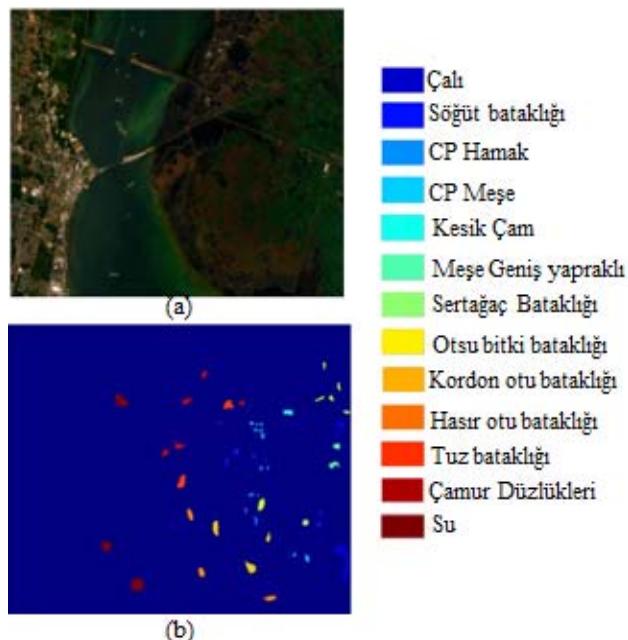


Şekil 3. Indian pines veriseti. (a) Indian pines verilerinin yanlış renkli görüntüsü. (b) Indian pines temel gerçeği haritası (Indian pines dataset. (a) False-color image of the Indian pines data. (b) Ground-truth map of the Indian pines)



Şekil 4. Pavia üniversitesi veriseti. (a) Pavia üniversitesi verilerinin yanlış renkli görüntüsü. (b) Pavia üniversitesi temel gerçeği haritası
(Pavia university dataset. (a) False-color image of the Pavia university data. (b) Ground-truth map of the Pavia university)

Salinas veri seti, toplam 16 tür arazi örtüsü ve 54.129 örnek içermektedir. Şekil 6'da, (a) Salinas verisetinin yanlış renkli bir görüntüsü ve (b) Salinas verisetinin bir yer gerçeği haritası gösterilmektedir.



Şekil 5. Kennedy uzay merkezi veriseti. (a) Kennedy uzay merkezi verilerinin yanlış renkli görüntüsü. (b) Kennedy uzay merkezi temel gerçeği haritası
(Kennedy space center dataset. (a) False-color image of the Kennedy space center data. (b) Ground-truth map of the Kennedy space center)

Tüm deneyler Google Colab olarak bilinen çevrimiçi bir platformda gerçekleştirilmiştir. Google Colab, herhangi bir ortamı çalıştmak 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

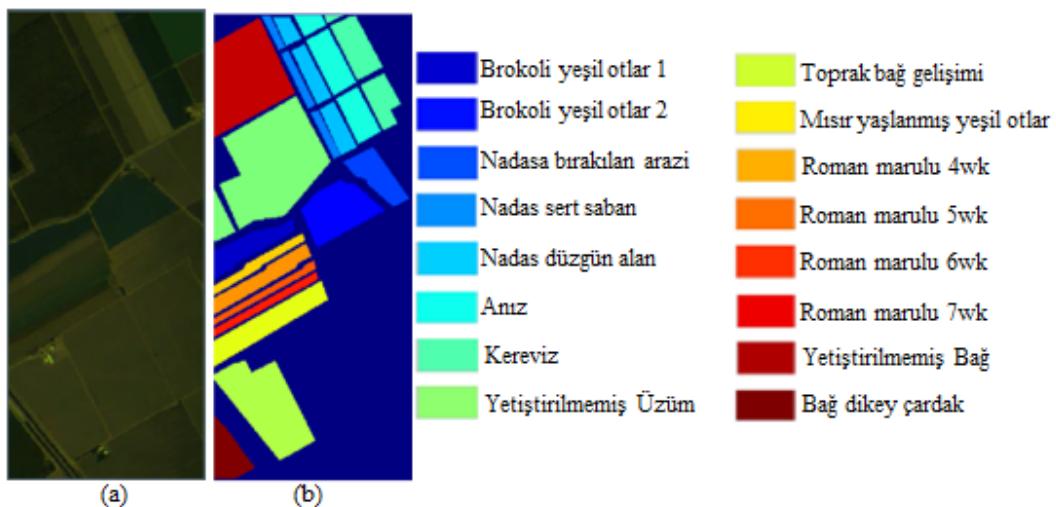
seçenek sunmaktadır. Tüm deneylerde, test-eğitim seti %30-70 oranına bölünmüştür. 0.001 öğrenme oranına sahip kategorik çaprazentropi ve optimizasyon için kullanılan 1e-06 bozunma işlevine sahip Adam optimizer kullanılmıştır. Eğitim süreci, 256 batch size ve 100 epochs boyunca tekrar etmektedir. Softmax'in kullanıldığı son katman hariç tüm katmanlar için bir aktivasyon işlevi olarak relu kullanılmaktadır. Dört verisetinin tümü, evrişim için 25×25 komşuluk kullanmaktadır. Bununla birlikte, TBA tekniğinden sonra çıkarılan bantların sayısı her veriseti için farklılık göstermektedir. IP, 30 temel bileşen kullanmaktadır. PU, SA ve KUM, özellik çıkarma için ilk 15 temel bileşeni kullanmaktadır. 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, f1 skoru (f1-score), hassasiyet (precision) ve geri çağrıma (recall) gibi çeşitli istatistiksel testler de dikkate alınmaktadır.

Önerilen yöntem literatürden, geleneksel DVM sınıflandırıcısından başlayarak 3B ESA, ResNet, SSRN, DFFN, MPRN ve MSSN gibi derin öğrenmeye dayalı hiperspektral UA görüntülerini sınıflandırma yöntemleri ile karşılaştırılmıştır [26]. DVM, sınıflandırma için kullanılabilen geleneksel ve klasik bir makine öğrenme yöntemidir. DVM, yüksek sınıflandırma doğruluğu sağlar ve hassasiyeti eğitimin örneklerinin sayısı ile daha azdır. Bu nedenle, bu çalışma sonuç karşılaştırması için mevcut sınıflandırma modellerinden biri olarak DVM'yi seçmektedir. 3B ESA, üç boyutlu evrişim çekirdeklerini kullanarak eş zamanlı olarak hiperspektral görüntülerden spektral ve uzamsal özelliklerini çıkarmaktadır. 3B ESA modeli, her piksel için $K \times K \times B$ komşuluğunu seçmektedir. Aynı zamanda, üç boyutlu evrişim ve havuzlama

gerçekleştirmektedir. Aktivasyon işlevi olarak ReLU ve ağırlıkları güncellemek için mini batch güncelleme tekniğini kullanmaktadır. Dropout tekniğinin kullanılması, modelde aşırı uyumu (overfitting) azaltmaktadır. ResNet, geri yayılım için yararlı olan hiperspektral görüntülerden zengin özellikler çıkarmak için kendi kendini haritalama fikrini kullanmaktadır. SSRN, üç boyutlu evrişim ile elde edilen spektral özellikleri ve iki boyutlu evrişim ile elde edilen uzamsal özellikleri kademeli bir şekilde birleştirerek modelin sürekli olarak spektral özellikleri ve uzamsal özellikler çıkarabilmesini sağlamaktadır. 3B ESA modeline benzer ve eğitim sürecinin düzenlenmesi için toplu normalleştirme (batch normalization) ve %50 bırakma (dropout) kullanır. Evrişimli katmanların artmasıyla sınıflandırma doğruluğunu azaltmak için artık

bloklar kullanılmaktadır. DFFN, ResNet tarafından çıkarılan özelliklerini sınıflandırma için farklı seviyelerde birleştirmektedir. DFFN, hesaplama maliyetini düşürebilecek en bilgilendirici bileşenleri çıkarmak için hiperspektral verilere TBA uygulamaktadır. MPRN, özellik çıkarımı için daha derin bir ağ yerine daha geniş bir artık ağın kullanılmasını önermektedir. MSSN, çok ölçekli ve çok seviyeli spektral uzamsal özellik füzyon ağını önermektedir. MSSN'de, ağır girdisi olarak farklı ölçekli komşuluk blokları kullanılarak, farklı ölçeklerin spektral uzamsal özellikleri etkin bir şekilde çıkarılabilmektedir.

Tablo 2, Indian pines verisetinden elde edilen çeşitli yöntemlerin GD, OD ve K olmak üzere üç değerlendirme göstergesine göre sınıflandırma sonuçlarını vermektedir.

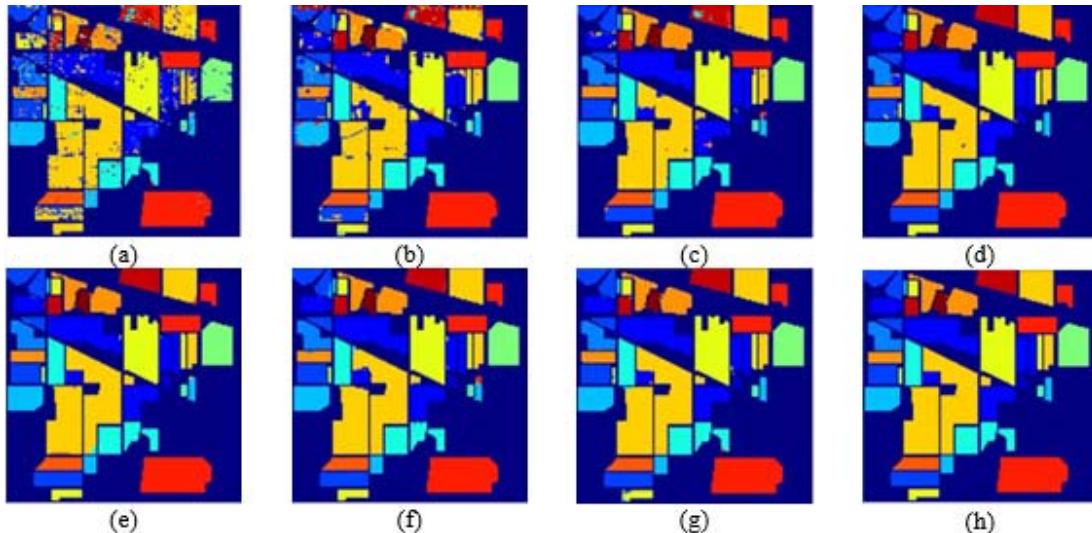


Şekil 6. Salinas veriseti. (a) Salinas verilerinin yanlış renkli görüntüsü. (b) Salinas temel gerçeği haritası
(Salinas dataset. (a) False-color image of the Salinas data. (b) Ground-truth map of the Salinas)

Tablo 2. IP verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları
(Classification results obtained with different methods in IP dataset) (%)

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	83,33	59,52	94,44	97,37	100	100	97,14	100
2	72,78	91,60	96,03	99,35	98,88	99,39	99,41	100
3	65,19	87,01	98,22	97,62	99,41	97,93	99,45	100
4	63,08	85,98	95,36	79,98	100	98,97	97,93	100
5	90,57	88,51	95,04	98,98	98,43	95,30	100	100
6	95,59	98,93	99,65	98,66	99,99	99,47	99,14	100
7	69,23	84,62	100	90,48	100	100	100	100
8	93,51	100	100	100	100	100	100	100
9	72,22	94,44	66,67	94,44	80	93,33	88,24	100
10	71,09	84	98,45	97,64	99,51	99,74	97,51	100
11	86,11	91,04	95,64	98,66	98,18	97,82	99,2	100
12	72,28	76,03	98,59	98,32	98,15	98,36	98,91	100
13	96,76	99,46	96,43	100	100	100	100	100
14	97,89	97,54	99,71	98,33	100	100	100	100
15	47,71	77,87	85,64	100	99,98	97,71	99,67	99,13
16	80,95	97,62	95,83	98,65	95,83	97,22	91,02	96,42
GD	81,18	90,38	96,92	98,22	99,06	98,71	99,12	99,93
OD	78,64	88,39	96,73	98,08	98,24	98,34	99,23	99,72
K	78,36	89,03	96,49	97,97	98,93	98,34	99,02	99,92

Şekil 7, Indian pines verisetini kullanan yedi algoritma ile önerilen yöntemin (4CF-Net) sınıflandırma haritasını göstermektedir. Tablo 2'den, önerilen yöntemin 15 nolu sınıf için sınıflandırma doğruluğu SSRN, DFFN ve MSSN yöntemlerinden daha düşük çıkmıştır. Aynı şekilde 16 nolu sınıf için sınıflandırma doğruluğu 3B ESA, SSRN ve MPRN yöntemlerinden düşük çıkmıştır. 15 ve 16 nolu sınıflar için sınıflandırma doğruluğu önerilen yöntemde düşük çıkışına rağmen, GD, OD ve K değerlendirme ölçütleri göz önüne alındığında diğer yöntemlerin tamamından yüksek sonuçlar elde edilmiştir. Önerilen yöntemin GD sonucu geleneksel klasik yöntemler olan DVM, 3B ESA ve ResNet'ten sırasıyla, %18,75, %9,55 ve %3,01 daha yüksek olduğu görülmektedir. Önerilen yöntem ayrıca, GD açısından sırasıyla, %1,71, %0,87, %1,22 ve %0,81 ile en gelişmiş SSRN, DFFN, MPRN ve MSSN yöntemlerinden daha iyi performans göstermektedir. Tablo 2 ve Şekil 7 göz önünde bulundurulduğunda, önerilen yöntemin sınıflandırma sonuçları temel gerçeğe (ground truth) çok benzerdir.



Şekil 7. IP verisi için sınıflandırma haritaları. (a) DVM (b) 3B ESA (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net

(Classification maps for IP dataset. (a) SVM (b) 3D CNN (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net)

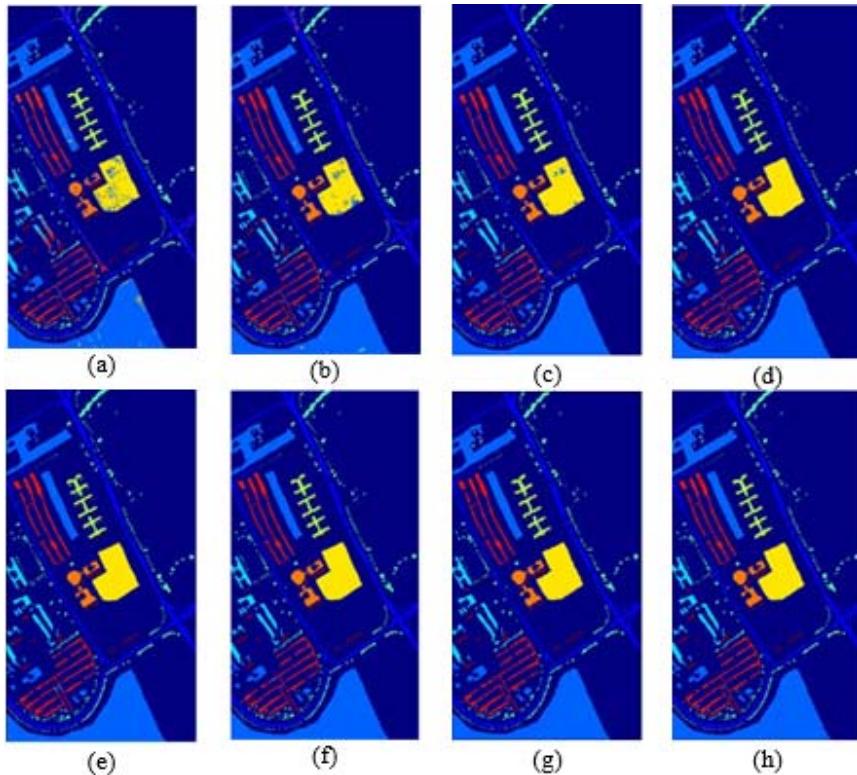
Tablo 3. PU verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları
(Classification results obtained with different methods in PU dataset) (%)

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	92,87	95,84	98,81	99,94	99,78	99,89	99,98	100
2	98,09	98,79	99,95	100	100	99,98	100	100
3	74,03	87,42	92,93	94,21	98,79	99,68	99,1	100
4	94,68	96,39	99,64	98,26	96,55	98,76	99,96	100
5	99,37	99,14	99,83	99,51	99,01	99,42	100	100
6	85,72	91,27	96,20	100	100	100	100	100
7	83,07	93,35	96,57	99,58	99,49	100	99,92	100
8	90,74	95,77	95,98	99,43	98,46	99,45	99,91	100
9	99,78	97	99,88	100	90,49	98,59	100	99,64
GD	93,38	96,26	98,51	99,51	99,27	98,71	99,94	99,99
OD	90,93	94,99	98,19	99,49	98,63	98,34	99,93	99,96
K	91,18	95,03	98,03	97,97	99,03	98,34	99,92	99,99

Tablo 3, Pavia üniversitesi verisetinden elde edilen çeşitli yöntemlerin sınıflandırma sonuçlarını vermektedir. Şekil 8, önerilen yöntem ile karşılaştırılan tüm yöntemlerin sınıflandırma haritalarını göstermektedir. Tablo 3'ten, önerilen yöntemin 9 nolu sınıf için sınıflandırma doğruluğu SSRN ve MSSN yöntemlerinden daha düşük çıkmıştır. Ancak diğer 8 sınıf için sınıflandırma doğruluğu SSRN, DFFN ve MSSN ile aynı çıkarken, DVM, 3B ESA, ResNet ve MPRN yöntemlerinden daha yüksek çıkmıştır. 9 nolu sınıf için sınıflandırma doğruluğu önerilen yöntemde düşük çıkışına rağmen, GD, OD ve K değerlendirme ölçütleri göz önüne alındığında diğer yöntemlerin tamamından yüksek sonuçlar elde edilmiştir. Önerilen yöntemin GD sonucu geleneksel klasik yöntemler olan DVM, 3B ESA ve ResNet'ten sırasıyla, %6,61, %3,73 ve %1,48 daha yüksek olduğu görülmektedir. Önerilen yöntem ayrıca, GD açısından sırasıyla, %0,48, %0,72, %1,28 ve %0,05 ile en gelişmiş SSRN, DFFN, MPRN ve MSSN yöntemlerinden daha iyi performans göstermektedir. Tablo 3 ve Şekil 8 göz

önünde bulundurulduğunda, önerilen yöntemin sınıflandırma sonuçları temel gerçek (ground truth) ile hemen hemen aynıdır. Tablo 4, Salinas veriseti için sınıflandırma sonuçlarını ve Şekil 9 ise sınıflandırma haritalarını göstermektedir. Tablo 4'ten, önerilen yöntemin

tüm sınıflar için en iyi sınıflandırma doğruluğunu elde edildiği görülmektedir. Önerilen yöntemin GD sonucu geleneksel klasik yöntemler olan DVM, 3B ESA ve ResNet'ten sırasıyla, %10,65, %4,44 ve %3,09 daha yüksek olduğu görülmektedir. Önerilen yöntem ayrıca, GD



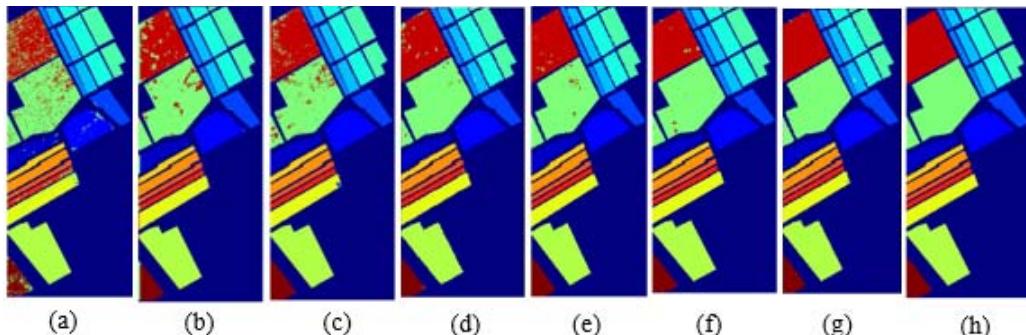
Şekil 8. PU veriseti için sınıflandırma haritaları. (a) DVM (b) 3B ESA (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net

(Classification maps for PU dataset. (a) SVM (b) 3D CNN (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net)

Tablo 4. SA verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları
(Classification results obtained with different methods in SA dataset) (%)

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	96,8	95,29	99,83	100	100	100	100	100
2	97,01	99,80	100	100	100	100	100	100
3	99,31	99,57	100	100	100	100	100	100
4	98,04	97,58	99,87	99,84	99,52	99,36	99,91	100
5	96,58	99,84	99,75	99,29	99,96	99,75	98,3	100
6	95,93	99,04	100	100	100	100	100	100
7	97,03	97,94	99,93	100	100	100	99,97	100
8	82,96	93,68	91,86	98,39	98,73	99,49	99,92	100
9	98,79	98,61	99,85	100	100	100	100	100
10	87,12	94,09	97,15	100	99,39	100	99,73	100
11	91,23	94,98	99,07	99,16	97,51	99,48	99,79	100
12	98,96	99,62	100	100	99,54	100	100	100
13	93,69	96,9	100	100	100	99,88	100	100
14	85,55	94,99	99,47	98,76	99,37	100	99,69	100
15	69,04	87,31	91,38	95,72	98,33	98,37	99,76	100
16	89,34	95,34	99,94	99,69	99,87	100	100	100
GD	89,35	95,56	96,91	99,01	99,38	99,63	99,84	100
OD	92,34	96,54	98,31	99,57	99,51	99,79	99,88	100
K	88,09	95,06	96,55	98,89	99,31	99,59	99,82	100

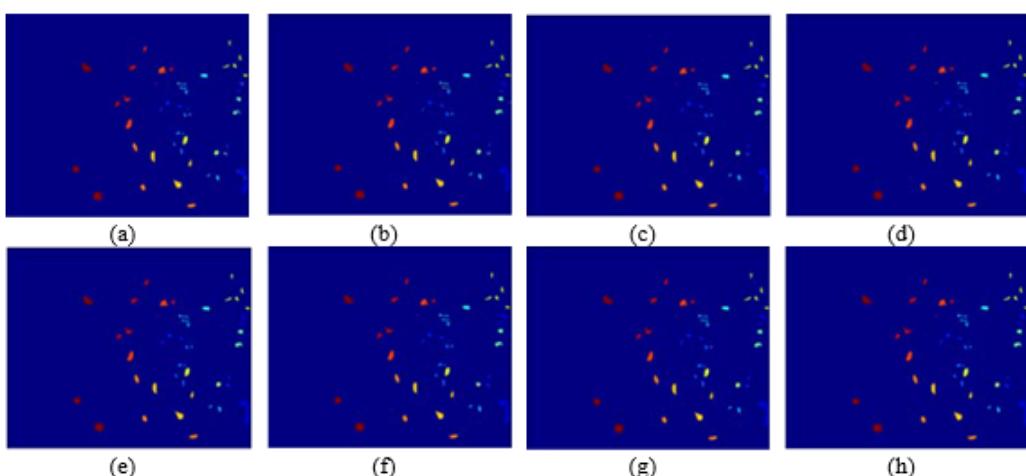
açısından sırasıyla, %0,99, %0,62, %0,37 ve %0,16 ile en gelişmiş SSRN, DFFN, MPRN ve MSSN yöntemlerinden daha iyi performans göstermektedir. Şekil 9'dan önerilen yöntem tarafından üretilen sınıflandırma sonuçlarının temel gerçek (ground truth) ile aynı elde edildiği görülmektedir.



Şekil 9. SA veriseti için sınıflandırma haritaları. (a) DVM (b) 3B ESA (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net
(Classification maps for SA dataset. (a) SVM (b) 3D CNN (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net)

Tablo 5. KUM verisetinde farklı yöntemlerle elde edilen sınıflandırma sonuçları
(Classification results obtained with different methods in KUM dataset) (%)

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	95,18	97,81	97,26	99,84	98,19	100	100	100
2	86,31	87,21	94,57	100	100	100	100	100
3	83,55	95,24	97,38	94,76	100	100	99,01	100
4	73,57	63,87	75,74	95,05	96,91	93,81	100	97,36
5	59,31	80,69	82,81	87,5	100	99,24	91,41	100
6	69,57	87,92	85,64	97,34	100	100	100	98,55
7	92,63	92,63	91,76	100	100	72,62	100	100
8	93,81	97,68	97,37	100	99,71	100	100	100
9	98,08	96,79	100	100	100	100	100	100
10	91,21	94,23	100	100	100	100	100	100
11	95,77	98,41	100	100	100	100	100	100
12	91,83	95,36	99,01	98,76	100	99,49	100	100
13	99,28	96,29	100	100	100	100	100	100
GD	91,18	93,63	96,39	98,87	99,56	99,08	99,68	99,81
OD	86,93	91,09	93,01	98,14	99,23	98,46	99,54	99,68
K	90,17	92,92	95,98	98,74	99,52	98,98	99,65	99,78



Şekil 10. KUM veriseti için sınıflandırma haritaları. (a) DVM (b) 3B ESA (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net
(Classification maps for KUM dataset. (a) SVM (b) 3D CNN (c) ResNet (d) SSRN (e) DFFN (f) MPRN (g) MSSN (h) 4CF-Net)

Tablo 5'de, Kennedy uzay merkezi verisetinden elde edilen çeşitli yöntemlerin sınıflandırma sonuçlarına yer verilmektedir. Şekil 10 ise, tüm yöntemlerin elde edilen sınıflandırma haritalarını göstermektedir. Tablo 5'ten, önerilen yöntemin 4 nolu sınıf için sınıflandırma doğruluğu

MSSN yönteminden %2,64 daha düşük çıkmıştır. Ayrıca, 6 nolu sınıf için sınıflandırma doğruluğu DFFN, MPRN ve MSSN yöntemlerinden %1,45 daha düşük çıkmıştır. Ancak diğer 11 sınıf için önerilen yöntem ile elde edilen sınıflandırma doğruluğu %100 elde edilmiştir. 4 ve 6 nolu sınıflar için sınıflandırma doğruluğu önerilen yöntemde düşük çıkışmasına rağmen, GD, OD ve K değerlendirme ölçütleri göz önüne alındığında diğer yöntemlerin tamamından yüksek sonuçlar elde edilmiştir. Önerilen yöntemin GD sonucu geleneksel klasik yöntemler olan DVM, 3B ESA ve ResNet'ten sırasıyla, %8,63, %6,18 ve %3,42 daha yüksek olduğu görülmektedir. Önerilen yöntem ayrıca, GD açısından sırasıyla, %0,94, %0,25, %0,73 ve %0,13 ile en gelişmiş SSRN, DFFN, MPRN ve MSSN yöntemlerinden daha iyi performans göstermektedir. Önerilen yöntemin diğer yöntemlere kıyasla hemen hemen her sınıf için en iyi sınıflandırma sonucunu elde ettiğini gözlemlayabiliyoruz. Tablo 5 ve Şekil 10 göz önünde bulundurulduğunda, önerilen yöntemin sınıflandırma sonuçları temel gerçeğe (ground truth) çok benzerdir. Genel olarak, önerilen yöntem (4CF-Net) çoğu kategoride en iyi sınıflandırma performansını elde etmiştir. Aynı zamanda, GD, OD ve Kappa açısından en iyi sınıflandırma sonuçlarını elde etmiştir.

6. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, hiperspektral UA görüntü sınıflandırmasını iyileştirmek amacıyla, hiperspektral görüntü verilerinde bulunan hem spektral hem de uzamsal bilgilerden tam olarak yararlanan yeni bir 3B ESA hiperspektral görüntü sınıflandırma yöntemi önerilmiştir. Önerilen model, ard arda 4 3B evrişim işleminden, düzleştirme katmanından ve bir tane tam bağlantılı katmandan oluşmaktadır. Maksimum spektral ve uzamsal bilgiyi korumak için ESA'daki havuz katmanı kullanılmamaktadır. Hiperspektral görüntülerdeki spektral fazlalığı gidermek için TBA boyut indirgeme yöntemi kullanılmıştır. 3B ESA modellerinin, sınıflandırma için hiperspektral görüntünün 3B yapısına uyacak şekilde uyarlanabileceği gösterilmiştir. Özellikle, 3B ESA yaklaşımımız dört popüler hiperspektral kıyaslama veri setinde, son teknoloji ürünü derin öğrenmeye dayalı 7 hiperspektral görüntü sınıflandırma yöntemiyle karşılaştırıldı. Tablo 2-5 incelendiğinde, Indian pines veri seti için GD, OD ve K sırasıyla, %99,93, %99,72 ve %99,92 olarak elde edilmiştir. Pavia Üniversitesi için %99,99, %99,96 ve %99,99 olarak elde edilmiştir. Salinas veri seti için tüm değerlendirme ölçütlerinde %100 sonuç bulunmuştur. Kennedy uzay merkezi veriseti için ise %99,81, %99,68 ve %99,78 sonuçları elde edilmiştir. Deneyim çalışmalar, önerilen 3B ESA tabanlı hiperspektral görüntü sınıflandırma yönteminin dört veri setinin tümünde en iyi genel doğruluğu, ortalama doğruluğu ve kappa katsayısını elde ettiğini göstermektedir. Gelecek çalışmalarla öncelikle 3D CNN ile 2D CNN'nin beraber kullanıldığı HibridCNN'ler ve farklı derin öğrenme yöntemleri üzerinde çalışmaların yürütülmesi planlanmaktadır.

KAYNAKLAR (REFERENCES)

- Dou P. and Zeng C., Hyperspectral image classification using feature relations map learning, *Remote Sens.*, 12 (18), 2020.
- Jia J., Wang Y., Chen J., Guo R., Shu R., and Wang J., Status and application of advanced airborne hyperspectral imaging technology: A review, *Infrared Phys. Technol.*, 104, 103-115, 2020.
- Sun H., Ren J., Zhao H., Yan Y., Zabalza J., and Marshall S., Superpixel based feature specific sparse representation for spectral-spatial classification of hyperspectral images, *Remote Sens.*, 11 (5), 2019.
- Audebert N., Le Saux B., and Lefèvre S., Deep learning for classification of hyperspectral data: A comparative review, *arXiv*, 2019.
- Yang D. and Bao W., Group Lasso-Based Band Selection for Hyperspectral Image Classification, *IEEE Geosci. Remote Sens. Lett.*, 14 (12), 2438–2442, 2017.
- Kang X., Duan P., and Li S., Hyperspectral image visualization with edge-preserving filtering and principal component analysis, *Inf. Fusion*, 57, 130–143, 2020.
- Xu H., Zhang H., He W., and Zhang L., Superpixel-based spatial-spectral dimension reduction for hyperspectral imagery classification, *Neurocomputing*, 360, 138–150, 2019.
- Hanbay K., Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (1), 443–456, 2020.
- Ahmad M. et al., Spatial prior fuzziness pool-based interactive classification of hyperspectral images, *Remote Sens.*, 11 (9), 1–19, 2019.
- Wang Y., Yu W., and Fang Z., Multiple Kernel-based SVM classification of hyperspectral images by combining spectral, spatial, and semantic information, *Remote Sens.*, 12 (1), 2020.
- Alcolea A., Paoletti M. E., Haut J. M., Resano J., and Plaza A., Inference in supervised spectral classifiers for on-board hyperspectral imaging: An overview, *Remote Sens.*, 12 (3), 1–29, 2020.
- Li Y., Zhang H., and Shen Q., Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network, *Remote Sens.*, 9 (1), 2017.
- Ahmad M., Khan A. M., Mazzara M., Distefano S., Ali M., and Sarfraz M.S., A Fast and Compact 3-D CNN for Hyperspectral Image Classification, *IEEE Geosci. Remote Sens. Lett.*, 1–5, 2020.
- Mohan A. and Venkatesan M., HybridCNN based hyperspectral image classification using multiscale spatirospectral features, *Infrared Phys. Technol.*, 108, 2020.
- Zhao C., Wan X., Zhao G., Cui B., Liu W., and Qi B., Spectral-Spatial Classification of Hyperspectral Imagery Based on Stacked Sparse Autoencoder and

- Random Forest, *Eur. J. Remote Sens.*, 50 (1), 47–63, 2017.
16. Chen Y., Lin Z., Zhao X., Wang G., and Gu Y., Deep learning-based classification of hyperspectral data, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 7 (6), 2094–2107, 2014.
 17. Mughees A. and Tao L., Efficient deep auto-encoder learning for the classification of hyperspectral images, 2016 International Conference on Virtual Reality and Visualization, ICVRV 2016, Hangzhou-China, 44–51, 24-26 September, 2016.
 18. Ma X., Geng J., and Wang H., Hyperspectral image classification via contextual deep learning, *Eurasip J. Image Video Process.*, 2015 (1), 2015.
 19. Chen Y., Zhao X., and Jia X., Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 8 (6), 2381–2392, 2015.
 20. Li J., Xi B., Li Y., Du Q., and Wang K., Hyperspectral classification based on texture feature enhancement and deep belief networks, *Remote Sens.*, 10 (3), 2018.
 21. Chen C. et al., Hyperspectral classification based on spectral-spatial convolutional neural networks, *Eng. Appl. Artif. Intell.*, 68, 165–171, 2018.
 22. Roy S. K., Krishna G., Dubey S. R., and Chaudhuri B. B., HybridSN: Exploring 3D-2D CNN Feature Hierarchy for Hyperspectral Image Classification, *arXiv*, 17 (2), 277–281, 2019.
 23. Zhong Z., Li J., Luo Z., and Chapman M., Spectral-Spatial Residual Network for Hyperspectral Image Classification: A 3-D Deep Learning Framework, *IEEE Trans. Geosci. Remote Sens.*, 56 (2), 847–858, 2018.
 24. Song L., Li W., Fang S., Hyperspectral Image Classification with Deep Feature Fusion Network, *IEEE Trans. Geosci. Remote Sens.*, 99, 3173–3184, 2018.
 25. Meng Z., Li L., Tang X., Feng Z., Jiao L., and Liang M., Multipath residual network for spectral-spatial hyperspectral image classification, *Remote Sens.*, 11 (16), 1–19, 2019.
 26. Mu C., Guo Z., and Liu Y., A multi-scale and multi-level spectral-spatial feature fusion network for hyperspectral image classification, *Remote Sens.*, 12 (1), 2020.
 27. Paoletti M. E., Haut J. M., Plaza J., and Plaza A., A new deep convolutional neural network for fast hyperspectral image classification, *ISPRS J. Photogramm. Remote Sens.*, 145, 120–147, 2018.
 28. Li S., Song W., Fang L., Chen Y., Ghamisi P., and Benediktsson J. A., Deep Learning for Hyperspectral Image Classification: An Overview, *arXiv*, 57 (9), 6690–6709, 2019.
 29. Huang L. and Chen Y., Dual-Path Siamese CNN for Hyperspectral Image Classification With Limited Training Samples, *IEEE Geosci. Remote Sens. Lett.*, 18 (3), 1–5, 2020.
 30. Chen P., Jiang Y., Li H., Jia C., Ghamisi X., Deep feature extraction and classification of hyperspectral images based on convolutional neural networks, *IEEE Trans. Geosci. Remote Sens.*, 54 (10), 6232–6251, 2016.
 31. Zhang Y., Jiang X., Wang X., and Cai Z., Spectral-spatial hyperspectral image classification with superpixel pattern and extreme learning machine, *Remote Sens.*, 11 (17), 2019.
 32. Appice A. and Malerba D., Segmentation-aided classification of hyperspectral data using spatial dependency of spectral bands, *ISPRS J. Photogramm. Remote Sens.*, 147, 215–231, 2019.
 33. Uddin M. P., Al Mamun M., and Hossain M. A., PCA-based Feature Reduction for Hyperspectral Remote Sensing Image Classification, *IETE Tech. Rev.* (Institution Electron. Telecommun. Eng. India), 1–21, 2020.
 34. Grupo De Inteligencia Computacional (GIC), Hyperspectral Remote Sensing Scenes, http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes. Erişim tarihi Mart 17, 2021.

