




Depthwise Separable Convolution Based Residual Network Architecture for Hyperspectral Image Classification

Hüseyin FIRAT^{1,*}  Mehmet Emin ASKER²  Davut HANBAY³ 

¹Dicle University, Vocational School of Technical Sciences, Department of Computer Technologies, 21280, Sur/DIYARBAKIR

²Dicle University, Vocational School of Technical Sciences, Department of Electricity and Energy, 21280, Sur/DIYARBAKIR

³Inonu University, Faculty of Engineering, Department of Computer Engineering, 44280, Merkez/MALATYA

Graphical/Tabular Abstract

In this study, a method in which 3D/2D CNN, Residual network architecture and Depthwise separable convolution (DSC) are used together, is proposed for classification of Hyperspectral remote sensing images (HRSIs). The architecture of the proposed method is presented in Figure A.




Figure A. Schema of the Proposed Method

Purpose: Classification of each pixel in HRSIs is great importance task. Many manual or self-learning classification methods have been proposed for HRSI classification (HRSIC). Manually extracting spatial-spectral features in HRSIC reduces the classification accuracy. For this, studies have been carried out on methods that automatically extract features. In this direction, the use of deep learning methods takes HRSIC to a new level. For this purpose, a deep learning-based method has been developed for HRSIC that works with high accuracy.

Theory and Methods: In this study, a method was developed for HRSIC in which 3D/2D CNN, residual network and DSC are used together. Thanks to the residual network, problems such as degradation and vanishing gradients that may occur in deep networks are overcome. On the other hand, DSC are used, which reduces the computational cost, prevents overfitting and provides more spatial feature extraction. Finally, spatial-spectral features are extracted simultaneously from HRSIs with 3D CNN. However, using only 3D CNN increases computational complexity. By using only 2D CNN, only spatial features are extracted from HRSIs. Spectral features cannot be extracted. By using 3D CNN and 2D CNN together, these two problems are solved. In addition, principal component analysis is used as a preprocessing step for optimum spectral band extraction in the proposed method.

Results: Indian pines and Salinas datasets were used to test the performance of the proposed method. As a result of the performed applications, 99.45% general accuracy results were obtained with Indian pines and 99.95% with Salinas. The obtained classification results show that the classification performance of the proposed method is better than the existing methods.

Conclusion: In this study, DSC-based residual network architecture is proposed for classification of HRSIs. With the use of residual network, vanishing gradients and overfitting problems in deep networks are prevented. In addition, with the skip connections used in residual blocks, more effective extraction of spatial-spectral feature information is provided. The purpose of using DSC is to speed up the training process by reducing the number of trainable parameters. The application results confirm that the proposed method provides better classification performance compared to existing methods.

Article Info:

Research article
Received: 10.01.2022
Revision: 11.04.2022
Accepted: 18.04.2022

Highlights

- Remote Sensing
- Classification
- Spectral-spatial feature extraction

Keywords

Hyperspectral image classification
Deep learning
Residual network
Depthwise separable convolution
Principal component analysis



Depthwise Separable Convolution Based Residual Network Architecture for Hyperspectral Image Classification

Hüseyin FIRAT^{1,*} Mehmet Emin ASKER² Davut HANBAY³

¹Dicle Üniversitesi, Teknik Bilimler MYO, Bilgisayar Teknolojileri Bölümü, 21280, Sur/DİYARBAKIR

²Dicle Üniversitesi, Teknik Bilimler MYO, Elektrik ve Enerji Bölümü, 21280, Sur/DİYARBAKIR

³İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 44280, Merkez/MALATYA

Abstract

Hyperspectral remote sensing images (HRSI) are 3D image cubes containing hundreds of spectral bands and having two spatial-one spectral dimensions. Classification is one of the most popular topics at HRSI. In recent years, many deep learning methods have been proposed for HRSI classification. Especially Convolutional Neural Networks (CNN) are commonly used in the classification of HRSIs. CNN has a strong feature learning capability, which can provide more distinctive features for higher quality HRSI classification. In this study, a method in which 3D/2D CNN, Residual network architecture (ResNet) and Depthwise separable convolution (DSC) are used together is proposed. In deeper CNNs, ResNet is used to achieve higher classification performance as the number of layers increases. In addition, thanks to ResNet, problems such as degradation and vanishing gradients that may occur in deep networks are overcome. On the other hand, DSCs have been used, which reduces the computational cost, prevents overfitting and provides more spatial feature extraction. Finally, spatial-spectral features are extracted simultaneously from HRSIs with 3D CNN. However, using only 3D CNN increases computational complexity. By using only 2D CNN, only spatial features are extracted from HRSIs. Spectral features cannot be extracted. By using 3D CNN and 2D CNN together, these two problems are solved. In addition, principal component analysis is used as a preprocessing step for optimum spectral band extraction in the proposed method. Applications were carried out using two popular HUAG benchmarking datasets, Indian pines and Salinas datasets. As a result of the applications, an overall accuracy of 99.45% with Indian pines and 99.95% with Salinas was obtained. The obtained classification results show that the classification performance of the proposed method is better than the existing methods.

Hiperspektral Görüntü Sınıflandırması için Derinlemesine Ayrılabilir Evrişim Tabanlı Artık Ağ Mimarisi

Öz

Hiperspektral uzaktan algılama görüntüleri (HUAG), yüzlerce spektral bant içeren ve iki uzamsal-bir spektral boyuta sahip 3B görüntü küpleridir. Sınıflandırma, HUAG'de en popüler konulardan biridir. Son yıllarda HUAG sınıflandırması için çok sayıda derin öğrenme yöntemi önerilmiştir. Özellikle Evrişimli Sinir Ağları (ESA), HUAG'lerin sınıflandırılmasında yaygın olarak kullanılmaktadır. ESA, daha yüksek kaliteli HUAG sınıflandırması için daha ayırt edici özellikler sağlayabilen güçlü bir özellik öğrenme yeteneğine sahiptir. Bu çalışma kapsamında 3B/2B ESA, Artık ağ mimarisi ve Derinlemesine ayrılabilir evrişimin birlikte kullanıldığı bir yöntem önerilmiştir. Daha derin ESA'larda, katman sayısı arttıkça daha yüksek sınıflandırma performansı elde etmek için artık ağ kullanılmaktadır. Ayrıca artık ağ sayesinde derin ağlarda oluşabilecek bozulma ve gradyanların yok olması gibi sorunların üstesinden gelinmektedir. Öte yandan, hesaplama maliyetini azaltan, aşırı öğrenmeyi önleyen ve daha fazla uzamsal özellik çıkarımı sağlayan Derinlemesine ayrılabilir evrişimler kullanılmıştır. Son olarak, 3B ESA ile HUAG'lerden uzamsal-spektral özellikler eş zamanlı olarak çıkarılmaktadır. Ancak sadece 3B ESA kullanımı hesaplama karmaşıklığını arttırmaktadır. Yalnızca 2B ESA kullanımı ile de HUAG'lerden sadece uzamsal özellikler çıkarılmaktadır. Spektral özellikler çıkarılmamaktadır. 3B ESA ile 2B ESA'nın birlikte kullanılmasıyla bu iki problem çözülmüştür. Ayrıca önerilen yöntemde optimum spektral bant çıkarımı için temel bileşen analizi bir ön işleme adımı olarak

Makale Bilgisi

Araştırma makalesi
Başvuru: 10.01.2022
Düzeltilme: 11.04.2022
Kabul: 18.04.2022

Keywords

Hyperspectral image classification
Deep learning
Residual network
Depthwise separable convolution
Principal component analysis

Anahtar Kelimeler

Hiperspektral görüntü sınıflandırma
Derin öğrenme
Artık ağ
Derinlemesine ayrılabilir evrişim
Temel bileşen analizi

kullanılmıştır. Popüler iki HUAG kıyaslama veriseti olan Indian pines ve Salinas verisetleri kullanılarak uygulamalar gerçekleştirilmiştir. Uygulamalar sonucunda Indian pines ile %99.45 ve Salinas ile %99.95 genel doğruluk sonucu elde edilmiştir. Elde edilen sınıflandırma sonuçları, önerilen yöntemin sınıflandırma performansının mevcut yöntemlerden daha iyi olduğunu göstermektedir.

1. GİRİŞ (INTRODUCTION)

Hiperspektral uzaktan algılama, son yıllarda uzaktan algılama teknolojisinin gelişmesiyle birlikte birçok araştırmacının ilgi odağı haline gelmiştir [1]. Hiperspektral uzaktan algılama sensörleri sayesinde elektromanyetik spektrumda yüzlerce sürekli ve dar bant genişliğine sahip dijital görüntü yakalanmakta ve uzamsal-spektral bilgileri içeren 3 boyutlu (3B) hiperspektral uzaktan algılama görüntüleri (HUAG) üretilmektedir. HUAG'ler yüzlerce spektral bant içermekte ve güçlü spektral bilgiye sahiptir. Ayrıca yüksek spektral çözünürlüğe sahiptirler. HUAG'lerdeki yüksek spektral çözünürlük sayesinde tanımlanması zor olan nesnelere tanınabilir hale gelmektedir. Yüzlerce spektral bantta içerdikleri zengin bilgilerle HUAG'ler, bitki örtüsü analizi, hassas tarım, jeolojik haritalama, çevresel izleme, biyolojik ve kimyasal algılama, nesne tespiti, kaynak arama ve madencilik gibi birçok gerçek dünya uygulamasında yaygın olarak kullanılmaktadır [2][3]. HUAG'lerde her pikselin sınıflandırılması bu uygulamalarda büyük önem taşımaktadır. Ancak HUAG'lerin çok sayıda spektral bant içermesi ve yüksek boyutlara sahip olması sınıflandırma işlemlerinde karşılaşılan en önemli sorunlardan biridir. Boyut indirgeme yöntemleri kullanılarak HUAG'lerin boyutları küçültülebilmektedir. Boyut indirgeme yöntemleri, önerilen yöntemin sınıflandırma performansını düşüren gereksiz spektral öznelik bilgilerinin ortadan kaldırılmasını sağladığı için hiperspektral görüntü analizinde oldukça önemli bir süreçtir. Boyut indirgeme, HUAG sınıflandırmasında iki farklı şekilde gerçekleştirilebilmektedir. (1) Spektral bant seçimi, (2) Spektral bant çıkarımı. Spektral bant seçiminde, orijinal HUAG spektral bandından seçilen en kullanışlı spektral bantlar üzerinde analiz yapılmaktadır. Spektral bant çıkarımında, yüksek spektral boyuta sahip HUAG verilerinin spektral boyutu azaltılmaktadır. Ancak, azalan spektral boyutla HUAG verilerinin uzamsal boyutu (genişlik ve yükseklik) değişmemektedir. Boyut indirgeme için en iyi ve sık kullanılan spektral bant çıkarma yöntemlerinden biri Temel Bileşen Analizidir (TBA) [4]. TBA ile HUAG'lerde faydalı spektral bantların çıkarılması amaçlanmaktadır. Bu işlem sonucunda veri boyutu küçülmekte ve işlem maliyeti azalmaktadır.

Son yıllarda, HUAG sınıflandırma için manuel veya kendi kendine öğrenen birçok sınıflandırma yöntemi önerilmektedir. Geleneksel HUAG sınıflandırma yöntemleri genellikle spektral bilgilere dayanmaktadır. Bu yöntemler arasında lojistik regresyon [5], destek vektör makinesi [6] ve rastgele orman [7] tabanlı tipik sınıflandırıcılar yer almaktadır. Bu sınıflandırıcılar arasında destek vektör makineleri, basit ama güçlü bir son sınıflandırıcı olarak kabul edilmektedir. Ancak, HUAG'ler hem spektral bant fazlalığına hem de spektral bantlar arasında yüksek korelasyona sahip olduğundan, bu tipik sınıflandırıcılar iyi performans gösterememektedirler. Çünkü çok sayıda spektral bant için yeterli sayıda eğitim örneği olmayabilir. Bu durum, spektral bantların yüksek boyutluluğu ile sınırlı sayıda eğitim örneği arasında bir dengesizliğe neden olmaktadır [8]. Ayrıca, yalnızca spektral bant bilgilerini kullanan bu sınıflandırma yöntemleri, yüksek çözünürlüklü veriler için algılanan önemli uzamsal değişkenliği elde edememektedir. Bu durum genellikle HUAG sınıflandırmasında daha düşük sınıflandırma performansı ile sonuçlanmaktadır. Sınıflandırma performansını iyileştirmenin en temel yolu, uzamsal-spektral özellikleri birlikte kullanan bir sınıflandırıcı tasarlamaktır. Çoğu geleneksel bant çıkarma yöntemi, uzamsal-spektral özellikler göz önüne alındığında sınıflandırma doğruluğunu arttırmaktadır. Bununla birlikte, yukarıda belirtilen HUAG sınıflandırma yöntemlerinin çoğu, uzamsal-spektral özellikleri manuel olarak çıkarmakta ve uzman yardımı gerektirmektedir [9].

HUAG sınıflandırmada uzamsal-spektral özellikleri manuel olarak çıkarmak sınıflandırma doğruluğunu düşürmektedir. Bunun için özellikleri otomatik olarak çıkaran yöntemler üzerinde çalışmalar yapılmıştır. Bu doğrultuda derin öğrenme yöntemlerinin kullanımı, HUAG sınıflandırmasını yeni bir düzeye taşımaktadır. Derin öğrenme tekniklerinin eğitim aşaması, özellikleri otomatik olarak çıkarmakta ve bu

özellikleri sınıflandırma aşamasında kullanılmaktadır [10]. Tipik bir derin öğrenme yöntemi olan yığılmış oto-kodlayıcı, uzamsal-spektral özellik bilgilerini çıkarabilmekte ve daha sonra bu bilgileri HUAG sınıflandırması için birleştirebilmektedir [11]. Chen vd. [12], derin öğrenme kavramını ilk başta HUAG sınıflandırması alanına uygulamıştır. Uzamsal-spektral özellik çıkarımı ve sınıflandırması için TBA, yığılmış oto-kodlayıcı ve lojistik regresyonun birlikte kullanıldığı bir yöntem geliştirmişlerdir. Kennedy uzay merkezi ve Pavia üniversitesi verisetleri üzerinde gerçekleştirilen uygulamalar sonucunda, sırasıyla %96.73 ve %95.14 genel doğruluk sonucu elde edilmiştir. Tao vd. [13], derin spektral özellikleri çıkarmak için yığılmış oto-kodlayıcı ve lojistik regresyonun birlikte kullanıldığı bir yöntem önermişlerdir. Derin inanç ağı tabanlı sınıflandırma, HUAG analizi için kullanılan diğer derin öğrenme yöntemlerinden biridir. Bu yöntem, HUAG'nin uzamsal özellik bilgisinin spektral özellik bilgisi ile birleştirilmesi için önerilmiştir. Pavia üniversitesi ve Indian pines verisetleri ile %10 eğitim örneği kullanılarak gerçekleştirilen uygulamalar sonucunda, sırasıyla %98.64 ve %89.35 genel doğruluk sonucu elde edilmiştir. Jia vd. [14], derin inanç ağına dayalı HUAG analizi için hiyerarşik öğrenmeye dayalı özellik çıkarımı olan TBA ve lojistik regresyonun birlikte kullanıldığı bir yöntem önermişlerdir. Önerilen yöntemin sınıflandırma performansını test etmek için Indian pines ve Pavia üniversitesi verisetleri kullanılmıştır. Elde edilen genel doğruluk sonuçları Indian pines için %95.95 ve Pavia üniversitesi için %99.05 olarak bulunmuştur. Li vd. [15], optimal derin inanç ağı ve doku özelliği geliştirmeyi kullanan yeni bir HUAG sınıflandırma yöntemi önermişlerdir. Indian Pines, Pavia üniversitesi ve Salinas verisetleri üzerinde gerçekleştirilen uygulamalar sonucunda, sırasıyla %97.56, %96.96 ve %96.22 genel doğruluk elde edilmiştir. Derin özellikler, yığılmış oto-kodlayıcı ve derin inanç ağı kullanılarak katman tabanlı bir eğitim sürecinde hiyerarşik olarak çıkarılabilirken, bu yöntemlere girdi olarak verilen görüntü parçalarından oluşan eğitim örneklerinin tek boyuta düzleştirilmesi gerekmektedir. Bu durumda, HUAG'deki uzamsal özellikler tam olarak kullanılamamaktadır. Ayrıca, yığılmış oto-kodlayıcı ve derin inanç ağı denetimsiz öğrenme algoritmalarıdır ve özellikleri öğrenirken doğrudan sınıf bilgilerini kullanmamaktadırlar. Bu durum sınıflandırma doğruluğunu düşürmektedir. Bu derin öğrenme mimarilerinin aksine HUAG sınıflandırmada literatürde sıklıkla kullanılan derin öğrenme yöntemi Evrişimsel sinir ağları (ESA)'dır. ESA, daha yüksek kaliteli HUAG sınıflandırması için daha ayırt edici özellikler sağlayabilen güçlü bir özellik öğrenme yeteneğine sahiptir. Öğrenilen özellikler ne kadar ayırt edici olursa, sınıflandırma problemlerini çözmek o kadar kolay olmaktadır [16][17]. Bu durum sınıflandırma doğruluğunu büyük ölçüde arttırmaktadır. Bu nedenle, HUAG sınıflandırmasında kullanılan ESA tabanlı yöntemler, daha derin uzamsal, spektral veya uzamsal-spektral özellik bilgilerini çıkarmak için kullanılan en etkili yöntemlerden biridir. ESA tabanlı yöntemler, HUAG sınıflandırma performansını etkili bir şekilde iyileştirdikleri için giderek daha fazla uygulanmaktadır. Mohan vd. [9], HUAG sınıflandırması için 3B ESA ve 2B ESA tabanlı çok ölçekli bir uzamsal-spektral özellikten oluşan hibrit bir ESA modeli önermişlerdir. Spektral bant fazlalığını azaltmak ve optimum bant çıkarımı sağlamak için doğrusal olmayan çekirdek temel bileşen analizi ve doğrusal gauss rastgele projeksiyondan oluşan hibrit boyut indirgeme yöntemini kullanmışlardır. Önerilen yöntemin sınıflandırma performansını test etmek için Indian pines, Pavia üniversitesi, Salinas ve Houston verisetleri üzerinde çalışmalar gerçekleştirilmiştir. Ayrıca 15x15 pencere boyutu, 15 temel bileşen ve %20 eğitim, %10 doğrulama ve %70 test örneği alınmıştır. Elde edilen genel doğruluk sonuçları sırasıyla Indian pines için %99.80, Pavia üniversitesi için %99.99, Salinas veriseti için %100 ve Houston veriseti için %99.12 olarak bulunmuştur. Mu vd. [18], HUAG sınıflandırması için çok ölçekli ve çok seviyeli bir uzamsal spektral özellik füzyon ağı önermişlerdir. Önerilen yöntemde, 3B'den 2B'ye alternatif artık blok, 3B ESA'dan çıkarılan spektral özellik bilgisini 2B ESA'dan çıkarılan uzamsal özellik bilgisi ile birleştirmektedir. Herhangi bir ön işlem gerçekleştirilmeden 7x7, 11x11, 15x15 pencere boyutları, önerilen yöntemin performansını test etmek için Indian pines, Pavia üniversitesi, Salinas, Kennedy uzay merkezi verisetleri kullanılmıştır. Indian pines için %10, Pavia üniversitesi için %5, Salinas için %5 ve Kennedy uzay merkezi için %10 eğitim örneği alınarak gerçekleştirilen uygulamalar sonucunda sırasıyla %99.12, %99.94, %99.84 ve %99.69 genel doğruluk sonuçları elde edilmiştir. Meng vd. [19], mevcut diğer derin öğrenme tabanlı HUAG sınıflandırma modellerinden daha geniş olan yeni bir ESA modeli önermişlerdir. Önerilen yöntem, katman sayısı arttıkça daha derindeki ağın sınıflandırma doğruluğunun kademeli olarak artmasına neden olduğu problemi çözmek için tasarlanmış yeni bir çok yollu artık ağ olarak adlandırılmaktadır. Çok yollu

artık ağ yönteminde, ağda birden çok artık blok kullanarak ağı derinleştirmek yerine paralel olarak çok yöllü artık bloklar kullanılmaktadır. Bu sayede ağı daha derin değil daha geniş yapmak amaçlanmaktadır. Girdi HUAG verisine boyut indirgeme yöntemi uygulanmadan 11x11 pencere boyutu ve Indian pines, Houston ve Kennedy uzay merkezi verisetleri üzerinde çalışmalar yapılmıştır. Indian pines ve Houston verisetleri için %10 ve Kennedy uzay merkezi için %2 eğitim örneği alınarak uygulamalar gerçekleştirilmiştir. Uygulamalar sonucunda, sırasıyla %99.16, %98.88, %96.00 genel doğruluk sonuçları elde edilmiştir. Song vd. [20], HUAG sınıflandırması için derin bir özellik füzyon ağı önermişlerdir. Önerilen yöntem, derin ağı eğitimi kolaylaştırabilen ve artan derinlikten yararlanabilen kimlik eşleme olarak birkaç evrimsel katmanı optimize etmek için artık öğrenmeyi kullanmaktadır. Bu şekilde, ağ daha derin özellikleri çıkarabilmektedir. Önerilen yöntemin sınıflandırma performansını test etmek için Indian pines, Pavia üniversitesi ve Salinas veriseti üzerinde uygulamalar yapılmıştır. HUAG verilerine ön işleme adımı olarak TBA uygulanmış ve 25x25 pencere boyutu üzerinde çalışılmıştır. Gerçekleştirilen çalışmalar sonucunda Indian pines için %98.52, Pavia üniversitesi için %98.73 ve Salinas için %98.87 genel doğruluk sonucu bulunmuştur. Zhong vd. [21], HUAG sınıflandırması için spektral-uzamsal artık ağı önermişlerdir. Bu yöntem, herhangi bir boyut indirgeme yöntemi kullanmadan 3B hiperspektral küpü girdi verisi olarak almaktadır. Artık bloklar, gradyanların geri yayılmasını kolaylaştıran kimlik eşleme yoluyla her 3B evrişim katmanını birbirine bağlamaktadır. Herhangi bir ön işlem adımı uygulanmadan, Indian pines ve Kennedy uzay merkezi için %20, Pavia üniversitesi için %10 eğitim örneği alınarak 7x7 pencere boyutu kullanılarak uygulamalar gerçekleştirilmiştir. Genel doğruluk sonuçları Indian pines için %97.81, Kennedy uzay merkezi için %99.01 ve Pavia üniversitesi için %99.54 olarak bulunmuştur. Roy vd. [22], HUAG sınıflandırması için hibrit bir spektral ESA yöntemi önermişlerdir. Bu yöntem, 3B ESA ve 2B ESA'nın birlikte kullanılmasından oluşmaktadır. 3B ESA ile bir spektral bant yığımindan ortak uzamsal-spektral özellikleri çıkarılırken, 2B ESA, 3B ESA'nın üzerine uzamsal özellikleri çıkarmaktadır. HUAG girdi verisine ön işleme adımı olarak TBA uygulanmıştır. 25x25 pencere boyutu ve %30 eğitim örneği alınarak Indian pines, Pavia üniversitesi ve Salinas verisetleri üzerinde çalışmalar yapılmıştır. Elde edilen genel doğruluk sonuçları sırasıyla, %99.75, %99.98 ve %100'dür. Ahmad vd. [23], HUAG sınıflandırmasında daha iyi sınıflandırma performansları elde etmek için uzamsal-spektral özellik bilgilerini kullanan hızlı bir 3B ESA yöntemi önermişlerdir. Önerilen yöntemde boyut indirgeme yöntemi olarak artımsal temel bileşen analizi kullanılmıştır. Boyut indirgeme sonucunda 20 temel bileşen üzerinde uygulamalar gerçekleştirilmiştir. 11x11 pencere boyutu, %70 eğitim örneği ile Indian pines, Pavia üniversitesi ve Salinas verisetleri üzerinde gerçekleştirilen uygulamalar sonucunda elde edilen genel doğruluk sonuçları sırasıyla, %97.75, %98.40 ve %98.06'dır. Ge vd. [24], HUAG sınıflandırması için farklı çekirdek boyutuna sahip 3B ESA ve 2B ESA ile çok dallı özellik füzyonuna dayalı derin bir ağ mimarisi önermişlerdir. Ayrıca ReLU yerine Mish aktivasyon fonksiyonunu kullanmışlardır. Ön işleme adımı olarak TBA kullanılmıştır. 25x25 pencere boyutu, %5 eğitim örneği alınarak, Indian pines, Pavia üniversitesi, Salinas ve Botswana verisetleri kullanılarak uygulamalar yapılmıştır. Uygulamalar sonucunda sırasıyla, %96.07, %99.52, %99.94 ve %96.44 genel doğruluk sonuçları elde edilmiştir. He vd. [25], HUAG sınıflandırması için 2B çok ölçekli uzamsal özelliği ve 1B spektral özelliği birlikte öğrenebilen çok ölçekli bir 3B derin ESA yöntemi önermişlerdir. Önerilen yöntemde, TBA gibi herhangi bir ön işlem olmadan Indian pines, Pavia üniversitesi ve Salinas verisetleri ile uygulamalar gerçekleştirilmiştir. Her üç verisetinde de eğitim örnekleri için her sınıftan rastgele 200 örnek alınmıştır. 7x7 pencere boyutu alınarak, Indian pines için %97.61, Pavia üniversitesi için %98.49 ve Salinas için %97.24 genel doğruluk sonucu bulunmuştur.

HUAG sınıflandırması için sadece 2B ESA'nın kullanılması ile sadece uzamsal özellikler çıkarılmaktadır. Spektral boyuttan iyi ayırt edici özellik haritaları çıkarılamamaktadır. Bu durum spektral özellik bilgilerinin kaybolmasıyla sonuçlanmaktadır. Spektral-uzamsal özellikleri eş zamanlı çıkarmak için yalnızca 3B ESA kullanımı sınıflandırma doğruluğunu arttırmaktadır. Ancak, birçok spektral bantta benzer dokulara sahip sınıflarla uğraşırken karmaşıklık artacak ve performansı olumsuz yönde etkileyecektir. Bu durumların oluşmasının nedeni ise, HUAG'nin hem uzamsal hemde spektral boyutlara sahip 3B veri görüntüsü olmasındandır. Yukarıda açıklanan problemleri çözmek için önerilen yöntem, spektral ve uzamsal özellik haritalarını tamamen çıkarabilen ve tek başına kullanılan 2B ESA ve 3B ESA'nın eksikliklerini giderebilen

3B ESA ile 2B ESA'nın birleşiminden oluşmaktadır. Ayrıca derin ağların eğitilmesi zordur. Aşırı öğrenme ve gradyan kaybolması gibi problemler ile karşı karşıya kalınmaktadır. Derin ağlarda bu tür problemlerin üstesinden gelmek için önerilen yöntem artık blokları eklenmiştir. Ağ derinleştikçe, önerilen yöntemdeki eğitilebilir parametre sayısı ve işlem maliyeti artmaktadır. Geleneksel 2B ESA mimarisinde kullanılan bazı 2B evrişim katmanları 2B derinlemesine ayrılabilir evrişim katmanları ile değiştirilmiştir. Derinlemesine ayrılabilir evrişim katmanlarının kullanılması eğitilebilir parametre sayısını ve işlem maliyetini düşürmekte ve aşırı öğrenme probleminde önleyebilmektedir. Bu çalışmanın başlıca katkıları şu şekildedir:

- (1) HUAG'nin özellik öğrenme yeteneğini geliştirmek için derinlemesine ayrılabilir evrişim ve artık ağ mimarisi beraber kullanılmıştır. Artık ağ mimarisinin kullanımı ile derin ağlarda gradyan kaybolması ve aşırı öğrenme problemlerinin önüne geçilmiştir. Ayrıca artık bloklarda kullanılan atlama bağlantıları ile uzamsal-spektral özellik bilgilerinin daha etkili bir şekilde çıkarılması sağlanmıştır.
- (2) Önerilen ağda, uzamsal-spektral özellikleri eş zamanlı çıkarmak için 3B ESA kullanılmıştır. 3B ESA'nın ardından daha fazla uzamsal özellik çıkarabilmek için 2B ESA ile birleştirilmiştir. Daha derin ağlarda derin özellikler çıkarabilmek için 3B ESA ve 2B ESA'ya artık blokları yerleştirilmiştir. 2B ESA bölümünde, derinlemesine ayrılabilir evrişim kullanılarak, eğitilebilir parametre sayısı azaltılmış ve aşırı öğrenme önlenmiştir.
- (3) Indian pines (IP) ve Salinas (SA) HUAG verisetleri üzerinde önemli uygulamalar gerçekleştirilmiştir. Uygulama sonuçları, önerilen yöntemin mevcut yöntemlerle karşılaştırıldığında daha iyi sınıflandırma performansı sağladığını doğrulamaktadır.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir. Bölüm 2'de önerilen yöntem ve teorik arkaplanı açıklanmıştır. Bölüm 3'te çalışma kapsamında kullanılan verisetleri ve uygulama sonuçları yer almaktadır. Son olarak Bölüm 4'te ise sonuçlar verilmiştir.

2. MATERYAL VE METOTLAR (MATERIAL AND METHODS)

2.1. Derinlemesine Ayrılabilir Evrişim (Depthwise Separable Convolution)

Derinlemesine ayrılabilir evrişim (DAE), derinlemesine evrişim ve noktasal evrişim (1x1 evrişim olarak da bilinir) olarak ayrıştırılmaktadır. Bunlardan derinlemesine evrişim, giriş görüntüsünün her kanalında ayrı bir evrişim işlemi gerçekleştirmektedir. Evrişim işlemi, her boyutta uzamsal özellikleri çıkarmak için kullanılmaktadır. Noktasal evrişim ise, çıktı özellik haritasında 1x1 standart evrişim işlemidir. Bu evrişim, özellik haritasını kanallar arasında birleştirmek için kullanılır. Derinlemesine ayrılabilir evrişim kullanımı, standart evrişime kıyasla eğitilebilir parametre sayısını azaltmaktadır. Bu da aşırı öğrenme problemini önleyebilmektedir. Ayrıca daha az hesaplama nedeniyle işlem maliyetini azaltmaktadır [26].

Şekil 1a'da gösterildiği gibi $D_f x D_f x M$ boyutunda bir giriş görüntüsü olduğunu varsayalım. Burada D_f , giriş görüntüsünün genişlik ve yüksekliğini, M ise kanal sayısını ifade etmektedir. Benzer şekilde $D_k x D_k x M$ evrişim çekirdek boyutunda N tane filtre/çekirdek olduğunu varsayalım. Standart bir evrişim işlemi gerçekleştirildiğinde, çıktı boyutu $D_p x D_p x N$ olacaktır. Standart evrişim işleminin işlem maliyeti Denklem 1'deki gibidir.

$$cost_{standart_conv} = N x D_p x D_p x D_k x D_k x M \quad (1)$$

Şekil 1b'de gösterildiği gibi derinlemesine ayrılabilir evrişim 2 işleme ayrılmaktadır. İlk olarak derinlemesine evrişim işleminde, tüm M kanalları için yapılan standart evrişim işleminin aksine, bir seferde tek bir kanala evrişim uygulanmaktadır. Burada $D_k x D_k x 1$ evrişim çekirdek boyutunda M tane filtre gereklidir. Çıktı boyutu, $D_p x D_p x M$ olacaktır. Derinlemesine evrişim işlemi için işlem maliyeti Denklem 2'deki gibi hesaplanmaktadır.

$$cost_{derinlemesine_conv} = M x D_p x D_p x D_k x D_k \quad (2)$$

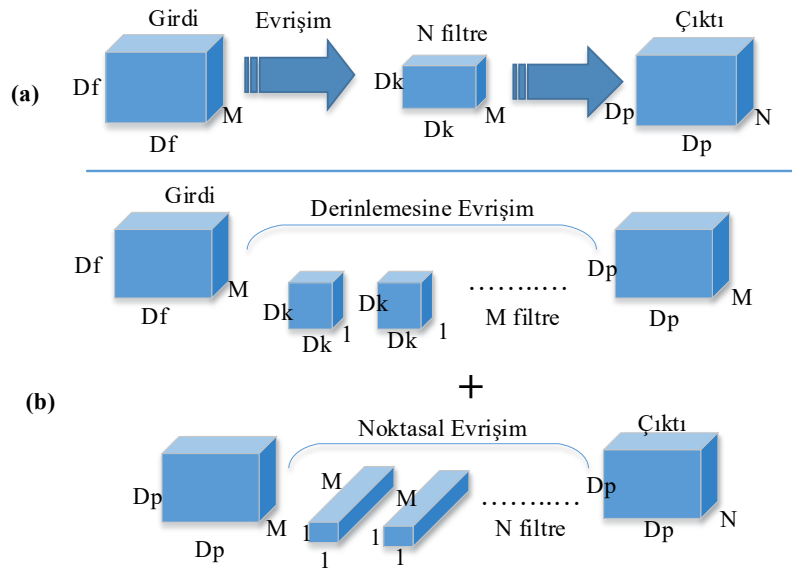
Noktasal evrişimde ise $D_p \times D_p \times M$ çıktısına 1×1 evrişim işlemi uygulanmaktadır. Bu işlemin çekirdek boyutu $1 \times 1 \times M$ olacaktır. N tane filtre kullanıldığı varsayıldığında, çıktı boyutu $D_p \times D_p \times N$ olacaktır. Noktasal evrişim işlemi sonucunda elde edilen maliyet Denklem 3'teki gibidir.

$$cost_{noktasal_conv} = M \times D_p \times D_p \times N \quad (3)$$

DAE işlem maliyeti, derinlemesine ve noktasal evrişim işlemleri sonucunda elde edilen maliyet toplamıdır. Standart evrişim işlemi ile derinlemesine ayrılabilir evrişim sonucunda elde edilen işlem maliyetlerini karşılaştırmak için gerekli olan hesaplama Denklem 4'teki gibidir.

$$\frac{cost_{derinlemesine_conv} + cost_{noktasal_conv}}{cost_{standart_conv}} = \frac{1}{N} + \frac{1}{D_k^2} \quad (4)$$

Denklem 4'e göre, DAE işlemi sonucunda elde edilen işlem maliyeti standart evrişimin $\frac{1}{N} + \frac{1}{D_k^2}$ katı olduğu görülmektedir. DAE'nin kullanılması eğitilebilir parametre sayısını ve hesaplama maliyetini önemli ölçüde azaltmaktadır.




Şekil 1. (a) Standart evrişim. (b) Derinlemesine ayrılabilir evrişim

2.2. Artık Ağ Mimarisi (Residual Network Architecture)

Derin olmayan ağ mimarisiyle (yani LeNet, AlexNet, VGGNet) karşılaştırıldığında, derin ağ mimarileri daha güçlü bir öğrenme ve özellik ifade etme yeteneğine sahiptir. Ağ mimarilerinde katman sayısının belirli bir derinliğe ulaşması performansın artmasını sağlamayacak, aksine ağın yapısında bozulmaya neden olacaktır. Yani ağ yapısındaki katman sayısının aşırı artması kullanılan eğitim setindeki sınıflandırma doğruluğunu azaltmaktadır. Aynı zamanda, katman sayısı arttıkça oluşan derin ağları eğitmek, kaybolan gradyan sorunu nedeniyle çok zordur. Kaybolan gradyan sorunu, daha derin ağlardaki eğitim sürecinde ortaya çıkmaktadır. Eğitim ilerledikçe, bir katmandan diğerine geçerken gradyan sinyalleri biraz kaybolmakta ve derin olmayan katmanlarda sifira yaklaşmaktadır. Bu durum ağın yakınsamasını daha baştan engellemektedir. Kaybolan gradyan ve bozunma problemini çözmek için Şekil 2'de gösterilen artık öğrenme bloğu He vd. tarafından önerilmiştir [27]. Ağ girişi x ve çıktı olarak elde edilecek özellik haritası $H(x)$ olarak ifade edilsin. Artık eşleme $H(x) = F(x)+x$, kimlik atlama bağlantıları eklenerek gerçekleştirilmektedir. Böylece ikinci katmanın çıktısına girdi verileri eklenerek geçmiş katmana ait verilerin ileri katmanlara etkin bir şekilde iletilmesi amaçlanmaktadır. Diğer bir ifadeyle, Şekil 2'deki artık ağ mimarisinde, 2 boyutlu evrişim işleminde, 3×3 çekirdek boyutunda iki evrişim işlemi gerçekleştirilmektedir. İlk evrişim işleminden sonra bir toplu normalleştirme (Batch normalization - BN) ve ReLU aktivasyon fonksiyon işlemi gerçekleştirilmektedir. Ardından ikinci evrişim işlemi ve BN

katmanından sonra elde edilen çıktı, bu iki evrişim işlemini atlayan x girdi değeri ile toplanmaktadır. Daha sonra ReLU aktivasyon fonksiyonundan geçirildikten sonra $H(x)$ çıktımız elde edilmektedir. 3 boyutlu evrişim işleminde ise, $3 \times 3 \times 3$ çekirdek boyutunda evrişim katmanları kullanılmaktadır. İleriye yayılma sürecinde, artık öğrenme blokları sayesinde derin ağı kimlik haritalaması gerçekleştirilmektedir. Böylece ağ, kaybolan gradyan ve bozulma problemlerinden kaçınırken katman sayısını arttırabilmektedir. Artık ağ, artık öğrenme blokları adı verilen çok sayıda temel yapısal öğenin istiflenmesiyle oluşturulmaktadır. Bu mimarinin en önemli katkılarından biri, yapay sinir ağının katman sayısını arttırırken ağın daha hızlı ve daha başarılı bir şekilde eğitilmesini sağlamasıdır.



Şekil 2. Artık öğrenme bloğu

2.3. Önerilen Yöntem (Proposed Method)

HUAG, küpün genişliğinin W , yüksekliğinin H ve spektral bandın D olduğu ve hiperspektral verinin girişinin $W \times H \times D$ olarak ifade edildiği 3B veri küpü olarak kabul edilmektedir. Her piksel D spektral ölçümleri içermekte ve one-hot encoding kullanılarak etiket vektörü $C = (c_1, c_2, \dots, c_n)$ oluşturulmaktadır. One hot encoding sayesinde, kategorik değişkenlerin ikili (binary) vektör olarak temsil edilmesi sağlanılmaktadır [28]. Burada n HUAG'deki sınıf sayısını (arazi örtüsü) belirtmektedir. HUAG pikselleri, herhangi bir sınıflandırma yöntemi için yoğun çaba gerektiren yüksek sınıflar arası benzerlik, yüksek sınıf içi değişkenlik, örtüşen ve iç içe bölgeler sergilemektedir. Bu problemlerin üstesinden gelmek için spektral bant fazlalığının ortadan kaldırılması gerekmektedir. Spektral bant fazlalığını ortadan kaldırmak için bir ön işleme adımı olarak, boyut indirgeme yöntemlerinden en sık kullanılan TBA ilk olarak spektral bantlar boyunca orijinal HUAG verilerine uygulanmaktadır. TBA ile nispeten daha az sayıda temel bileşen korunmaktadır. TBA uygulandıktan sonra, aynı uzamsal boyutlar (yani genişlik W ve yükseklik H) korunurken spektral bantların sayısı D 'den B 'ye düşürülmektedir. Herhangi bir nesneyi tanımak için çok önemli olan uzamsal bilgi korunarak yalnızca spektral bantlar azaltılmıştır. Böylece istenilen bant sayısına indirilmiştir. Bu durumda, hiperspektral veriler $W \times H \times B$ olarak temsil edilmektedir. HUAG verileri büyük boyutludur ve birçok spektral banda sahiptir. Bu verileri doğrudan işleme, yüksek donanım ve bellek gereksinimleri gerektirmektedir. Bu nedenle görüntü sınıflandırma ve işlemeden önce HUAG verileri $S \times S \times B$ olarak ifade edilen, merkezi piksele dayalı gerçek etiketlerin üretildiği örtüşen küçük 3B parçalara bölünmektedir. Bu durumda elde edilen 3B parçaların yükseklik ve genişlik boyutu S ve spektral bant sayısı B 'dir. HUAG küpünden üretilen toplam 3B parça sayısı $(W - S + 1) \times (H - S + 1)$ ile bulunmaktadır. Son olarak, 3B parçalar sınıflandırma doğruluk sonuçlarının elde edilmesi için önerilen ağ mimarisinin girişine verilmektedir.

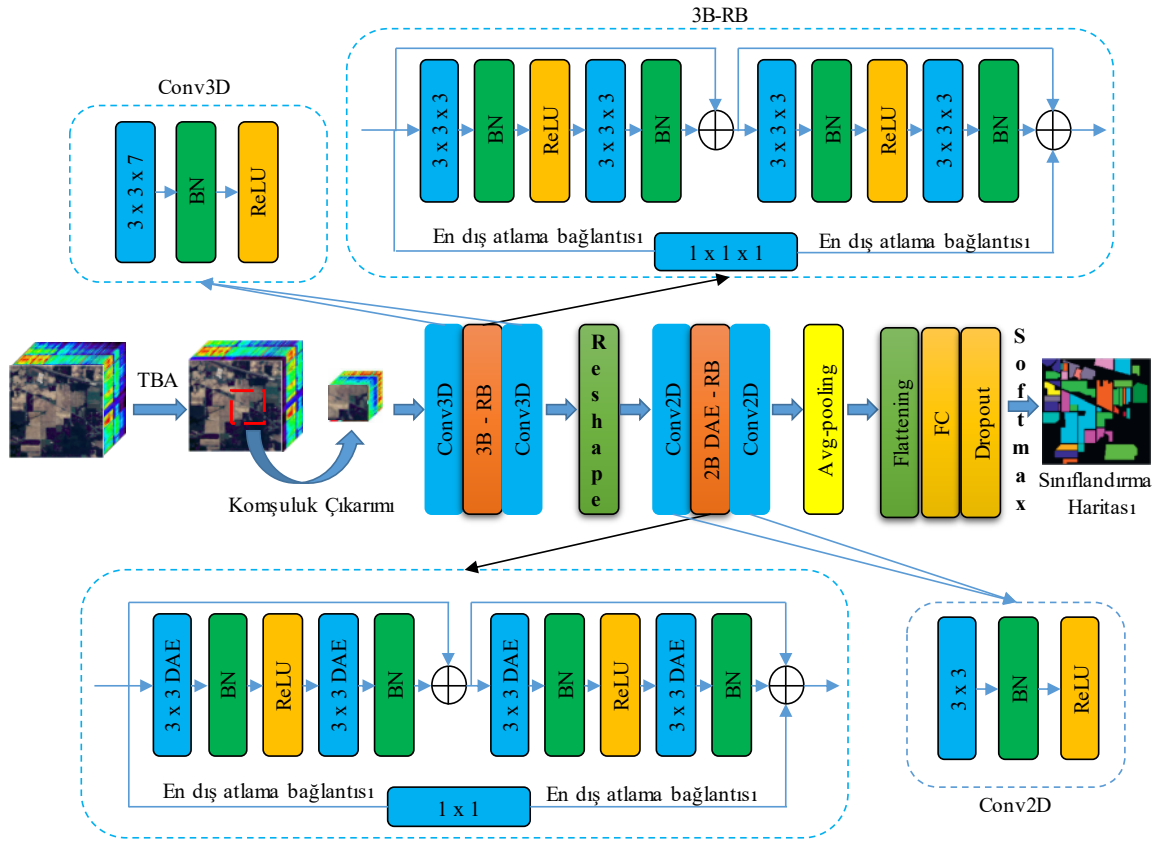
Geleneksel 2B ESA yönteminde, girdi HUAG verilerini aktivasyon fonksiyonundan geçirmeden önce 2B çekirdek kullanılarak evrişim gerçekleştirilmektedir. Evrişim, çekirdek ve giriş HUAG arasındaki iç çarpım toplamını hesaplayarak gerçekleştirilmektedir. Çekirdek, tüm uzamsal boyutu kapsayacak şekilde HUAG üzerinde ilerlemektedir. Bu evrişim işlemi, HUAG'den uzamsal özelliklerin çıkarılmasını sağlamaktadır. Yani; 2B evrişim işleminde, uzamsal boyuta evrişim uygulanmakta ve 2B özellik haritası elde edilmektedir. Ancak, HUAG 3B veridir ve spektral özelliği yakalamak gereklidir. 2B ESA spektral bilgiyi işleyemez. 3B verilere evrişim işlemleri uygulandığında, özelliklerin hem uzamsal hem de spektral boyutlardan yakalanması istenmektedir. Bu amaçla, 3B girdi verilerinden ortak uzamsal spektral özellikleri çıkarmak için 3B özellik küplerine 3B evrişim işlemlerinin uygulandığı 3B ESA kullanılmaktadır. 3B evrişim işlemi,

bir 3B evrişim çekirdeğinin 3B verilerle konvolüsyonu ile elde edilmektedir. 3B evrişim çekirdeği, giriş 3B görüntüsünün iki boyutu üzerinde evrişim işlemlerini gerçekleştirmekte ve bir 3B özellik haritası elde etmektedir. 3B ESA aynı anda spektral ve uzamsal özellikleri çıkarabilir, ancak hesaplama karmaşıklığını arttırmaktadır. 2B ESA ve 3B ESA'nın eksikliklerinin üstesinden gelmek ve 2B ve 3B'nin otomatik özellik öğrenme yeteneklerinden tam olarak yararlanmak için önerilen yöntemde, 3B ESA ve 2B ESA'yı birleştiren hibrit bir evrişimli sinir ağı çerçevesi kullanılmaktadır. Ayrıca, önerilen yöntemde, geleneksel 2B evrişim katmanlarından bazıları, DAE'lerle değiştirilmiştir. Bu şekilde parametre ve işlem maliyetleri sorunu çözülebilmekte ve aşırı öğrenme (overfitting)'den daha fazla kaçınılabilmektedir. Diğer bir deyişle, önerilen yöntemin 2B bölümünde DAE katmanlarının kullanılması, eğitilebilir parametre sayısını azaltmakta ve aşırı öğrenmeyi önlemektedir. DAE kullanılarak, HUAG'nin özellik öğrenme kapasitesi iyileştirilmekte ve hesaplama karmaşıklığı azaltılmaktadır.

Önerilen yöntem (ÖY), Şekil 3'te gösterildiği gibi 2 3B evrişim (conv3D) katmanı ile 3B evrişim katmanlarından oluşan artık bloklar (Residual blok-RB) (3B-RB), 2 2B evrişim katmanı (conv2D) ile 2B DAE katmanlarından oluşan artık bloklar (DAE-RB), ortalama havuzlama (Average pooling-Avg pooling), düzleştirme (flattening), tam bağlantılı (fully connected-FC), bırakma (dropout) ve softmax katmanlarından oluşmaktadır. $S_x S_x B$ boyutunda elde edilen 3B HUAG verisine ilk olarak $3 \times 3 \times 7$ (iki uzamsal (3×3) ve bir spektral (7) boyut) evrişim çekirdek boyutuna sahip 32 filtre uygulanmaktadır. Ardından 3B evrişim katmanlarından oluşan 2 artık blok uygulanmaktadır. Artık bloklarda kullanılan 3B evrişim çekirdeklerinin tamamı $3 \times 3 \times 3$ boyutunda ve 32 filtre içermektedir. Ayrıca artık blokların en dışındaki atlama bağlantısı $1 \times 1 \times 1$ boyutunda 32 filtre içermektedir. Atlama bağlantısı sayesinde, gradyan kaybolması problemi çözülmekte ve daha derin özelliklerin çıkarılması sağlanmaktadır. 3B evrişim katmanlarını içeren artık bloklardan elde edilen özellik haritasına $3 \times 3 \times 24$ boyutunda ve 64 filtreden oluşan 3B evrişim işlemi uygulanmaktadır. Elde edilen çıktı daha fazla uzamsal özellik elde edilmesini sağlamak için yeniden boyutlandırılarak (Reshape) 2B evrişim işlemleri başlatılmaktadır. İlk olarak 3×3 çekirdek boyutunda 128 filtreden oluşan 2B evrişim işlemi gerçekleştirilmektedir. Daha sonra elde edilen çıktı 2B DAE katmanlarından oluşan artık bloklarının girişine verilmektedir. Artık bloklarda kullanılan DAE katmanlarının tamamı 3×3 çekirdek boyutunda 128 filtre ve en dıştaki atlama bağlantısı 1×1 boyutunda 128 filtre içermektedir. Ağ yapısında DAE katmanlarının kullanılması, yalnızca eğitilebilir parametre sayısını azaltmakla kalmaz, aynı zamanda eğitim hızını da arttırmakta ve aşırı öğrenmeyi önlemektedir. 2B DAE katmanlarından oluşan artık bloklarda elde edilen özellik haritasına 3×3 çekirdek boyutunda ve 128 filtreden oluşan 2B evrişim işlemi uygulanmaktadır. Hem 3B hem de 2B artık bloklarda çıktı özellik haritasının boyutuyla giriş boyutunun aynı olmasını sağlamak için padding="same" kullanılmıştır. Ancak, Artık blokların haricinde kullanılan 3B ve 2B evrişim katmanlarının tamamında padding="valid" kullanılmıştır. Böylece artık bloklara giriş yapmadan önce özellik haritalarının boyutları küçültülmektedir. ReLU, ESA'da en sık kullanılan aktivasyon fonksiyonu olduğundan, tüm evrişim katmanlarında kullanılmaktadır. Eğitim için gradyan iniş teknikleri kullanıldığında ReLU, diğer etkinleştirme işlevlerinden daha hızlıdır. Ayrıca, eğitim sürecini düzenlemek ve hızlandırmak için toplu normalleştirme (Batch normalization - BN) kullanılmaktadır. Tüm 3B/2B artık bloklar ile 3B/2B evrişim işlemlerinden sonra elde edilen özellik haritasına 3×3 boyutunda ortalama havuzlama katmanı uygulanmaktadır. Ortalama havuzlama aracılığıyla 128 çıktı özellik haritası, 1×1 boyutunda 128 özellik haritasına dönüştürülmektedir. Ardından çıkarılan özellikler düzleştirilmekte ve sınıflandırma için tam bağlantılı katmana girdi olarak verilmektedir. Önerilen yöntemde 64 nöronlu tek tam bağlantılı katman kullanılmaktadır. Aşırı öğrenmeyi önlemek için, tam bağlantılı katmandan sonra bırakma (dropout) oranı %0,5 olan bir bırakma katmanı uygulanmaktadır. Tam bağlantılı katmanın çıktısı, sınıflandırma sonucunu üretmek için basit softmax sınıflandırıcıya verilmektedir. Softmax, sınıflandırma için bir derin öğrenme yönteminin son katmanında sıklıkla kullanılan başka bir etkinleştirme işlevidir. Bu etkinleştirme işlevi, tüm örneklerin olasılık dağılımını üretmekte ve bunların toplamı bire eşittir. Önerilen yöntem ile ilgili daha fazla ayrıntı Tablo 1'de gösterilmektedir.

Tablo 1. Indian pines veriseti için önerilen yönteminin ayrıntılı yapısı

Katman	Özellik Haritası boyutu	Filtre	Çekirdek Boyutu	Stride	Padding
Girdi	11x11x30	-	-	-	-
Conv3D (3B Evrişim)	9x9x24	32	3x3x7	1	valid
Residual Blok1 (Conv3D-1, Conv3D-2)	9x9x24	32	3x3x3	1	same
	9x9x24	32	3x3x3	1	same
Residual Blok 2 (Conv3D-1, Conv3D-2)	9x9x24	32	3x3x3	1	same
	9x9x24	32	3x3x3	1	same
Dış Atlama Bağlantısı (Residual Blok1, Residual Blok 2)	9x9x24	32	1x1x1	1	same
Conv3D (3B Evrişim)	7x7x1	64	3x3x24	1	valid
Reshape (Yeniden Boyutlandırma)	7x7	64	-	-	-
Conv2D (2B Evrişim)	5x5	128	3x3	1	valid
Residual Blok3 (Conv2D-1, Conv2D-2)	5x5	128	3x3	2	same
	5x5	128	3x3	1	same
Residual Blok 4 (Conv2D-1, Conv2D-2)	5x5	128	3x3	1	same
	5x5	128	3x3	1	same
Dış Atlama Bağlantısı (Residual Blok3, Residual Blok 4)	5x5	128	1x1	1	same
Conv2D (2B Evrişim)	3x3	128	3x3	1	valid
Ortalama havuzlama katmanı	1x1	128	3x3	1	valid
Düzleştirme katmanı	128	-	-	-	-
Tam bağlantılı katman	64	-	-	-	-
Dropout Katmanı	64	-	-	-	-
Softmax	16	-	-	-	-



Şekil 3. HUAG için önerilen yöntem mimarisi

3. VERİSETLERİ VE UYGULAMALAR (DATASETS AND APPLICATIONS)

3.1. Veri setleri (Datasets)

















Önerilen yöntemin ve en son tekniklerin performansını değerlendirmek için Indian Pines (IP) ve Salinas (SA) verisetlerini içeren iki HUAG veriseti kullanılmıştır. IP ve SA verisetleri http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes web adresinden alınmıştır. IP, kuzeybatı Indiana'daki Indian pines test alanında havadan görünür/ kızılötesi görüntüleme spektrometresi sensörü tarafından toplanmıştır. Bu verisetindeki her spektral görüntü 145x145 uzamsal boyutundadır. Sensör, 0.4-2.5 mikrometre dalga boyu aralığında toplam 224 spektral bant elde etmiştir. Bu 224 banttan, 24 bant tam su emme bölgesindedir ve bunlar sınıflandırma için yararlı değildir. Toplam 200 bant uygulamalarda kullanılmıştır. IP, 16 tür sınıf ve 10249 örnek içermektedir. SA, California, Salinas Valley üzerinden havadan görünür/ kızılötesi görüntüleme spektrometresi sensörü tarafından elde edilmiştir. Veriseti, piksel başına 3.7 m uzamsal çözünürlüğe sahiptir. 224 bant içeren, 217 piksel genişliğinde ve 512 piksel yüksekliğinde bir uzaktan algılama görüntüsüdür. 20 su emme bandı çıkarıldıktan sonra kalan 204 bant uygulamalarda kullanılmıştır. SA, toplam 16 sınıf ve 54129 örnek içermektedir. Verisetlerinin sınıf ve örnek sayısı bilgileri Tablo 2'de gösterilmiştir.

3.2. Uygulamalar (Applications)

Tüm uygulamalar Colaboratory (Colab) Notebook kullanılarak gerçekleştirilmiştir. Colab, Google tarafından sunulan ve donanım hızlandırıcıları olarak Grafik İşleme Birimi'ne (GPU) ve Tensör İşleme Birimlerine (TPU) ücretsiz erişim sağlayan çevrimiçi bir platformdur. Uygulamalarımızı çalıştırırken donanım hızlandırıcı olarak GPU kullanılması tercih edilmektedir. GPU, veri hesaplama için 12.69 GB RAM ve 78.19 GB depolama alanına sahip bir Python 3 masaüstü bilgisayarda kod çalıştırma olanağı

sunmaktadır. Tüm uygulamalarda, 0.001 öğrenme oranlı kategorik çapraz entropi ve optimizasyon için Adam kullanılmaktadır. Yığın boyutu (batch size) 100 ve adım sayısı (epoch) 100 olarak ayarlanmıştır. Eğitim örneklerinin oranı ve girdinin boyutu, HUAG sınıflandırmanın doğruluğunu etkileyen faktörlerdir. Her iki veri kümesi de evrişim için 11×11 komşuluk (pencere boyutu) kullanılmaktadır. IP ve SA veri setlerinin eğitim örnek oranları sırasıyla %20 ve %10 olarak alınmıştır. Uygulamalarımızda ise IP ve SA veri setleri için sırasıyla 30 ve 15 temel bileşen kullanılmaktadır. Diğer derin öğrenme tabanlı yöntemlerle daha iyi bir karşılaştırma yapabilmek için değerler bu şekilde seçilmiştir. Yani komşuluk çıkarımı sonucunda elde edilen 3B yamaların boyutu sırasıyla IP için $11 \times 11 \times 30$ ve SA için $11 \times 11 \times 15$ olarak ayarlanmıştır.

Tablo 2. Her sınıfın IP ve SA verisetlerindeki örneklerle ilgili bilgiler

No	Renk	Indian Pines (IP)		Salinas (SA)	
		Sınıf	Örnek	Örnek	SA
1		Alfalfa	46	Brocoli_green_weeds_1	2009
2		Corn-notill	1428	Brocoli_green_weeds_2	3726
3		Corn-mintill	830	Fallow	1976
4		Corn	237	Fallow_rough_plow	1394
5		Grass-pasture	483	Fallow_smooth	2678
6		Grass-trees	730	Stubble	3959
7		Grass-pasture-mowed	28	Celery	3579
8		Hay-windrowed	478	Grapes_untrained	11,271
9		Oats	20	Soil_vinyard_develop	6203
10		Soybean-notill	972	Corn_senesced_green_weeds	3278
11		Soybean-mintill	2455	Lettuce_romaine_4wk	1068
12		Soybean-clean	593	Lettuce_romaine_5wk	1927
13		Wheat	205	Lettuce_romaine_6wk	916
14		Woods	1265	Lettuce_romaine_7wk	1070
15		Buildings-grass-trees-drives	386	Vinyard_untrained	7268
16		Stone-steel-towers	93	Vinyard_vertical_trellis	1807
Total Number			10,249		54,129


Her yöntemin sınıflandırma sonuçlarını değerlendirmek için genel doğruluk (GD), Ortalama doğruluk (OD) ve Kappa istatistikleri (K) kullanılmıştır. GD, test örneklerinde doğru sınıflandırılmış örnekler ile toplam test örnek sayısı arasındaki oran ile hesaplanmaktadır. OD, her sınıfın doğruluğunun ortalama değeridir. K, temel doğruluk haritası ile sınıflandırma haritası arasında güçlü bir anlaşmaya ilişkin karşılıklı bilgi sağlayan istatistiksel bir ölçüm metriğidir. Önerilen yöntem (ÖY), SVM-RBF [29], 2B ESA [30], 3B ESA [8], SSRN [21] ve HybridSN [22] gibi literatürden alınan derin öğrenmeye dayalı HUAG sınıflandırma yöntemleri ile karşılaştırılmıştır.

İlk uygulama IP veriseti kullanılarak gerçekleştirilmiştir. Her sınıfın sınıf bazında ve GD, OD ve K değerlendirme ölçütlerine göre sınıflandırma doğruluğu Tablo 3'te gösterilmiştir. IP veriseti ile yapılan uygulamalar sonucunda elde edilen temel doğruluk (ground truth) ve sınıflandırma haritaları Şekil 4'te verilmiştir. Tablo 3 incelendiğinde önerilen yöntemin GD, OD ve K değerlendirme ölçütlerine göre sırasıyla %99.45, %99.66 ve %99.37 ile en iyi sınıflandırma sonucunu elde ettiği görülmektedir. Önerilen yöntem en yakın sonuçlar %99.19 GD, %98.93 OD ve %99.07 K değerleri ile SSRN, %99.26 GD, %98.98 OD ve %99.09 K değerleri ile HybridSN yönteminde elde edilmiştir. Diğer sınıflandırma yöntemlerinden en düşük GD, OD ve K değerleri sırasıyla %82.83, %80.84 ve %82.23 ile SVM-RBF'de elde edilmiştir. SVM-RBF'deki OD değerine bakıldığında her sınıf için doğru sınıflandırma sayısının diğer yöntemlere göre daha az olduğu görülmektedir. 2B ESA yönteminde sırasıyla, %90.89 GD, %89.68 OD, %88.56 K değeri ve 3B ESA'da ise %94.07 GD, %93.72 OD, %93.87 K değeri elde edilmiştir. Sınıf bazlı sınıflandırma performansları göz önüne alındığında ise, önerilen yöntem ile 2., 3., 10., 11., 12. ve 15.

sınıflar dışındaki tüm sınıflarda %100 ile en iyi sınıflandırma doğrulukları elde edilmektedir. Sınıf 2 için % 99.17 ile SSRN’de, sınıf 3, 10, 11, 12,15 için sırasıyla %99.55, %99.61, %99.85, %99.31, %99.68 ile önerilen yöntem ile en iyi sınıflandırma doğrulukları elde edilmiştir. Şekil 4 incelendiğinde, temel doğruluk haritasına en çok benzeyen önerilen yöntem olduğu görülmektedir.

Tablo 3. IP verisetinin eğitim-test örnek sayıları ve sınıflandırma doğrulukları (%)

No	Eğitim/Test	SVM-RBF	2B ESA	3B ESA	SSRN	HybridSN	ÖY
1	9/37	61.5	85.88	94.63	97.82	97.98	100
2	285/1143	78.68	91.31	93.9	99.17	98.37	97.64
3	166/664	73.41	91.07	94.85	99.53	99.48	99.55
4	47/190	71.58	80.38	93.48	97.79	97.38	100
5	97/386	80.38	91.89	93.56	99.24	99.23	100
6	146/584	92.27	99.01	94.2	99.51	99.14	100
7	6/22	79.52	82.59	89.73	98.7	99	100
8	96/382	87.38	100	96.01	99.85	100	100
9	4/16	85.87	66.55	95	98.5	99.01	100
10	194/778	77.58	86.38	94.55	98.74	98.76	99.61
11	491/1964	83.75	90.47	93.87	99.3	99.64	99.85
12	118/475	83.21	82.89	91.52	98.43	99.12	99.31
13	41/164	84.64	99.06	93.89	100	100	100
14	253/1012	98.01	97.86	91.77	99.31	100	100
15	77/309	94.3	90.52	95.03	99.2	99.35	99.68
16	19/74	61.43	98.94	93.57	97.82	97.26	100
GD (%)		82.83	90.89	94.07	99.19	99.26	99.45
OD (%)		80.84	89.68	93.72	98.93	98.98	99.66
K x100		82.23	88.56	93.87	99.07	99.09	99.37




Şekil 4. IP için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) HUAG RGB görüntüsü, (b) temel doğruluk (ground truth), (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HybridSN ve (h) ÖY

İkinci uygulama kapsamında SA veriseti kullanılmıştır. SA veri seti ile yapılan uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Tablo 4'te verilmiştir. Sınıflandırma sonucunda elde edilen sınıflandırma haritaları Şekil 5'te gösterilmiştir. Tablo 4 incelendiğinde önerilen yöntemde en iyi sınıflandırma doğrulukları %99.95 GD, %99.93 OD ve 99.95 K değerleri ile elde edilmiştir. Önerilen

yönteme en yakın sonuçlar tüm değerlendirme metriklerinde %99.80 ile HybridSN ve %99.64 GD, %98.76 OD, %99.60 K değerleri ile SSRN yönteminde elde edilmiştir. En kötü sınıflandırma doğruluğu IP verisetinde de olduğu gibi %92.67 GD, %91.61 OD ve %92.21 değerleri ile SVM-RBF yöntemiyle elde edilmiştir. 3B ESA %94.02 GD, %93.49 OD, %93.57 K değeri ile SVM-RBF'den sonra en kötü sonuçların elde edildiği yöntem olmuştur. 2B ESA ile %95.34 GD, %94.75 OD ve %94.93 K değeri elde edilmiştir. Sınıf bazlı sınıflandırma doğrulukları incelendiğinde, önerilen yöntem en iyi sınıflandırma doğruluğuna %100 ile 1., 2., 3., 5., 7., 8., 9., 11., 12., 13., 16. sınıflarda ulaşmıştır. En iyi sınıflandırma sonuçları 4., 6., 10., 14. sınıflar için %100 ile HybridSN yönteminde elde edilmiştir. 15 nolu sınıf için %99.92 ile önerilen yöntem en iyi sınıflandırma sonuçlarını vermektedir. Şekil 5 göz önüne alındığında, temel doğruluk haritasına en çok benzeyen önerilen yöntem ile elde edilen sınıflandırma haritası olduğu görülmektedir. Önerilen yöntemden sonra ise HybridSN yönteminin sınıflandırma haritası temel doğruluk haritasına en çok benzemektedir.

Tablo 4. SA verisetinin eğitim-test örnek sayıları ve sınıflandırma doğrulukları (%)

No	Eğitim/Test	SVM-RBF	2B ESA	3B ESA	SSRN	HybridSN	ÖY
1	201/1808	92.56	95.51	95.19	99.78	100	100
2	372/3354	94.78	95.87	96.12	99.78	100	100
3	197/1779	94.22	95.64	95.89	99.78	100	100
4	139/1255	97.36	99.99	97.18	99.99	100	99.44
5	268/2410	93.38	94.51	94.70	99.78	100	100
6	396/3563	95.36	96.71	95.63	99.78	100	99.92
7	358/3221	95.79	95.51	95.36	99.78	100	100
8	1127/10144	80.21	86.93	86.33	99.78	100	100
9	620/5583	97.67	97.42	97.19	99.78	100	100
10	328/2950	88.99	90.93	90.94	92.69	100	99.76
11	107/961	90.20	94.24	90.20	90.68	98.24	100
12	193/1734	96.42	99.91	96.24	99.95	99.61	100
13	91/825	95.53	95.53	95.31	99.85	99.59	100
14	107/963	91.26	92.97	94.18	99.88	100	99.90
15	727/6541	72.67	90.93	81.39	99.12	99.32	99.92
16	181/1626	89.37	93.43	94.09	99.78	100	100
GD (%)		92.67	95.34	94.02	99.64	99.80	99.95
OD (%)		91.61	94.75	93.49	98.76	99.80	99.93
K x 100		92.21	94.93	93.57	99.60	99.80	99.95



Şekil 5. SA için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) HUAG RGB görüntüsü, (b) temel doğruluk (ground truth), (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HybridSN ve (h) ÖY

4. SONUÇ (CONCLUSION)

Bu çalışmada, hiperspektral uzaktan algılama görüntülerinin sınıflandırılması için derinlemesine ayrılabilir evrişim tabanlı artık ağ mimarisi önerilmiştir. Önerilen ağ mimarisi 4 bölümden oluşmaktadır. Öncelikle komşuluk çıkarımı sonucunda elde edilen 3B hiperspektral küp'e 3B evrişim işlemi uygulanmaktadır. Ardından tamamı 3B evrişimlerden oluşan ard arda 2 artık bloktan geçirilmektedir. Elde edilen özellik haritasına tekrardan 3B evrişim uygulanmakta ve yeni bir özellik haritası elde edilmektedir. 3B özellik haritasından daha fazla uzamsal özellik çıkarabilmek için yeniden boyutlandırma yapılarak özellik haritası 2B yapılmaktadır. Elde edilen 2B görüntüye, öncelikle 2B evrişim işlemi uygulanmaktadır. Daha sonra tamamı 2B derinlemesine ayrılabilir evrişimlerden oluşan ard arda 2 artık bloktan geçirildikten sonra elde edilen özellik haritasına tekrardan 2B evrişim uygulanmaktadır. Tüm işlemler tamamlandıktan sonra sınıflandırma işlemi gerçekleştirilmektedir. Derinlemesine ayrılabilir evrişim kullanılmasının amacı, eğitilebilir parametre sayısını azaltarak eğitim işlemini hızlandırmak ve aşırı öğrenme problemini önlemektir. Önerilen yöntemi test etmek için Indian pines ve Salinas hiperspektral uzaktan algılama görüntü verisetleri kullanılmıştır. Gerçekleştirilen uygulamalar sonucunda, Indian pines verisetinde sırasıyla %99.45 GD, %99.66 OD, %99.37 K değeri elde edilirken, Salinas verisetinde %99.95 GD, %99.93 OD ve %99.95 K değeri elde edilmiştir. Bu sınıflandırma sonuçlarına göre, önerilen yöntem mimarisi, karşılaştırma için kullanılan diğer yöntemlerden başarılı olduğu görülmektedir. Gelecek çalışmalarda, derinlemesine ayrılabilir evrişim katmanları ile kodlayıcı-kod çözücü ağ mimarilerinin beraber kullanıldığında hiperspektral uzaktan algılama görüntü sınıflandırmasını nasıl etkilediği üzerinde çalışma yapılması planlanmaktadır.

KAYNAKLAR (REFERENCES)

- [1] C. Chen et al., "Hyperspectral classification based on spectral-spatial convolutional neural networks," *Engineering Applications of Artificial Intelligence*, vol. 68, no. October 2017, pp. 165–171, 2018, doi: 10.1016/j.engappai.2017.10.015.
- [2] H. Fırat and D. Hanbay, "4CF-Net: Hiperspektral uzaktan algılama görüntülerinin spektral uzamsal sınıflandırılması için yeni 3B evrişimli sinir ağı," *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, vol. 1, pp. 439–453, 2021, doi: 10.17341/gazimmfd.901291.
- [3] S. K. Roy, S. Chatterjee, S. Bhattacharyya, B. B. Chaudhuri, and J. Platos, "Lightweight Spectral-Spatial Squeeze-and-Excitation Residual Bag-of-Features Learning for Hyperspectral Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 8, pp. 5277–5290, 2020, doi: 10.1109/TGRS.2019.2961681.
- [4] H. Fırat, M. E. Asker, and D. Hanbay, "Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN," *Remote Sensing Applications: Society and Environment*, p. 100694, 2022, doi: 10.1016/j.rsase.2022.100694.
- [5] J. Li, J. M. Bioucas-Dias, and A. Plaza, "Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 11, pp. 4085–4098, 2010, doi: 10.1109/TGRS.2010.2060550.
- [6] Y. Wang, W. Yu, and Z. Fang, "Multiple Kernel-based SVM classification of hyperspectral images by combining spectral, spatial, and semantic information," *Remote Sensing*, vol. 12, no. 1, 2020, doi: 10.3390/RS12010120.
- [7] J. S. Ham, Y. Chen, M. M. Crawford, and J. Ghosh, "Investigation of the random forest framework for classification of hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 492–501, 2005, doi: 10.1109/TGRS.2004.842481.
- [8] Y. Li, H. Zhang, and Q. Shen, "Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network," *Remote Sensing*, vol. 9, no. 1, 2017, doi: 10.3390/rs9010067.
- [9] A. Mohan and M. Venkatesan, "HybridCNN based hyperspectral image classification using

- multiscale spatio-spectral features,” *Infrared Physics & Technology*, vol. 108, no. March, 2020, doi: 10.1016/j.infrared.2020.103326.
- [10] H. Üzen, M. Turkoglu, M. Aslan, and D. Hanbay, “Depth-wise Squeeze and Excitation Block-based Efficient-Unet model for surface defect detection,” *The Visual Computer*, 2022, doi: 10.1007/s00371-022-02442-0.
- [11] C. Zhao, X. Wan, G. Zhao, B. Cui, W. Liu, and B. Qi, “Spectral-Spatial Classification of Hyperspectral Imagery Based on Stacked Sparse Autoencoder and Random Forest,” *European Journal of Remote Sensing*, vol. 50, no. 1, pp. 47–63, 2017, doi: 10.1080/22797254.2017.1274566.
- [12] H. Data et al., “Deep Learning-Based Classification of Hyperspectral Data,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 6, pp. 2094–2107, 2014, doi: 10.1109/JSTARS.2014.2329330.
- [13] A. Mughees and L. Tao, “Efficient deep auto-encoder learning for the classification of hyperspectral images,” *Proc. - 2016 Int. Conf. Virtual Real. Vis. ICVRV 2016*, no. September, pp. 44–51, 2017, doi: 10.1109/ICVRV.2016.16.
- [14] Y. Chen, X. Zhao, and X. Jia, “Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2381–2392, 2015, doi: 10.1109/JSTARS.2015.2388577.
- [15] J. Li, B. Xi, Y. Li, Q. Du, and K. Wang, “Hyperspectral classification based on texture feature enhancement and deep belief networks,” *Remote Sensing*, vol. 10, no. 3, 2018, doi: 10.3390/rs10030396.
- [16] C. Zhang et al., “Joint Deep Learning for land cover and land use classification,” *Remote Sensing of Environment*, vol. 221, no. May 2018, pp. 173–187, 2019, doi: 10.1016/j.rse.2018.11.014.
- [17] H. Firat, M. Uçan, and D. Hanbay, “Classification of Hyperspectral Remote Sensing Images Using Hybrid 3D-2D CNN Architecture,” *Journal of Computer Science*, vol. IDAP-2021, no. Special, pp. 132–140, 2021.
- [18] C. Mu, Z. Guo, and Y. Liu, “A multi-scale and multi-level spectral-spatial feature fusion network for hyperspectral image classification,” *Remote Sensing*, vol. 12, no. 1, 2020, doi: 10.3390/RS12010125.
- [19] Z. Meng, L. Li, X. Tang, Z. Feng, L. Jiao, and M. Liang, “Multipath residual network for spectral-spatial hyperspectral image classification,” *Remote Sensing*, vol. 11, no. 16, pp. 1–19, 2019, doi: 10.3390/rs11161896.
- [20] L. Song, W.; Li, S.; Fang, “Hyperspectral Image Classification with Deep Feature Fusion Network,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 99, pp. 3173–3184, 2018, doi: 10.1109/IGARSS.2019.8898520.
- [21] Z. Zhong, J. Li, Z. Luo, and M. Chapman, “Spectral-Spatial Residual Network for Hyperspectral Image Classification: A 3-D Deep Learning Framework,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 56, no. 2, pp. 847–858, 2018, doi: 10.1109/TGRS.2017.2755542.
- [22] S. K. Roy, G. Krishna, S. R. Dubey, and B. B. Chaudhuri, “HybridSN: Exploring 3D-2D CNN Feature Hierarchy for Hyperspectral Image Classification,” *arXiv*, vol. 17, no. 2, pp. 277–281, 2019.
- [23] M. Ahmad, A. M. Khan, M. Mazzara, S. Distefano, M. Ali, and M. S. Sarfraz, “A Fast and Compact 3-D CNN for Hyperspectral Image Classification,” *IEEE Geoscience and Remote Sensing Letters*, no. April, pp. 1–5, 2020, doi: 10.1109/LGRS.2020.3043710.

- [24] Z. Ge, G. Cao, X. Li, and P. Fu, "Hyperspectral Image Classification Method Based on 2D-3D CNN and Multibranch Feature Fusion," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 5776–5788, 2020, doi: 10.1109/JSTARS.2020.3024841.
- [25] H. C. Mingyi He, Bo Li, "Multi-scale 3D deep convolutional neural network for hyperspectral image classification," *2017 IEEE Int. Conf. Image Process.*, pp. 3904–3908, 2017.
- [26] L. Dang, P. Pang, and J. Lee, "Depth-wise separable convolution neural network with residual connection for hyperspectral image classification," *Remote Sensing*, vol. 12, no. 20, pp. 1–20, 2020, doi: 10.3390/rs12203408.
- [27] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016, vol. 2016-Decem, pp. 770–778, doi: 10.1109/CVPR.2016.90.
- [28] M. E. Paoletti, J. M. Haut, J. Plaza, and A. Plaza, "Deep learning classifiers for hyperspectral imaging: A review," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 158, no. September, pp. 279–317, 2019, doi: 10.1016/j.isprsjprs.2019.09.006.
- [29] B. C. Kuo, H. H. Ho, C. H. Li, C. C. Hung, and J. S. Taur, "A kernel-based feature selection method for SVM with RBF kernel for hyperspectral image classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 1, pp. 317–326, 2014, doi: 10.1109/JSTARS.2013.2262926.
- [30] Q. Wang, J. Gao, and Y. Yuan, "A Joint Convolutional Neural Networks and Context Transfer for Street Scenes Labeling," *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 5, pp. 1457–1470, 2018, doi: 10.1109/TITS.2017.2726546.