

Hiperspektral Görüntü Sınıflandırma için Hibrit Evrimsel Sinir Ağı ve Sıkma- Uyarma Bloğu Yöntemi

Mehmet NERGİZ^{1*}

¹ Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Dicle Üniversitesi, Diyarbakır, Türkiye
^{*1} mnergiz@dicle.edu.tr

(Geliş/Received: 23/01/2023;

Kabul/Accepted: 27/02/2023)

Öz: Yüksek spektral çözünürlüğe sahip bir tür optik uzaktan algılama görüntüsü olarak, hiperspektral görüntüler, zengin spektral özellik bilgisine sahip 3 boyutlu görüntü küpleridir. Şu anda hiperspektral görüntü sınıflandırması, uzaktan algılama alanındaki en aktif araştırma alanlarından biridir. Son yıllarda bu alanda derin öğrenme ve özellikle evrimsel sinir ağları (ESA) sıklıkla kullanılmaktadır. Bu çalışma kapsamında, hiperspektral görüntü sınıflandırması için yeni bir model geliştirilmiştir. Önerilen model, 3B ESA, Sıkma-uyarma bloğu ve 2B Derinlemesine ayrılabilir evrimselden (DAE) oluşmaktadır. 2B ESA ile spektral özellik bilgileri elde edilemediğinden dolayı, hem spektral hem de uzamsal özellikleri elde etmek için 3B ESA kullanılmıştır. Sadece 3B ESA kullanımı hesaplama karmaşıklığını arttırmaktadır. Hibrit ESA kullanımı bu sorunu çözmektedir. Hibrit ESA'larda daha fazla uzamsal özellik çıkarabilmek için 3B ESA'dan sonra 2B ESA kullanılmaktadır. Ancak bu çalışma kapsamında, 2B ESA yerine 2B DAE kullanımı tercih edilmiştir. Standart 2B ESA yerine 2B DAE kullanımı ile eğitilebilir parametre sayısı ve hesaplama maliyeti azaltılmıştır. Bu, sınıflandırma performansını arttırmıştır. Ayrıca, özellik çıkarma ve hiperspektral görüntü sınıflandırmasındaki performansı arttırmak için Hibrit ESA modeli bir sıkma-uyarma bloğu ile birleştirilmiştir. Önerilen yöntemin sınıflandırma performansını test etmek için HyRank-Loukia ve Houston 2013 verisetleri kullanılmıştır. %10 eğitim örneği alınarak gerçekleştirilen uygulamalar sonucunda sırasıyla %90.86 ve %99.39 genel doğruluk değeri elde edilmiştir. Ayrıca, önerilen yöntem literatürden yedi farklı yöntem ile karşılaştırılmış ve önerilen yöntemin daha iyi sonuç verdiği görülmüştür.

Anahtar kelimeler: Hiperspektral görüntü sınıflandırma, derin öğrenme, evrimsel sinir ağı, derinlemesine ayrılabilir evrişim, sıkma-uyarma bloğu.

Hybrid Convolutional Neural Network and Squeeze-Excitation Block Method for Hyperspectral Image Classification

Abstract: As a kind of optical remote sensing image with high spectral resolution, hyperspectral images are 3D image cubes with rich spectral feature information. At present, hyperspectral image classification is one of the most active research areas in the remote sensing field. In recent years, deep learning and especially convolutional neural networks (CNN) have been used frequently in this field. In this study, a new model has been developed for hyperspectral image classification. The proposed model consists of 3D CNN, Squeeze-and-Excitation, and 2D Depthwise separable convolution (DSC). Since spectral feature information cannot be obtained with 2D CNN, 3D CNN is used to obtain both spectral and spatial features. Using only 3D CNN is that it increases computational complexity. The use of hybrid CNN solves this problem. In order to extract more spatial features in hybrid CNNs, 2D CNN is used after 3D CNN. However, within the scope of this study, the use of 2D DSC was preferred instead of 2D CNN. By using 2D DSC instead of standard 2D CNN, the number of trainable parameters and computational cost are reduced. This has improved the classification performance. In addition, the hybrid CNN model is combined with a Squeeze-and-Excitation block to improve performance in feature extraction and hyperspectral image classification. HyRank-Loukia and Houston 2013 datasets were used to test the classification performance of the proposed method. As a result of the applications performed by taking 10% training samples, 90.86% and 99.39% overall accuracy values were obtained, respectively. In addition, the proposed method was compared with seven different methods from the literature and it was seen that the proposed method gave better results.

Key words: Hyperspectral image classification, deep learning, convolutional neural network, depthwise separable convolution, squeeze-excitation block.

1. Giriş

Hiperspektral görüntüler, 3 boyutlu (3B) (bir spektral-iki uzamsal) hiperküp olarak temsil edilmektedir. Bu görüntüler, RGB ve multispektral görüntülere kıyasla yüzlerce spektral banttan oluşmaktadır [1]. Ayrıca zengin

* Sorumlu yazar: mnergiz@dicle.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-0867-5518

spektral özellik bilgisi içermektedirler. Zengin spektral özellik bilgileri sayesinde, yer nesnelere tanınması ve sınıflandırılması daha doğru bir şekilde yapılabilmektedir [2]. Bu nedenle astronomi, tarım, askeri gözetleme, nesne tespiti, yangın izleme, madencilik, bitki örtüsü analizi, ekin izleme gibi birçok gerçek yaşam uygulamasında yaygın olarak kullanılmaktadır [3,4]. Bununla birlikte, orijinal hiperspektral görüntülerin bol spektral özellik bilgisi, spektral fazlalığa neden olmaktadır. Bu durum hiperspektral görüntü sınıflandırma performansını düşürmektedir. Bu sorunu çözmek için, orijinal hiperspektral görüntü verilerine Temel bileşen analizi (TBA), Lineer diskriminant analizi (LDA), Kernel TBA, Bağımsız bileşen analizi, artımlı temel bileşen analizi gibi boyut indirgeme yöntemleri uygulanmaktadır [5]. Bu boyut indirgeme yöntemleri arasında en sık kullanılan yöntem TBA'dır. TBA, denetimsiz ve doğrusal bir yöntemdir. Temel bileşenlerin spektral bilgilerini daha büyük bir varyans katkısıyla korurken, hiperspektral görüntü verilerinden büyük miktarda fazla spektral bilgiyi kaldırabilmektedir. TBA'dan sonra spektral boyut sayısı azalmakta ve hesaplama maliyeti düşmektedir [6].

Hiperspektral görüntülerde sınıflandırma oldukça önemli ve zorlu bir problem olduğundan, hiperspektral görüntü sınıflandırma birçok araştırmacı tarafından araştırmalarının odak noktası haline gelmiştir. Destek vektör makinesi [7], lojistik regresyon [8] ve k-en yakın komşular [9] gibi geleneksel hiperspektral görüntü sınıflandırma yöntemleri, genellikle hiperspektral görüntü sınıflandırma için birçok spektral özellik bilgisinin kullanılmasına dayanmaktadır. Bununla birlikte, hiperspektral görüntüler hem spektral bantlar arasında yüksek korelasyona hem de spektral bant fazlalığına sahip olduğundan, bu tipik sınıflandırıcılar ile yüksek sınıflandırma doğruluğu elde edilememektedir. Ayrıca, yalnızca spektral özellikleri kullanan bu geleneksel sınıflandırıcılar, yüksek çözünürlüklü veriler için algılanan önemli uzamsal özellikleri elde edememektedir. Bu durum genellikle hiperspektral görüntülerde daha düşük sınıflandırma doğruluğuna neden olmaktadır. Sınıflandırma doğruluğunu arttırmanın en basit yolu, hem spektral hem de uzamsal özellikleri bir arada kullanan sınıflandırma yöntemleri geliştirmektir. Hiperspektral görüntülerde uzamsal özellikler spektral özelliklerle morfolojik profiller, çoklu çekirdek öğrenme, süper piksel ve seyrek temsil tabanlı yöntemlerle birleştirilmektedir [10]. Spektral özellik bilgisinin uzamsal özellik bilgisi ile birlikte kullanılması sınıflandırma performansını arttırmaktadır. Bununla birlikte, çoğu geleneksel sınıflandırıcılar, hem spektral hem de uzamsal özellikleri manuel olarak çıkarmaktadır.

Son yıllarda, derin öğrenmeye dayalı yöntemler, özellikle evrişimsel sinir ağları (ESA), hiperspektral görüntü sınıflandırmada yaygın olarak kullanılmaktadır. Geleneksel sınıflandırıcılardan farklı olarak, derin öğrenme yöntemlerinin eğitim aşaması özellikleri otomatik olarak çıkarmakta ve çıkarılan özellikleri sınıflandırma aşamasında kullanmaktadır [11]. ESA, hiperspektral görüntü sınıflandırmada daha belirgin özellikler sağladığından, oldukça iyi özellik öğrenme özelliğine sahiptir. Sınıflandırma problemlerinin daha kolay çözülebilmesi için öğrenilen özelliklerin ayırt edici olması gerekmektedir. Bu, sınıflandırma performansını önemli ölçüde arttırmaktadır. Bu nedenle, ESA tabanlı yöntemler, hiperspektral görüntü sınıflandırmada daha derin uzamsal-spektral öznelikler çıkarmak için kullanılan en güçlü yöntemlerden biridir. Bu yöntemler, sınıflandırma doğruluğunu arttırdıkları için çoğu araştırmacı tarafından çalışmalarda yaygın olarak kullanılmaktadır.

ESA, uzamsal spektral özellik bilgilerini çıkarırken yüksek sınıflandırma doğruluğu sağlamaktadır. Bu yönüyle diğer derin öğrenme temelli yöntemlere kıyasla hiperspektral görüntü sınıflandırma alanında sıklıkla kullanılan önemli bir yöntem olduğunu kanıtlamıştır. Son yıllarda literatürde incelendiğinde de bu alanda oldukça sık kullanıldığı görülmektedir. Bu çalışma kapsamında da hiperspektral görüntü sınıflandırması için hibrit ESA ve sıkma-uyarma bloğundan (SU) oluşan bir yöntem önerilmiştir. Önerilen yöntem 3B ESA, SU bloğu ve 2B Derinlemesine ayrılabilir evrişim katmanlarından oluşmaktadır. Bu çalışmada önerilen yöntemin katkıları şu şekildedir:

- Hiperspektral görüntü sınıflandırmada 2B ESA kullanılan çalışmalarda sadece uzamsal özellikler çıkarılmaktadır. Ayırt edici özellikler spektral boyuttan çıkarılmadığından, önemli spektral özellikler kaybolmaktadır. Hiperspektral görüntü sınıflandırmada en önemli sorunlardan biri, hem spektral hem de uzamsal özelliklerin dikkate alınmasıdır. 2B ESA ile her iki özellik bilgisi elde edilememektedir. 2B ESA'dan farklı olarak, 2B evrişim yerine 3B evrişimlerin kullanıldığı 3B ESA'da uzamsal-spektral özellikler eş zamanlı olarak çıkarıldığı için hiperspektral görüntü sınıflandırmada kullanılmıştır.
- Ancak, 3B ESA kullanımı, hesaplama karmaşıklığında bir artışa neden olmaktadır. Ayrıca, hiperspektral görüntülerdeki farklı sınıflar birçok spektral bant üzerinde benzer dokulara sahip olduğunda tek başına 3B ESA kullanımı sınıflandırma doğruluğunu azaltabilmektedir. 2B ve 3B ESA ayrı ayrı kullanıldığında ortaya çıkan problemlerin üstesinden gelmek için her iki yöntemin birlikte kullanıldığı hibrit ESA yöntemine odaklanılmıştır. Hibrit ESA yöntemi ile hem uzamsal hem de spektral öznelik bilgisinden tam olarak yararlanılması amaçlanmaktadır. Bu, sınıflandırma doğruluğunu arttırmaktadır.
- Önerilen yöntemimizdeki bir başka motivasyonumuz hibrit ESA yönteminde 2B Evrişim yerine 2B derinlemesine evrişim katmanlarının kullanılmasıdır. Derinlemesine evrişim katmanları kullanılarak,

eğitilebilir parametre sayısı azaltılmış ve sınıflandırma performansı arttırılmıştır. Bu sayede önerilen hibrit yöntemin sınıflandırma doğruluğunun arttırılması amaçlanmıştır.

- SU bloğu, toplam parametre sayısını minimum düzeyde arttırırken sınıflandırma performansını arttırdıkları için önerilen yönteme entegre edilmiştir.
- Önerilen yöntemin sınıflandırma performansını değerlendirmek için uygulamalarda HyRank-Loukia [28] ve Houston 2013 [29] veri setleri kullanılmıştır. %10'luk bir eğitim örneği kullanıldığında, HyRank-Loukia için sırasıyla %90.86 genel doğruluk, %89.13 kappa, %84.39 ortalama doğruluk ve Houston 2013 için %99.39 genel doğruluk, %99.34 kappa, %99.42 ortalama doğruluk sonuçları elde edilmiştir.

Çalışmanın geri kalanı şu şekildedir: Literatürde hiperspektral görüntü sınıflandırma alanında derin öğrenme ile gerçekleştirilen çalışmalar, ilgili çalışmalar bölümünde yer almaktadır. Hibrit ESA'nın teorik altyapısını oluşturan, derinlemesine ayrılabilir evrişim ağları, 3B-2B ESA ve önerilen yöntem materyal ve metot bölümünde açıklanmıştır. Ayrıca çalışmada kullanılan veri setleri ile ilgili bilgilerde materyal ve metot bölümünde yer almaktadır. Kullanılan veri setlerine ilişkin uygulamalar ve bu uygulamaların sınıflandırma sonuçları uygulamalar ve uygulama sonuçları bölümünde yer almaktadır. Bu çalışmanın genel bir değerlendirmesine sonuçlar bölümünde yer verilmiştir.

2. İlgili Çalışmalar

Derin öğrenme, özellikle ESA tabanlı yöntemler, hiperspektral görüntülerin sınıflandırılmasında araştırmacılar tarafından yaygın olarak kullanılmaktadır. Roy vd. [1] hiperspektral görüntü sınıflandırma için etkili bir S3EResBoF (spektral-uzaysal sıkma ve uyarma artık özellik çantası) öğrenme yöntemini geliştirdi. Bu yöntem, sınıflandırma performansını arttırmak için uzamsal ve spektral artık öğrenme blokları içermektedir. Ek olarak, her artık bloğu bir sıkma ve uyarma ağı takip etmektedir. Roy vd. [12], 2B ve 3B ESA'yı birlikte kullanarak hiperspektral görüntü sınıflandırma için bir HybridSN (Hybrid SpectralNet) yöntemi geliştirdi. Geliştirilen yöntemde öncelikle uzamsal-spektral özellikleri çıkarmak için 3B ESA gerçekleştirilmiştir. Ardından, daha fazla uzamsal özellik çıkarmak için 2B ESA uygulanmıştır. Ahmad [13], sınıflandırma doğruluğunu arttırmak için 4 ardışık 3B evrişim katmanından oluşan bir yöntem (FC3B ESA) geliştirdi. Ayrıca boyut indirgeme yöntemi olarak artımlı TBA'yı kullandı. Roy, Dubey vd. [14] maksimum ve küresel havuzlama gibi farklı sıkma türlerinde çift doğrusal bir füzyon işlemi olan FuseNet'i tasarladı. FuseNet yönteminde, sıkma ve uyarma ağı artık blok ile birleştirilmiştir. Iyer vd. [15], hiperspektral görüntü sınıflandırma için Inception modüllerini kullanan bir yöntem önerdi. Ardından geliştirdikleri Inception modülüne HybridSN ve Inception artık ağ mimarisini eklediler. Yang [16], hiperspektral görüntü sınıflandırma için yeni bir sinerjik evrişimsel sinir ağı önerdi. Önerilen yöntem, hibrit 3B-2B ESA ve uzamsal-spektral özellik bilgisini birleştiren veri etkileşimi modüllerinden oluşmaktadır. Ayrıca, tamamen bağlı katmandan önceki bilgileri ve özellikleri etkili bir şekilde filtrelemeye yardımcı olan bir 3B dikkat mekanizması sunmaktadırlar. Firat vd. [17] 3B ESA ve ResNet18 mimarisini kullanarak derin uzamsal spektral özellikleri çıkarmak için hibrit bir 3B artık uzamsal-spektral evrişim ağı önermişlerdir. Eşzamanlı olarak spektral-uzamsal özellik çıkarımı, 3B ESA kullanılarak sağlanmıştır. Daha derin ESA'larda, katman sayısı arttıkça daha yüksek sınıflandırma performansı elde etmek için artık ağ (ResNet) mimarisi kullanılmıştır. Ayrıca ResNet mimarisi sayesinde derin ağlarda oluşabilecek bozulma ve kaybolan gradyan gibi problemlerin üstesinden gelinmiştir. Ali [18] hiperspektral görüntü sınıflandırma için çok yönlü Hibrit ESA ve sıkma-uyarma ağının bir kombinasyonundan oluşan bir yöntem önermektedir. Ding [19], çok ölçekli süper piksel tabanlı grafik özelliklerini ve yerel piksel özelliklerini çıkarabilen çok ölçekli grafik evrişimli ağı ve çok ölçekli ESA'yı entegre ederek hiperspektral görüntü sınıflandırması için yeni bir çok kademeli füzyon ağı önerdi. Hong [20], hiperspektral görüntü sınıflandırma için sıralı bir perspektiften transformatörler kullandı ve SpectralFormer adlı yeni bir yöntem önerdi. SpectralFormer, klasik transformatörlerdeki bant yönünde temsillerin ötesinde, hiperspektral görüntülerin komşu bantlarından spektral olarak yerel dizi bilgisini öğrenerek grup bazında spektral gömmeler sağlayabilmektedir.

3. Materyal ve Metot

Bu bölümde çalışma kapsamında önerilen yöntemin teorik arka planını oluşturan 3B-2B evrişimsel sinir ağı, 2B derinlemesine ayrılabilir evrişim, çalışma kapsamında kullanılan veri setleri ile ilgili bilgiler ve önerilen yöntemin detaylı açıklaması yer almaktadır.

3.1. 3B ve 2B evrişimsel sinir ağları (ESA)

Son zamanlarda sınıflandırma sürecinde derin öğrenme tekniklerinin kullanımı oldukça ilgi görmektedir. ESA, evrişim katmanı, havuzlama katmanı ve tamamen bağlantılı katman, sınıflandırma katmanı gibi farklı katmanlardan oluşan çok katmanlı sinir ağıdır. Evrişim işlemi, ESA modelinin birincil katmanı olan evrişim katmanındaki girdi verileri üzerinde gerçekleştirilir. Evrişim, alıcı alan ve çekirdek (öğrenilebilir parametreler) olmak üzere iki matris arasındaki nokta çarpım işlemidir. Genel olarak, çekirdek girdi verilerinin boyutundan daha küçüktür ve çekirdek girdi verileri üzerinde belirli bir adım (stride) değerine göre kaydırılarak mevcut özelliklere göre özellik haritası oluşturulur. Havuzlama katmanı, özellik haritasının uzamsal boyutunu azaltmada etkilidir ve genellikle evrişim katmanından sonra yer alır. Havuzlama işlemi, ağıdaki parametre sayısını azaltır ve aşırı öğrenmeyi etkili bir şekilde önler. Ağın son kısmı genellikle tamamen bağlı birkaç katmanı birbirine bağlar. Tamamen bağlı bir katmandaki her bir nöron, bir önceki katmandaki tüm nöronlarla bağlantı kurar ve çıktı değerini sınıflandırıcıya gönderir [21]. Bireysel nöronun x girdileri için çıktısı şu şekilde hesaplanır:


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

Denklem 1'de w filtre ağırlığıdır ve b bias değeridir. $f(\cdot)$, ağırlıklı bir girdi toplamına uygulanan doğrusal olmayan aktivasyon anlamına gelir. ReLU, derin sinir ağlarına dayalı olarak geliştirilen modellerde en sık kullanılan aktivasyon fonksiyonudur ve Denklem 2'deki gibi hesaplanır [22].

$$f(y) = \max(0, y) \quad (2)$$


Bu fonksiyonda, y 'in değeri sıfırdan büyükse y 'nin çıktısı, y 'in değeri sıfırdan küçük veya ona eşitse çıktısı sıfırdır. ReLU doğrusal olmayan işlevini kullanmanın temel avantajı, sıfırdan büyük tüm girdiler için sabit bir türev olmasıdır. Bu sabit türev, ağ öğrenimini hızlandırır. Sınıflandırma katmanı, ESA modelinin son katmanı ve sınıflandırma işleminin yapıldığı katmandır. Bu katmanın çıktı değerleri, tanınacak nesne sayısına bağlı olarak sınıf sayısına eşittir. Derin öğrenme mimarilerine dayanan softmax sınıflandırıcı bu katmanda yaygın olarak kullanılmaktadır. Bu sınıflandırıcı, her sınıf için 0-1 arasında olasılıksal değerler üretir. Sonuç olarak en yüksek olasılık değeri model tarafından tahmin edilen sınıfı verir [23]. Katmanların temel amacı, sınıflandırma işlemini gerçekleştirmek için daha sonraki katmanlarda kullanılacak yararlı özellikleri çıkarmaktır.

Geleneksel 2B ESA'da evrişim, 2×2 , 3×3 , 5×5 , 7×7 gibi 2B filtreler kullanılarak gerçekleştirilir. Bu işlem standart evrişimdir. Hiperspektral görüntü verilerine standart 2B ESA uygulandığında, yalnızca uzamsal özellik bilgisi elde edilir. Evrişim işlemi, Şekil 1'de gösterildiği gibi girdi görüntü matrisinin ve çekirdek/filtre matrisinin iç çarpımı ile gerçekleştirilir. Girdi görüntüsünün (özellik haritası) çıktısı, girdi görüntü matrisi üzerinde belirtilen adım sayısı (stride) kadar çekirdek matrisi sağa-sola, yukarı-aşağı kaydırılarak oluşturulur.



Şekil 1. 2B evrişim işlemi.

Hiperspektral görüntü verilerine standart 2B ESA uygulandığında, yalnızca uzamsal özellik bilgisi elde edilir. Hiperspektral görüntü verileri 3 boyutlu olduğu için 2 boyutlu ESA uygulandığında spektral öznelik bilgileri elde edilemez. Bu durumda, 3B evrişim katmanlarına sahip 3B ESA kullanılır. 3B ESA ile hem spektral hem de uzamsal özelliklerden yararlanır. 3B ESA'da kullanılan filtreler $3 \times 3 \times 3$, $5 \times 5 \times 5$, $7 \times 7 \times 7$ gibi 3B'dir. 3B Evrişim işlemi, standart 2B evrişim işlemiyle aynıdır. Geleneksel 2B ESA'larda, 2B özellik haritalarını elde etmek için evrişim işlemi yalnızca uzamsal boyutlara uygulanır ve önceki katmanın tüm özellik haritalarını içerir. Ayrıca, geleneksel 2B ESA'larda, giriş görüntüsü 2B veya 3B olsun, çıkış görüntüsü 2B'dir. Hiperspektral görüntüler 3B'dir. Şekil 2'de gösterildiği gibi hem spektral hem de uzamsal özellikleri elde etmek için bir 3B filtre kullanılır ve çıktı 3B'dir.



Şekil 2. 3B evrişim işlemi.

3.2. 2B Derinlemesine Ayrılabilir Evrişim (2B DAE)

Standart evrişimin aksine, derinlemesine ayrılabilir evrişimin (DAE) kullanımı, eğitilebilir parametrelerin sayısını azaltmanın etkili bir yolu olarak görülebilmektedir. Eğitilebilir parametre sayısının azaltılması sınıflandırma performansını artırabilmektedir. DAE, standart evrişim işlemini iki ayrı adımda gerçekleştirir. (1) Derinlemesine evrişim (DE) ve (2) Noktasal evrişim (NE). NE ayrıca 1x1 standart evrişimdir. DAE'de, girişleri tek adımda yeni bir çıkış kümesinde birleştiren ve filtreleyen standart evrişimden farklı olarak, DE önce her giriş kanalını bağımsız olarak filtreler, ardından NE, DE'nin çıkışını 1x1 evrişimle filtreleyerek birleştirir. Bu açıdan DAE çarpanlara ayrılmış evrişim olarak da tanımlanabilmektedir [24,25]. Şekil 3'te gösterildiği gibi, 2B DAE'de, DE kullanılarak, giriş görüntüsünün her kanalına ayrı ayrı evrişim işlemleri uygulanır ve her boyutta uzamsal özellikler çıkarılır. 1x1 evrişimli NE, DE sonucunda elde edilen özellik haritalarına uygulanır. NE, özellik haritasını kanallar arasında birleştirmek için kullanılır. Şekil 3'teki giriş görüntüsünün uzunluğu $W \times H \times D$ olsun. Burada W genişlik, H yükseklik ve D kanal sayısıdır. $K \times K \times D$ boyutunda 1 filtre olduğunu varsayalım. Standart evrişim işlemi yapıldığında $W \times H \times 1$ boyutunda çıktı alındığını varsayalım. Standart evrişim işleminin maliyeti Denklem 3'teki gibidir.

$$cost_{standart_convolution} = KxKxDxWxHx1 \quad (3)$$

Derinlemesine ayrılabilir evrişimde, önce derinlemesine evrişim işlemi uygulanır. Daha sonra noktasal evrişim işlemi uygulanır. 2B Derinlemesine ayrılabilir evrişim işleminin matematiksel gösterimi aşağıdaki gibidir.

$$cost_{depthwise_convolution} = KxKx1xWxHxD \quad (4)$$


$$cost_{standart_convolution} = KxKxDxWxHx1 \quad (5)$$

$$\frac{(cost_{depthwise_convolution} + cost_{pointwise_convolution})}{cost_{standart_convolution}} = \frac{KxKx1xWxHxD + WxHxD}{KxKxDxWxHx1} = 1 + \frac{1}{K^2} \quad (6)$$

3.3. Sıkma ve uyarma bloğu (SU)

Sıkma-uyarma bloğu (SU), ESA'lar için neredeyse hiçbir hesaplama maliyeti olmadan kanal bağımlılıklarını iyileştiren bir yapı sunmaktadır. SU bloğu, girdi olarak aldığı özellikleri yeniden kalibre ederek önemli olan özellik bilgilerini çıkartmaktadır [26]. SU bloğunu kullanmak, kanallar arasındaki karşılıklı bağımlılığı artırabilmekte ve hiperspektral görüntü sınıflandırmaları için yararlı olan özellik bilgilerini geliştirebilmektedir. SU bloğunun işlevi şu şekildedir: Öncelikle, SU bloğunun girişine bir özellik haritası ve sahip olduğu mevcut kanal sayısı verilmektedir. Ardından, Global Ortalama Havuzlama (Global Average Pooling) kullanılarak, her kanal tek bir sayısal değere dönüştürülmektedir (sıkma işlemi). Daha sonra uyarma işlemi, parametrelere göre her özellik kanalı için ağırlıklar oluşturmak için kullanılmaktadır. Parametreler, özellik kanalları arasındaki korelasyonu açıkça modellemek için

öğrenilmektedir. Modelin karmaşıklığını sınırlamak ve genelleştirmeyi kolaylaştırmak için ve kanallar arasındaki korelasyonları modellemek için bir darboğaz yapısı oluşturmak üzere iki tam bağlı katman (FC katmanı) kullanılmaktadır. Birinci FC katmanı özellik boyutunu küçültmek için kullanılır ve ilk FC'den sonra ikinci FC katmanında tekrar orijinal boyutuna yükseltilir. Doğrudan bir FC katmanı kullanmakla karşılaştırıldığında, bu yapı, kanallar arasındaki karmaşık korelasyona daha iyi uyum sağlayabilen daha fazla doğrusal olmayan özelliğe sahiptir. Ayrıca parametre ve hesaplama miktarını da azaltabilmektedir. Daha sonra, 0 ile 1 arasında normalize edilmiş ağırlıkları elde etmek için sigmoid fonksiyonu kullanılmaktadır. Son olarak, normalleştirilmiş ağırlıkları her bir kanalın özelliklerine göre ağırlıklandırmak için bir ölçekleme işlemi gerçekleştirilmektedir [27]. SU bloğunun bu işlemleri neredeyse hiçbir ek işlem maliyeti gerektirmez. Sınıflandırma görevlerinde performans artırıcı özelliğinden dolayı herhangi bir modele kolay bir şekilde eklenebilmektedir.



Şekil 3. 2B Derinlemesine ayrılabilir evrişim.

3.4. Veri setleri

Önerilen yöntemin performansını test etmek için literatürden HyRank-Loukia (HL) [28] ve Houston (UH) 2013 [29] veri setleri kullanılmıştır. HL veri seti, Hyperion Earth Observing-1 sensörü kullanılarak toplanan HyRANK veri setindeki görüntüyü temsil eder. Bu veri seti, 400–2500 nm'lik bir spektral kapsama ve 30 m'lik bir uzamsal çözünürlüğe sahiptir. Görüntü, 249 x 945 piksel boyutunda 176 yüzey yansıtma bandı sağlar. 14 çeşit arazi örtüsü sınıfı ve 13.503 örnek içermektedir. Houston Üniversitesi (UH) veri seti, 2012'de 2.5 metre uzamsal çözünürlüğe sahip Kompakt Hava Spektrografik Görüntüleyici tarafından elde edilmiştir. Veri seti 349 x 1905 boyutunda 144 banttan oluşmaktadır. 15 çeşit arazi örtüsü sınıfı ve 15.029 örnek içermektedir. HL ve UH veri setleri hakkında detaylı bilgiler Tablo 1'de gösterilmiştir.

Tablo 1. HyRank-Loukia ve Houston verisetlerindeki her sınıfın örneklerine ilişkin bilgiler.

		HyRank-Loukia (HL)		Houston 2013 (UH)	
Renk	No	Sınıf Adı	Örnek Sayısı	Sınıf Adı	Örnek Sayısı
	1	Yoğun kentsel yapı	288	Sağlam çim	1251
	2	Mineral çıkarım sahaları	67	Yıpranmış çim	1254
	3	Sulanmayan ekilebilir arazi	542	Sentetik çim	697
	4	Meyve ağaçları	79	Ağaç	1244
	5	Zeytinlikler	1401	Toprak	1242
	6	Geniş yapraklı orman	223	Su	325
	7	İğne yapraklı orman	500	Konut	1268
	8	Karışık orman	1072	Ticari Yapı	1244
	9	Yoğun sklerofil bitki örtüsü	3793	Yol	1252
	10	Seyrek sklerofil bitki örtüsü	2803	Otoyol	1227
	11	Seyrek bitki örtüsü olan alanlar	404	Demiryolu	1235
	12	Kayalar ve kum	487	Otopark 1	1233
	13	Su	1393	Otopark 2	469
	14	Kıyı suyu	451	Tenis kortu	428
	15			Koşu parkuru	660
Toplam örnek sayısı			13503		15029

3.5. Önerilen yöntem (ÖY)

Bu çalışmada, hiperspektral görüntü sınıflandırması için hibrit ESA ve sıkma-uyarma (SU) bloğundan oluşan yeni bir model önerilmiştir. Önerilen modelde, Şekil 4'te de gösterildiği gibi Hibrid ESA, 3B ESA ve 2B DAE katmanlarından oluşmaktadır. Bu çalışmanın ilk amacı, hiperspektral görüntü sınıflandırma için uzamsal-spektral özelliklerin eş zamanlı olarak çıkarılmasını sağlamaktır. 2B ESA ile sadece uzamsal özellikler çıkarılır. Bununla birlikte, hiperspektral görüntüler 3 boyutlu olduğundan, spektral özellikler oldukça önemlidir. Uzamsal özellikler ile birlikte spektral özellikleri de çıkarmak için 3B ESA yöntemi kullanıldı. Çalışma kapsamındaki bir diğer amaç ise, hesaplama maliyetini düşürmektir. Hesaplama maliyetinin düşürülmesi ise eğitilebilir parametre sayısının azaltılmasıyla mümkündür. DAE katmanları, hesaplama maliyetini ve eğitilebilir parametre sayısını azaltmak için kullanıldı. Hibrit bir yöntem kullanılmasının nedeni ise, sadece 3B ESA'nın kullanımı hesaplama maliyetini arttırmaktadır. DAE katmanları ve hibrit yöntem kullanılması hesaplama maliyetini azaltmaktadır. Ayrıca, özellik çıkarma ve hiperspektral görüntü sınıflandırmasındaki performansı arttırmak için Hibrit ESA modeli bir SU bloğu ile birleştirilmiştir. SU bloğu, toplam parametre sayısını minimum düzeyde arttırırken sınıflandırma performansını arttırdıkları için önerilen yönteme entegre edilmiştir.

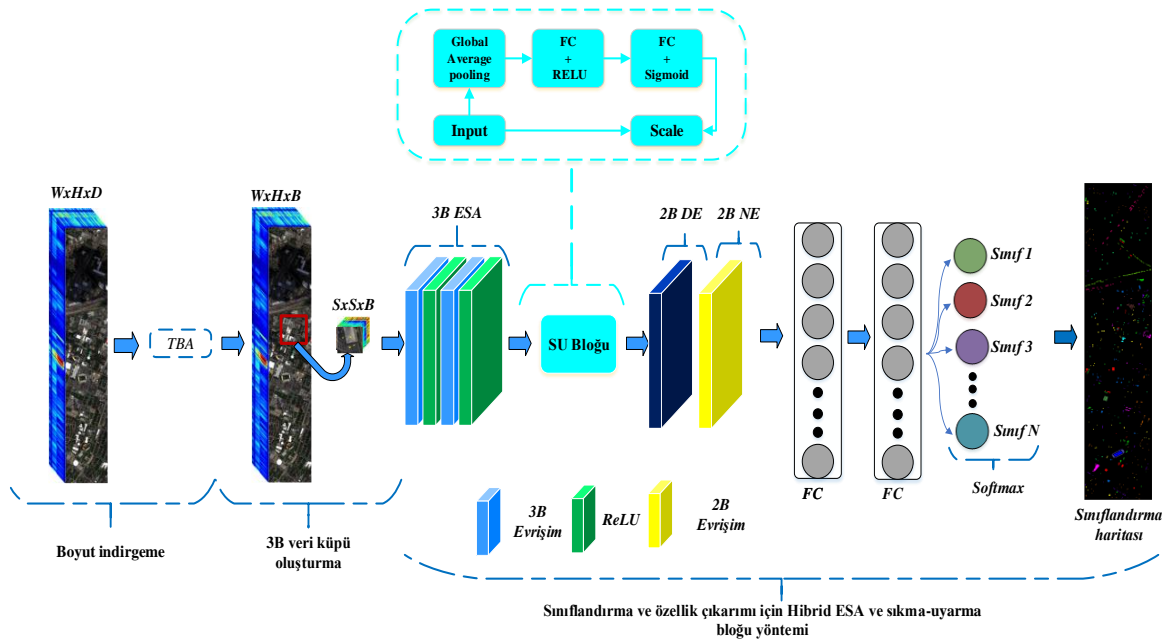
Hiperspektral görüntü, $W \times H \times D$ boyutunda bir 3B küp olarak belirtilmektedir. W ve H , görüntünün uzamsal genişliğini ve yüksekliğini ifade etmektedir. D , spektral bantların sayısını gösterir. Hiperspektral görüntü pikselleri, herhangi bir sınıflandırma modeli için kapsamlı çaba gerektiren sınıflar arası yüksek benzerlik, yüksek sınıf içi değişkenlik, örtüşen ve iç içe bölgeler sergiler. Bu sorunların üstesinden gelmek için spektral fazlalığı ortadan kaldırmak gerekir. Spektral bantlar boyunca geleneksel TBA, spektral fazlalığı ortadan kaldırmak için önce orijinal hiperspektral görüntüye uygulanır. TBA, aynı uzamsal boyutları (yani genişlik W ve yükseklik H) korurken spektral bant sayısını D 'den B 'ye azaltır. Bu şekilde, yalnızca spektral bantlar azaltıldı ve herhangi bir nesneyi tanımak için çok önemli olan uzamsal bilgiler korundu. TBA'dan sonra spektral bant fazlalığı azaltılıp, istenilen bant sayısına düşürülmüştür. TBA'dan sonra, hiperspektral veri küpü, görüntü sınıflandırma tekniklerini kullanmak için merkezi piksele dayalı gerçek etiketlerin üretildiği küçük örtüşen 3B uzamsal parçalara bölünmüştür. 3B parçalar, uzamsal konumda (a,b) merkezli ve $S \times S$ penceresini veya uzamsal boyutu ve tüm B spektral bantlarını kapsayan hiperspektral veri küpünden oluşturuldu. Oluşturulan 3B parçaların boyutu $S_x S_x B$ 'dir. Hiperspektral veri küpünden üretilen toplam 3B parça sayısı $(M-S+1) \times (N-S+1)$ ile bulunur.

Elde edilen 3B parçalara öncelikle ard arda 2 defa 3B evrişim uygulanmaktadır. Uygulanan 3B evrişimlerin filtre ve çekirdek boyutları şu şekildedir: Birinci 3B evrişimin çekirdek boyutu $3 \times 3 \times 3$ ve filtre sayısı 8'dir. İkinci 3B evrişimin çekirdek boyutu $1 \times 1 \times 1$ ve filtre sayısı 16'dır. Her bir 3B evrişimden sonra aktivasyon fonksiyonu olarak ReLU kullanılmaktadır. 3B evrişim işlemlerinden sonra 2B görüntü boyutunda yeniden boyutlandırma (reshape) işlemi yapılır. Elde edilen 2B görüntü öncelikle bir SU bloğundan geçirilir ve elde edilen çıktıya 2B DAE uygulanır. 2B DAE, DE ve NE katmanlarından oluşmaktadır. DE katmanı 3×3 çekirdek boyutuna ve NE katmanı 1×1 çekirdek boyutuna sahiptir. En son işlemekten sonra, çıkarılan öznitelikler düzleştirilir ve hiperspektral görüntü

sınıflandırma için tam bağlı (FC) katmanlara girdi olarak verilir. Önerilen hibrit yöntemde, 128 ve 256 nöronlu iki FC katmanı kullanılır. Aşırı öğrenmeyi önlemek için her FC katmanından sonra 0.4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanır. FC katmanının çıktısı, sınıflandırma sonucunu oluşturmak için basit softmax sınıflandırıcıya verilir. HyRank-Loukia (HL) veri seti kullanılarak önerilen yöntem ile ilgili ayrıntılı bilgiler Tablo 2’de yer almaktadır. Tablo 2’ye bakıldığında, HL veri seti için önerilen yöntemdeki eğitilebilir parametre sayısının 1.409.855 olduğu görülmektedir.

Tablo 2. HL veri seti kullanılarak önerilen yöntem ile ilgili ayrıntılı bilgiler.

Katman	Çıktı	Parametre sayısı
Girdi	(11,11,20,1)	0
3B evrişim_1	(11,11,20,8)	224
3B evrişim_2	(11,11,20,16)	144
Yeniden boyutlandırma (reshape)	(11,11,320)	0
2B Global Ortalama havuzlama	320	0
FC	0	0
FC	1	1
tf.reshape	(1,1,1)	0
multiply	(11,11,320)	0
2B Derinlemesine evrişim	(9,9,640)	6400
2B evrişim (NE)	(9,9,64)	41024
Düzleştirme katmanı	(5184)	0
FC	256	1327360
Bırakma katmanı	256	0
FC	128	32896
Bırakma katmanı	128	0
Çıktı katmanı	14	1806
Toplam Eğitilebilir Parametre sayısı		1.409.855



Şekil 4. Hiperspektral görüntü sınıflandırması için önerilen yöntem.

4. Uygulamalar ve uygulama sonuçları

İki veri seti kullanılarak gerçekleştirilen uygulamalar python programlama dilinde yazılmıştır. Uygulamalarda Google Colab kullanılmıştır. Ayrıca donanım hızlandırıcı olarak Tensor işleme birimi kullanıldı. Tensör işleme birimleri, Colab'da python kodlarını çalıştırmak için 107.77 GB depolama ve 35 GB RAM sağlamaktadır. Tüm verisetleri için eğitim-test oranı %10-90 alınmıştır. Ayrıca, öğrenme oranı 0.001 olarak alınmış ve optimize edici olarak Adam kullanılmıştır. Eğitim süreci 256 batch size ve 100 epoch'ta gerçekleştirilmiştir. Her iki veri setinde elde edilen 3 boyutlu veri küpünün genişlik ve yüksekliği 11x11 (S=11) olarak alınmıştır. WxHxD boyutunda hiperspektral görüntüye TBA uygulandıktan sonra spektral bant sayısı azalır ve yeni oluşturulan görüntü WxHxB boyutunda olur. Uygulamalar kapsamında her iki veri seti için B=20 alınmıştır. Karşılaştırma için kullanılan tüm derin öğrenmeye dayalı yöntemlere girdi görüntü verileri olarak verilen 3B parça boyutları, her iki veri seti için 11x11x20'dir (SxSxB). Ortalama doğruluk (OD), Genel doğruluk (GD) ve Kappa (K) katsayısı değerlendirme metrikleri, önerilen yöntemin iki veri setindeki sınıflandırma doğruluğunu analiz etmek için kullanıldı. OD, sınıf bazlı sınıflandırma doğruluğuna göre hesaplanır. GD, doğru sınıflandırılmış örnek sayısının tüm test örneklerinin sayısına oranıyla belirlenir. K, tahmin sonucunda elde edilen sınıflandırma haritası ile yer gerçeği (ground truth) haritası arasındaki tutarlılığı değerlendirebilen istatistiksel bir metriktir.

Önerilen yöntem, S3EResBoF [1], HybridSN [12], FC3B ESA [13], FuSENet [14], DLEM [15], 3B ESA [30], 2B ESA [31] gibi son yıllarda üzerinde çalışılan 7 farklı derin öğrenmeye dayalı yöntemle karşılaştırılmıştır.

HL veri seti kullanılarak gerçekleştirilen uygulamalarda elde edilen GD, OD, K değerlendirme metrikleri ile her sınıfın sınıf bazlı sınıflandırma sonuçları Tablo 3'te verilmiştir. Tablo 3 incelendiğinde, önerilen yöntem ile elde edilen GD, K ve OD sonuçları sırasıyla %90.86, %89.13 ve %84.39 olarak bulunmuştur. Diğer tüm yöntemler ile karşılaştırıldığında en yüksek sınıflandırma sonuçlarının önerilen yöntem ile elde edildiği görülmektedir. Önerilen yöntemle en yakın sınıflandırma sonuçları %84.83 GD, %81.92 K ve %77.91 OD ile DLEM yönteminde elde edilmiştir. En düşük sınıflandırma doğruluk değerleri ise, %73.55 GD, %68.18 K ve %55.28 OD ile FC3B ESA yönteminde elde edilmiştir. Sınıf bazlı sınıflandırma doğrulukları incelendiğinde, 3, 4, 6, 8, 9, 10 ve 11 nolu sınıflarda sırasıyla %89.96, %50.70, %53.73, %92.23, %88.87, %93.02 ve %88.15 ile en iyi sınıflandırma sonuçlarının önerilen yöntem ile elde edildiği görülmektedir. 1 nolu sınıf için %83.45 ile en iyi sınıflandırma sonucu S3EResBof yönteminde elde edilmiştir. 2 nolu sınıf için %100 ile DLEM, FuSENet ve S3EResBoF yöntemlerinde en iyi sınıflandırma sonuçları elde edilirken, 7 ve 12 nolu sınıflarda ise %88.31 ve %95.27 ile FuSENet'te en iyi sonuçlar bulunmuştur. 5 nolu sınıf için %97.07 ile DLEM yönteminde en iyi sonuç elde edilmiştir. 13 nolu sınıf için %100 ile ÖY, DLEM, HybridSN, FC3B ESA, 2B ESA yöntemleri ile en iyi sınıflandırma doğruluk sonucu elde edilirken, 14 nolu sınıf için yine %100 ile ÖY, DLEM, HybridSN, FC3B ESA, 3B ESA yöntemlerinde en iyi sınıflandırma doğruluk sonucu bulunmuştur. Tüm yöntemler için elde edilen sınıflandırma haritaları Şekil 5'te verilmiştir. Tüm yöntemlerin OD sonuçları dikkate alındığında en iyi OD sonucunun önerilen yöntem ile en kötü OD sonucunun ise FC3B ESA ile elde edildiği görülmüştür. OD sonuçlarından yola çıkarak, ground truth'a en yakın yöntemin, önerilen yöntem ile elde edilen sınıflandırma haritası olduğu söylenebilmektedir.

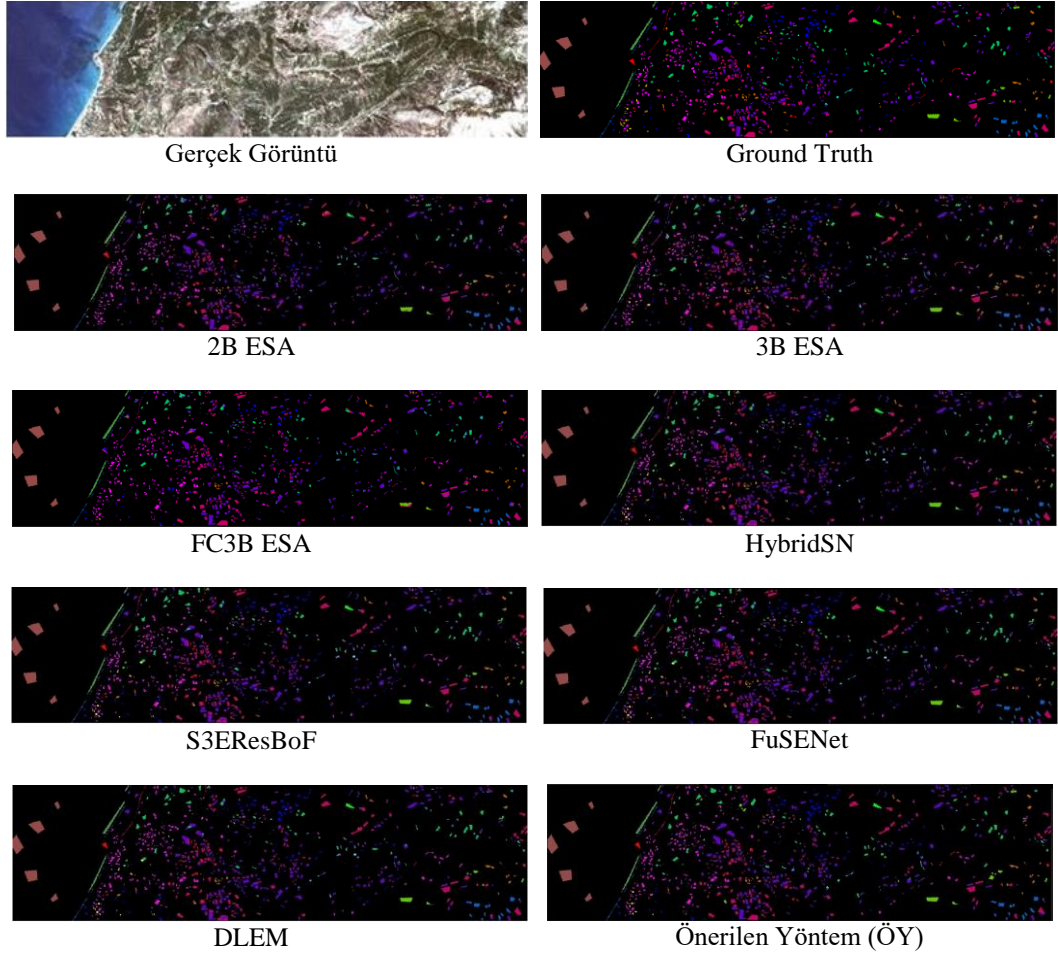
UH veri seti kullanılarak gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğruluk değerleri Tablo 4'te verilmiştir. Tablo 4 incelendiğinde, önerilen yöntem ile %99.39 GD, %99.34 K ve %99.42 OD değeri elde edilmiştir. Karşılaştırma için kullanılan diğer tüm yöntemler incelendiğinde tüm metriklerde en iyi sınıflandırma doğruluklarının önerilen yöntem ile elde edildiği görülmektedir. Önerilen yöntemle en yakın sınıflandırma doğruluk değerleri %98.10 GD, %97.95 K ve %98.25 OD ile DLEM yönteminde elde edilmiştir. Tüm yöntemler arasında en kötü sınıflandırma sonuçları ise %89.54 GD, %88.68 K ve %88.94 OD ile FC3B ESA yönteminde bulunmuştur. Sınıf bazlı sınıflandırma sonuçları incelendiğinde, 1, 11 ve 13 nolu sınıflarda %98.40, %99.73, %97.87 ile ÖY'de en iyi sınıflandırma doğruluk sonuçları elde edilmiştir. 2, 7, 8, 9 ve 12 nolu sınıflarda sırasıyla %100, %98.34, %99.79, %100 ve %99.81 ile FuSENet'te en iyi sonuçlar bulunmuştur. 3 nolu sınıfta %100 ile FuSENet ve ÖY, 4 nolu sınıfta %100 ile DLEM, 5 nolu sınıfta %100 ile ÖY, DLEM, FuSENet, S3EResBof, HybridSN, 6 nolu sınıfta %100 ile ÖY, DLEM, FuSENet, 10 sınıfta %100 ile ÖY, DLEM yöntemleri ile en iyi sınıflandırma doğruluk sonuçları elde edilmiştir. 14 nolu sınıf için DLEM, ÖY ve HybridSN yöntemleri ile %100 sınıflandırma doğruluğu elde edilirken, 15 nolu sınıf için %100 ile ÖY, DLEM, HybridSN ve 3B ESA yöntemlerinde en iyi sonuçlar bulunmuştur. Önerilen yöntem ile 1, 3, 5, 6, 10, 11, 13, 14 ve 15 nolu sınıflarda en iyi sınıflandırma doğruluğu elde edilirken, diğer sınıflarda da en iyi sınıflandırma sonucunun elde edildiği yöntemle oldukça yakın sonuçların elde edildiği görülmektedir. Tüm yöntemler için elde edilen sınıflandırma haritaları Şekil 6'da verilmiştir. Tüm yöntemlerin OD değerleri incelendiğinde en iyi değer önerilen yöntem ile elde edildiği görülmektedir. Bu değerden yola çıkarak, ground truth değerine en yakın sınıflandırma haritasının önerilen yöntem ile elde edildiği sonucu çıkarılabilmektedir.

Tablo 3. HL veri seti kullanılarak elde edilen sınıflandırma doğruluk değerleri (%).

No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	FuSENet	DLEM	ÖY
1	29/259	43.73	39.78	11.68	65.69	83.45	79.34	73.36	79.92
2	7/60	49.23	83.08	29.69	96.87	100.00	100.00	100.00	83.33
3	54/488	70.15	68.44	67.96	86.02	88.27	68.49	86.41	89.96
4	8/71	1.30	15.58	4.00	46.67	48.14	38.77	26.67	50.70
5	140/1261	88.96	92.42	88.13	89.63	77.46	82.82	97.07	96.83
6	22/201	7.87	29.63	4.24	28.77	46.90	73.27	29.72	53.73
7	50/450	45.36	59.59	46.31	64.42	83.62	88.31	62.74	70.44
8	107/965	57.88	54.90	67.39	78.09	72.71	65.06	84.38	92.23
9	379/3414	80.97	70.97	74.13	80.07	80.99	85.27	81.54	88.87
10	280/2523	72.89	80.21	77.81	79.76	64.15	77.58	84.30	93.02
11	41/363	50.00	52.04	32.29	66.14	77.78	48.09	69.79	88.15
12	49/438	80.93	85.38	70.41	94.17	90.54	95.27	94.82	94.29
13	139/1254	100.00	98.67	100.00	100.00	99.91	99.58	100.00	100.00
14	45/406	99.77	100.00	100.00	100.00	99.08	99.49	100.00	100.00
GD	1350	75.57	75.48	73.55	82.04	77.46	80.65	84.83	90.86
K	/	70.57	70.79	68.18	78.61	73.10	77.28	81.92	89.13
OD	12153	60.64	66.48	55.28	76.88	79.50	78.67	77.91	84.39

Tablo 4. UH veri seti kullanılarak elde edilen sınıflandırma doğruluk değerleri (%).

No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	FuSENet	DLEM	ÖY
1	125/1126	94.07	92.17	92.93	97.05	97.93	98.12	97.22	98.40
2	125/1129	99.59	98.44	97.73	99.92	99.24	100.00	99.92	99.91
3	70/627	95.41	99.26	95.62	99.70	99.66	100.00	99.70	100.00
4	124/1120	99.01	94.95	93.15	99.58	97.64	97.65	100.00	99.73
5	124/1118	99.67	99.75	99.58	100.00	100.00	100.00	100.00	100.00
6	33/292	86.98	85.08	85.44	99.68	99.63	100.00	100.00	100.00
7	127/1141	94.06	90.73	92.45	94.77	97.69	98.34	97.26	97.19
8	124/1120	90.14	73.24	90.27	97.46	99.48	99.79	96.70	99.20
9	125/1127	90.62	92.92	60.97	86.54	98.43	100.00	91.08	99.82
10	123/1104	93.36	94.45	91.25	99.40	98.87	93.09	100.00	100.00
11	123/1112	90.15	97.41	87.98	94.63	95.28	98.86	99.49	99.73
12	123/1110	94.23	96.32	90.35	96.16	97.68	99.81	97.61	99.55
13	47/422	54.06	66.15	58.52	93.50	95.42	89.93	94.84	97.87
14	43/385	69.40	92.05	99.26	100.00	86.99	95.00	100.00	100.00
15	66/594	97.81	100.00	98.56	100.00	99.46	93.91	100.00	100.00
GD	1502	92.54	92.58	89.54	96.91	97.89	98.00	98.10	99.39
K	/	91.92	91.97	88.68	96.66	97.72	97.83	97.95	99.34
OD	13527	89.90	91.52	88.94	97.23	97.55	97.63	98.25	99.42




Şekil 5. HL veri seti kullanılarak elde edilen sınıflandırma haritaları.

5. Sonuçlar

Bu çalışma, hiperspektral görüntü sınıflandırması için yeni bir derin özellik çıkarma yöntemi geliştirmeyi amaçlamaktadır. Bu amaçla 3B ESA, Sıkma-uyarma bloğu ve 2B DAE'den oluşan bir yöntem önerilmiştir. 2B ESA ile sadece uzamsal özellik bilgileri çıkarılmaktadır. Hiperspektral görüntüler 3B olduğundan dolayı uzamsal özellik bilgilerinin yanısıra spektral özellik bilgilerinin de elde edilmesi sınıflandırma açısından oldukça önemlidir. Bu doğrultuda, 3B ESA, hem spektral hem de uzamsal özellikleri aynı anda çıkarmak için kullanıldı. Ancak, yalnızca 3B ESA kullanmak, hesaplama karmaşıklığını arttırmaktadır. 2B ESA ve 3B ESA kullanılarak elde edilen hibrit yöntemler ile hesaplama karmaşıklığının önüne geçilmekte ve eş zamanlı olarak daha fazla uzamsal özellik çıkarılmaktadır. Ancak bu çalışma kapsamında 2B ESA'daki 2B evrişim katmanları, 2B DAE katmanları ile değiştirilmiştir. DAE katmanlarının kullanımı ile eğitilebilir parametre sayısı azaltılmıştır. Eğitilebilir parametre sayısının azaltılması ile hesaplama maliyeti de düşürülmüştür. Son olarak, bu çalışmada öznelik çıkarma ve hiperspektral görüntü sınıflandırmasındaki performansını arttırmak amacıyla geliştirilen Hibrit ESA yöntemine bir sıkma-uyarma bloğu eklenmiştir. Sıkma-uyarma bloğunun neredeyse hiçbir ek işlem maliyeti gerektirmez. Sınıflandırma görevlerinde performans artırıcı özelliğinden dolayı herhangi bir modele kolay bir şekilde eklenebilmektedir. Önerilen yöntemin sınıflandırma performansını analiz etmek için uygulamalarda HyRank-Loukia ve Houston 2013 veri setleri kullanılmıştır. Her iki veri seti ile gerçekleştirilen uygulamalarda %10 eğitim örneği alınmıştır. %10 eğitim örneğinin alınmasının nedeni, düşük eğitim örneğinde önerilen yöntemin performansını test etmektir. HyRank-Loukia veri seti ile gerçekleştirilen uygulamalar sonucunda %90.86 genel doğruluk, %89.13 kappa ve %84.39 ortalama doğruluk sonucu elde edilirken, Houston 2013 veri setinde önerilen yöntem ile %99.39 genel doğruluk, %99.34 kappa ve %99.42 ortalama doğruluk sonuçları elde edilmiştir. Ayrıca önerilen yöntem, literatürden alınan 2B ESA, 3B ESA, FC 3B ESA, HybridSN, S3EResBoF, FuSENet ve DLEM

yöntemleriyle karşılaştırılmıştır. HyRank-Loukia ile gerçekleştirilen uygulamalarda önerilen yöntem dışındaki diğer yöntemler ile sırasıyla %75.57, %75.48, %73.55, %82.04, %77.46, %80.65 ve %84.83 genel doğruluk sonucu elde edilmiştir. Yine aynı veri seti kullanılarak önerilen yöntem dışındaki diğer yöntemler ile sırasıyla %70.57, %70.79, %68.18, %78.61, %73.10, %77.28, %81.92 kappa ve %60.64, %66.48, %55.28, %76.88, %79.50, %78.67, %77.91 ortalama doğruluk değerleri elde edilmiştir. Houston 2013 ile önerilen yöntem dışındaki diğer yöntemler ile sırasıyla %92.74, %92.58, %89.54, %96.91, %97.89, %98, %98.10 genel doğruluk, %91.92, %91.97, %88.68, %96.66, %97.72, %97.83, %97.95 kappa ve %89.90, %91.52, %88.94, %97.23, %97.55, %97.63, %98.25 ortalama doğruluk değerleri bulunmuştur. Önerilen yöntem, her iki veri setinde de tüm değerlendirme ölçümleri için karşılaştırılan yöntemlerden daha iyi performans gösterdiği görülmektedir. Sınıflandırma sonuçları, önerilen yöntemin gerçek dünya uygulamalarında kullanılabilceğini göstermektedir.



Şekil 6. UH veri seti kullanılarak elde edilen sınıflandırma haritaları.

Kaynaklar

- [1] Roy SK, Chatterjee S, Bhattacharyya S, Chaudhuri BB, and Platos J. Lightweight Spectral-Spatial Squeeze-and-Excitation Residual Bag-of-Features Learning for Hyperspectral Classification. *IEEE Trans. Geosci. Remote Sens.* 2020; 58(8): 5277–5290. doi: 10.1109/TGRS.2019.2961681
- [2] Wang A, Liu C, Xue D, Wu H, Zhang Y, and Liu M. Depthwise separable relation network for small sample hyperspectral image classification. *Symmetry (Basel)* 2021; 13(9):1673. doi: 10.3390/sym13091673.
- [3] Firat H and Hanbay D. Classification of hyperspectral images using 3D CNN based ResNet50. *SIU 2021 - 29th IEEE Conf. Signal Process. Commun. Appl. Proc.*, 2021:6–9. doi: 10.1109/SIU53274.2021.9477899.
- [4] Ahmad M, Mazzara M, and Distefano S. Regularized cnn feature hierarchy for hyperspectral image classification. *Remote Sens* 2021;13(12):1–11. doi: 10.3390/rs13122275.
- [5] Firat H, Asker ME, and Hanbay D. Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN. *Remote Sens. Appl. Soc. Environ* 2022:100694. doi: 10.1016/j.rsase.2022.100694.
- [6] Mohan A and Meenakshi Sundaram V. V3O2: hybrid deep learning model for hyperspectral image classification using vanilla-3D and octave-2D convolution. *J. Real-Time Image Process* 2020:0123456789. doi: 10.1007/s11554-020-00966-z.
- [7] Wang Y, Yu W, and Fang Z. Multiple Kernel-based SVM classification of hyperspectral images by combining spectral, spatial, and semantic information. *Remote Sens* 2020;12(1). doi: 10.3390/RS12010120.
- [8] Li J, Bioucas-Dias JM, and Plaza A. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning. *IEEE Trans. Geosci. Remote Sens* 2010:48(11):4085–4098. doi: 10.1109/TGRS.2010.2060550.
- [9] Ahmad M et al., Spatial prior fuzziness pool-based interactive classification of hyperspectral images. *Remote Sens* 2019;11(9):1–19. doi: 10.3390/rs11091136.
- [10] Firat H, Emin M, Mehmet IB, and HanbayD. Hybrid 3D / 2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. *Neural Process. Lett* 2022:1–44. doi: 10.1007/s11063-022-10929-z.
- [11] Uzen H, Turkoglu M, and Hanbay D. Texture defect classification with multiple pooling and filter ensemble based on deep neural network. *Expert Syst. Appl* 2021;175:114838. doi: 10.1016/j.eswa.2021.114838.
- [12] Roy SK, Krishna, G Dubey SR, and Chaudhuri BB. HybridSN: Exploring 3D-2D CNN Feature Hierarchy for Hyperspectral Image Classification. *arXiv* 2019;17(2):277–281, 2019.
- [13] Ahmad M, Khan A, Mazzara M, Distefano S, Ali M, and Sarfraz MS. A Fast and Compact 3-D CNN for Hyperspectral Image Classification. *IEEE Geosci. Remote Sens. Lett* 2020:1–5. doi: 10.1109/LGRS.2020.3043710.
- [14] Roy SK, Dubey SR, Chatterjee S, and Chaudhuri BB, FuSENet: Fused squeeze-and-excitation network for spectral-spatial hyperspectral image classification. *IET Image Process* 2020; 14(8):1653–1661. doi: 10.1049/iet-ipr.2019.1462.
- [15] Iyer P, S. A, and Lal S. Deep learning ensemble method for classification of satellite hyperspectral images. *Remote Sens. Appl. Soc. Environ* 2021;23:100580. doi: 10.1016/j.rsase.2021.100580.
- [16] Yang X et al. Synergistic 2D/3D convolutional neural network for hyperspectral image classification. *Remote Sens* 2020; 12(12):1–19. doi: 10.3390/rs12122033.
- [17] Firat H, Asker ME, Bayindir Mİ, and Hanbay D. 3D residual spatial–spectral convolution network for hyperspectral remote sensing image classification. *Neural Comput. Appl* 2022;8. doi: 10.1007/s00521-022-07933-8.
- [18] Ari A Multipath feature fusion for hyperspectral image classification based on hybrid 3D/2D CNN and squeeze-excitation network. *Earth Sci. Informatics* 2023: 0123456789. doi: 10.1007/s12145-022-00929-x.
- [19] Ding Y et al. Multi-feature fusion: Graph neural network and CNN combining for hyperspectral image classification. *Neurocomputing* 2022; 501:246–257. doi: 10.1016/j.neucom.2022.06.031.
- [20] Hong D et al. SpectralFormer: Rethinking Hyperspectral Image Classification with Transformers. *IEEE Trans. Geosci. Remote Sens* 2022; 60. doi: 10.1109/TGRS.2021.3130716.
- [21] Ge Z, Cao G, Li X, and Fu P. Hyperspectral Image Classification Method Based on 2D-3D CNN and Multibranch Feature Fusion. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens* 2020;13:5776–5788. doi: 10.1109/JSTARS.2020.3024841.

- [22] Ghaderizadeh S, Abbasi-Moghadam D, Sharifi A, Zhao N, and Tariq A. Hyperspectral Image Classification Using a Hybrid 3D-2D Convolutional Neural Networks. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens* 2021; 14:7570–7588. doi: 10.1109/JSTARS.2021.3099118.
- [23] Türkoğlu M, Hanbay K, Sivrikaya IS, and Hanbay D. Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *BEÜ Fen Bilim. Derg* 2020;9(1):334–345.
- [24] Üzen H, Turkoglu M, Aslan M, and Hanbay D. Depth-wise Squeeze and Excitation Block-based Efficient-Unet model for surface defect detection. *Vis. Comput* 2022. doi: 10.1007/s00371-022-02442-0.
- [25] Fırat H, Asker ME, and Hanbay D. Hybrid 3D Convolution and 2D Depthwise Separable Convolution Neural Network for Hyperspectral Image Classification *Balk. J. Electr. Comput. Eng* 2022;10(1):35–46. doi: 10.17694/bajece.1039029.
- [26] Hu J, Shen L, and Sun G. Squeeze-and-Excitation Networks. *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit* 2018; 7132–7141. doi: 10.1109/CVPR.2018.00745.
- [27] Li G, Zhang G, Lei R, Zhang X, Ye Z, and Li X. Hyperspectral remote sensing image classification using three-dimensional-squeeze-and-excitation-DenseNet (3D-SE-DenseNet). *Remote Sens. Lett* 2020; 11(2):195–203. doi: 10.1080/2150704X.2019.1697001.
- [28] Evaluation Q and Aeronautics N. HyRANK : THE NEW ISPRS HYPERSPECTRAL BENCHMARK. 2018.
- [29] 2013 IEEE GRSS Data Fusion Contest – Fusion of Hyperspectral and LiDAR Data. https://hyperspectral.ee.uh.edu/?page_id=459.
- [30] Ben Hamida A, Benoit A, Lambert P, and Ben Amar C. 3-D deep learning approach for remote sensing image classification. *IEEE Trans. Geosci. Remote Sens* 2018; 56(8):4420–4434. doi: 10.1109/TGRS.2018.2818945.
- [31] Makantasis K, Karantzalos K, Doulamis A, and Doulamis N. Deep supervised learning for hyperspectral data classification through convolutional neural networks. *Int. Geosci. Remote Sens. Symp* 2015; 4959–4962. doi: 10.1109/IGARSS.2015.7326945.