



## Comparison of 3D CNN based deep learning architectures using hyperspectral images

Hüseyin Fırat<sup>1\*</sup> , Davut Hanbay<sup>2</sup> 

<sup>1</sup>Dicle University, Vocational School of Technical Sciences, Department of Computer Technologies, 21200 Sur Diyarbakir, Türkiye

<sup>2</sup>Department of Computer Engineering, Faculty of Engineering, Inonu University, 44280, Malatya, Türkiye

### Highlights:

- Use of LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 in hyperspectral image classification
- Simultaneously spectral-spatial feature extraction using 3D CNN
- Use of Indian pines, Salinas, Botswana and HyRANK-Loukia datasets

### Keywords:

- Hyperspectral image classification
- Deep learning
- 3D convolutional neural network
- principal component analysis

### Graphical/Tabular Abstract

With deep learning methods, features are extracted automatically in Hyperspectral image classification (HSI). Especially, Convolutional neural network (CNN) based methods are getting more attention in this field. In this study, LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 deep learning architectures, which are among the successful examples of CNN, are used for the HSI classification problem. A 3D CNN-based approach is proposed when using these architectures. The architecture of the proposed method is presented in Figure A.

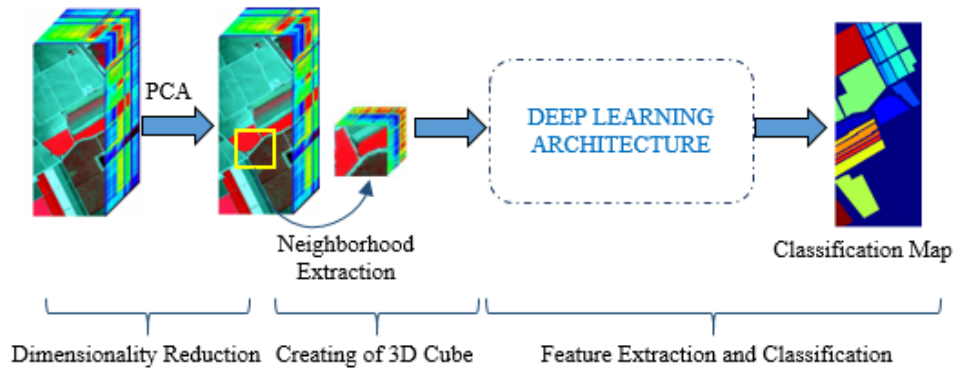


Figure A. Framework for hyperspectral image classification

### Article Info:

Research Article

Received: 02.08.2021

Accepted: 16.02.2022

### DOI:

10.17341/gazimmfd.977688

### Correspondence:

Author: Hüseyin Fırat

e-mail:

huseyin.firat@dicle.edu.tr

phone: +90 412 241 1000 / 7751

### Purpose:

In this study, it is aimed to compare the classification performances of 3D CNN based LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 deep learning architectures for classification of hyperspectral images.

### Theory and Methods:

In this study, classification performances of 3D CNN based LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 deep learning architectures were compared for classification of hyperspectral images. 3D CNN extracts spectral and spatial features from hyperspectral images simultaneously to achieve better classification accuracy. The proposed deep learning framework chooses the neighborhood block as the input of the network model. PCA is applied on the hyperspectral image cube as a pre-processing step to remove the spectral band redundancy. Then, the hyperspectral cube is divided into small overlapping 3D patches. Classification maps are obtained by giving 3D patches to the input of deep learning architectures.

### Results:

Applications were conducted on Indian pines, Salinas, Botswana and HyRANK-Loukia datasets to evaluate the performance of 3D CNN based LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 deep learning architectures. In the implemented applications, overall accuracy (OA), average accuracy (AA) and kappa (K) evaluation metrics are used. The best classification accuracies were obtained in LeNet5 and VGG16 with 100% using the Salinas dataset, in VGG16 with 98.86%, 97.92% and 98.65%, respectively, using the HyRANK-Loukia dataset, in ResNet50 with 100% using the Botswana dataset, and in VGG16 with 99.77%, 99.77% and 99.74%, respectively, using the Indian pines dataset.

### Conclusion:

As a result of the performed applications, the best classification accuracy was obtained with VGG16 in Indian pines, ResNet50 in Botswana, VGG16 in HyRANK-Loukia, LeNet5 and VGG16 in Salinas.



## Hiperspektral görüntüler kullanılarak 3B ESA tabanlı derin öğrenme mimarilerinin karşılaştırılması

Hüseyin Fırat<sup>1\*</sup>, Davut Hanbay<sup>2</sup>

<sup>1</sup>Dicle Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, 21200 Sur Diyarbakır, Türkiye

<sup>2</sup>İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 44280, Malatya, Türkiye

### ÖNEÇIKANLAR

- Hiperspektral görüntü sınıflandırmada LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 kullanımı
- 3B ESA kullanılarak eş zamanlı olarak spektral-uzamsal özellik çıkarımı
- Indian pines, Salinas, Botswana, HyRANK-Loukia verisetlerinin kullanımı

### Makale Bilgileri

Araştırma Makalesi  
Geliş: 02.08.2021  
Kabul: 16.02.2022

### DOI:

10.17341/gazimmfd.977688

### Anahtar Kelimeler:

Hiperspektral görüntü sınıflandırma, derin öğrenme, 3B evrişimli sinir ağı, temel bileşen analizi

### ÖZ

Hiperspektral görüntüler (HG), iki uzamsal ve bir spektral boyuta sahip 3 boyutlu (3B) görüntü küpleridir. Derin öğrenme yöntemlerinin gelişimi, HG sınıflandırmada önemli bir etki oluşturmuştur. Özellikle evrişimsel sinir ağı (ESA) tabanlı yöntemler bu alanda daha fazla ilgi görmektedir. Bu çalışmada, HG sınıflandırma problemi için ESA'nın başarılı örnekleri arasında olan LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 derin öğrenme mimarilerinden yararlanıyoruz. Bu mimarileri kullanırken 3B ESA tabanlı hibrit bir yaklaşım kullanılmaktadır. Çünkü, 3B ESA kullanılarak, spektral-uzamsal özellikler eş zamanlı olarak çıkarılmaktadır. Bu durumda elde edilen spektral-uzamsal tabanlı derin öğrenme mimarisi ile HG'lerin sınıflandırma doğruluğu arttırılmaktadır. Bununla birlikte, önerilen modelde, HG'lerden optimal bant çıkarımı için bir ön işleme tekniği olarak temel bileşen analizi (TBA) kullanılmaktadır. TBA uygulandıktan sonra komşuluk çıkarımı ile 3B küpler elde edilmekte ve derin öğrenme mimarilerinin girişine verilmektedir. 3B ESA tabanlı derin öğrenme mimarilerinin sınıflandırma performanslarını karşılaştırmak için Indian pines, Salinas, Botswana ve HyRANK-Loukia verisetleri kullanılmıştır. Gerçekleştirilen uygulamalar sonucunda, en iyi sınıflandırma doğruluğu Indian pines verisetinde VGG16, Botswana verisetinde ResNet50, HyRANK-Loukia verisetinde VGG16, Salinas verisetinde LeNet5 ve VGG16 mimarileri ile elde edilmiştir.

## Comparison of 3D CNN based deep learning architectures using hyperspectral images

### HIGHLIGHTS

- Use of LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 in hyperspectral image classification
- Simultaneously spectral-spatial feature extraction using 3D CNN
- Use of Indian pines, Salinas, Botswana, HyRANK-Loukia datasets

### Article Info

Research Article  
Received: 02.08.2021  
Accepted: 16.02.2022

### DOI:

10.17341/gazimmfd.977688

### Keywords:

Hyperspectral image classification, deep learning, 3D convolutional neural network, principal component analysis

### ABSTRACT

Hyperspectral images (HSI) are 3-dimensional (3D) image cubes with two spatial and one spectral dimensions. The development of deep learning methods has had a significant impact on HSI classification. Especially convolutional neural network (CNN) based methods are getting more attention in this field. In this study, we make use of the deep learning architectures LeNet5, AlexNet, VGG16, GoogleNet and ResNet50, which are among the successful examples of CNN for the HSI classification problem. We use a 3D CNN-based hybrid approach when using these architectures. Because, using 3D CNN, spectral-spatial features are extracted simultaneously. In this case, the classification accuracy of HSIs is increased with the spectral-spatial-based deep learning architecture. However, in the proposed model, principal component analysis (PCA) is used as a preprocessing technique for optimal band extraction from HSIs. After applying PCA, 3D cubes are obtained by neighborhood extraction and given to the input of deep learning architectures. Indian pines, Salinas, Botswana and HyRANK-Loukia datasets were used to compare the classification performances of 3D CNN-based deep learning architectures. As a result of the applications, the best classification accuracy was obtained with VGG16 architectures in Indian pines dataset, ResNet50 in Botswana dataset, VGG16 in HyRANK-Loukia dataset, LeNet5 and VGG16 architectures in Salinas dataset.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*huseyin.firat@dicle.edu.tr, davut.hanbay@inonu.edu.tr /  
Tel: +90 412 241 1000 / 7751

## 1. Giriş (Introduction)

Hiperspektral görüntüler (HG) genellikle görünürden kızılötesi spektruma kadar uzanan yüzlerce spektral bant hakkında bilgi içermektedir. HG'lerdeki her piksel, girişleri belirli bir dalga boyundaki spektral yansımaya karşılık gelen yüksek boyutlu bir vektördür ve ilgilenilen arazi örtülerini ayırt etmek için zengin spektral bilgiler sağlamaktadır [1]. Son zamanlarda, her pikselin arazi örtüsü türünü belirlemek amacıyla HG sınıflandırması, uzaktan algılama topluluğundaki en aktif araştırma alanlarından biri haline gelmiştir, çünkü çevresel izleme, hassas tarım, madencilik, askeri gözetim ve nesne takibi gibi çok çeşitli dünya izleme uygulamalarında önemli bir adımdır [2]. Ancak HG'lerin çok sayıda spektral bant içermesi ve yüksek boyutlara sahip olması sınıflandırma işlemlerinde karşılaşılan en önemli sorunlardan biridir. Boyut indirgeme yöntemleri kullanılarak HG'lerin boyutları küçültülebilmektedir. Boyut indirgeme yöntemi, önerilen yöntemin sınıflandırma performansını düşüren gereksiz spektral özellik bilgilerinin ortadan kaldırılmasını sağladığı için hiperspektral görüntü analizinde oldukça önemli bir süreçtir. Boyut indirgeme, HG sınıflandırmasında iki farklı şekilde gerçekleştirilebilir: spektral bant seçimi ve spektral bant çıkarımı. Spektral bant seçiminde, orijinal HG spektral bandından seçilen en kullanışlı spektral bantlar üzerinde analiz yapılmaktadır. Spektral bant çıkarımında, yüksek spektral boyuta sahip HG verilerinin spektral boyutu azaltılmaktadır [3]. Ancak, spektral boyutu azalan HG verilerinin uzamsal boyutu değişmez. Boyut indirgeme için en iyi ve sık kullanılan spektral bant çıkarma yöntemlerinden biri Temel Bileşen Analizidir (TBA) [4]. TBA ile HG'lerde faydalı spektral bantların çıkarılması amaçlanmaktadır. Bu işlem sonucunda veri boyutu küçülmekte ve işlem maliyeti azalmaktadır. HG'lerin spektral ve uzamsal bilgileri, sınıflandırma için kullanılabilir iki ana özelliktir [5]. Rastgele orman (RO) [6], destek vektör makinesi (DVM) [7] ve lojistik regresyon (LR) [8] gibi geleneksel sınıflandırma yöntemleri, esas olarak sınıflandırma için bol miktarda spektral bilgiden yararlanmaya odaklanmaktadır. Sınıflandırma performansını iyileştirmek için, morfolojik profiller [9], çoklu çekirdek öğrenme [10], süper piksel [11] ve seyrek gösterim [12] gibi yöntemler, uzamsal bilgileri HG sınıflandırması için spektral bilgilerle birleştirmek için tanıtılmıştır. Örneğin, Benediktsson vd., HG'lerin spektral-uzamsal özelliklerini elde etmek için genişletilmiş morfolojik profiller kullanmıştır [9]. Fang vd., HG'lerin çok ölçekli uzamsal bilgisinden yararlanmak için çok ölçekli bir uyarlamalı seyrek gösterim modeli önermiştir [12]. Fauvel vd., sınıflandırma için uzamsal ve spektral bilgiyi birlikte kullanmak için morfolojik çekirdek tabanlı bir DVM sınıflandırıcı önermiştir [13]. Bununla birlikte, bu yöntemlerin ortak sınırlaması, uzmanların deneyimlerini ve özellik mühendisliğinde büyük çabalar gerektiren ve zor senaryolarda uygulanabilirliklerini sınırlayan el yapımı özelliklere büyük ölçüde dayanmalarıdır.

Son zamanlarda, derin öğrenme tabanlı yöntemler, orijinal verilerden hiyerarşik bir şekilde otomatik olarak sağlam ve ayırt edici özellikleri çıkarabildikleri için, görüntü sınıflandırma, anlamsal bölümlenme, doğal dil işleme ve nesne algılama gibi birçok bilgisayarla görme görevinde büyük ilerlemeler kaydetmiştir [1]. Bunun ana nedenlerinden biri, derin öğrenmenin bir problem alanı için etkili bir özellik temsilini otomatik olarak keşfedebilmesi ve böylece karmaşık ve el yapımı özellik mühendisliği sürecinden kaçınılabilmektedir [14]. Chen vd. tarafından ilk olarak HG spektral-uzamsal sınıflandırması için yığınlanmış bir otomatik kodlayıcı önerilmiştir [15]. Daha sonra, derin inanç ağı ve evrimsel sinir ağı (ESA) dahil olmak üzere derin öğrenme modelleri, HG sınıflandırması için derin spektral-uzamsal sınıflandırıcılar olarak tanıtılmıştır. HG'lerin hem spektral hem de uzamsal bilgisinden yararlanmak için, bir dizi geliştirilmiş ESA tabanlı spektral-uzamsal sınıflandırıcı önerilmiştir. [1] nolu

çalışmada, mevcut diğer derin öğrenme tabanlı HG sınıflandırma modellerinden daha geniş olan yeni bir ESA modeli önerilmiştir. Çok yollu artık ağı (ResNet) olarak adlandırılan yöntem, ağı daha derinden ziyade daha geniş hale getirmek için artık bloklarda çoklu artık işlevler kullanmaktadır. [16] nolu çalışmada, HG'lerin uzamsal ve spektral özelliklerini etkin bir şekilde çıkaran 2B ESA ile 3B ESA birleştirilerek hibrit bir ağı modeli tasarlanmıştır. [17] nolu çalışmada, 2 boyutlu çok ölçekli uzamsal özellikleri ve 1 boyutlu spektral özellikleri birlikte öğrenen çok ölçekli 3 boyutlu derin evrimsel sinir ağı önerilmiştir. [18] nolu çalışmada, derin bir ESA'dan çıkarılan çok katmanlı özelliklerin sınıflandırma için kaynaştırıldığı ve gradyan kaybolma problemini hafifletmek için artık öğrenmenin kullanıldığı bir derin öznetelik füzyon ağı önerilmiştir. [5] nolu çalışmada, HG sınıflandırması için 3B ESA ve 2B ESA tabanlı çok ölçekli bir uzamsal-spektral özellikten oluşan hibrit bir ESA modeli önerilmiştir. Spektral bant fazlalığını azaltmak ve optimum bant çıkarımını sağlamak için doğrusal olmayan çekirdek temel bileşen analizi ve doğrusal gauss rastgele projeksiyondan oluşan hibrit boyut indirgeme yöntemi kullanılmıştır. [19] nolu çalışmada, HG sınıflandırması için farklı çekirdek boyutuna sahip 3B ESA ve 2B ESA ile çok dallı özellik füzyonuna dayalı derin bir ağı mimarisi önerilmiştir. Bu çalışmada, ReLU yerine Mish aktivasyon fonksiyonu kullanılmıştır.

ESA'ların başarılı örnekleri arasında Visual Geometry Group (VGG), GoogLeNet, ResNet tarafından önerilen çok derin ESA'lar ile LeNet5, Alexnet gibi ağlar da bulunmaktadır. Ayrıca, hiperspektral görüntülerin hacimsel veri olması ve spektral boyuta sahip olmasından dolayı 2B ESA spektral boyutlardan iyi ayırt edici özellik haritaları çıkaramamaktadır. Çünkü 2B ESA ile uzamsal özellikler genellikle ayrı olarak çıkarılmakta ve uzamsal-spektral bilgiden ortak olarak yararlanmayı bir dereceye kadar geçersiz kılmaktadır. Artan hesaplama karmaşıklığı nedeniyle çok az yöntem 3B ESA kullanmaktadır. 3B ESA ile spektral ve uzamsal özellikler eşzamanlı olarak çıkarıldığından, 3B HG'lerin yapısal özelliklerinden tam olarak yararlanılmaktadır. Bu çalışma kapsamında, mümkün olabilecek maksimum doğruluğu elde etmek için hem spektral hem de uzamsal özellik haritalarını tam olarak kullanacak şekilde bu beş derin öğrenme mimarisi ile 3B ESA'nın birleşiminden oluşan hibrit bir yöntem önerilerek ESA tabanlı bu beş derin öğrenme mimarisinin HG'ler üzerinde sınıflandırma performanslarının karşılaştırılması amaçlanmıştır.

Bu çalışmada önerilen yöntemin teorik alt yapısı oluşturan derin öğrenme mimarileri Bölüm 2'de ve önerilen yöntem çerçevesi Bölüm 3'te açıklanmıştır. Bölüm 4'te kullanılan verisetleri ve uygulama sonuçları verilmiştir. Bölüm 5'te ise sonuçlar yer almaktadır.

## 2. Esa ve Derin Öğrenme Mimarileri (Cnn and Deep Learning Architectures)

Bu bölümde hiperspektral görüntü sınıflandırmasında kullanılan ESA ve beş farklı derin öğrenme mimarisi kısaca tanıtılacaktır. Bu mimariler arasında LeNet5, AlexNet, GoogleNet, ResNet50 ve VGG16 bulunmaktadır.

*ESA:* Görüntü sınıflandırması için derin öğrenme teknikleri son zamanlarda yaygın olarak kullanılmaktadır. ESA, evrimsel katmanı, havuzlama katmanı ve tamamen bağlı katmandan oluşan çok katmanlı bir sinir ağıdır. Evrimsel katmanı, giriş verileri üzerinde evrimsel işlemi gerçekleştiren ESA'nın temel parçasıdır. Evrimsel, iki matris, yani alıcı alan (receptive field) ve çekirdek (kernel) arasındaki bir iç çarpım işlemidir. Genel olarak, çekirdek uzamsal olarak giriş verilerinden daha küçüktür. Çekirdek alıcı alan üzerinde kaymakta ve giriş verilerinin bir özellik haritasını oluşturmaktadır. Havuzlama katmanı, özellik haritasının uzamsal boyutunu azaltmaktadır. Bir dizi çıkırtı,

yakındaki özellik değerlerinin istatistiklerine göre tek bir değerle değiştirmektedir. En yaygın kullanılan havuzlama tekniği maksimum havuzlamadır ve bir dizi özelliği maksimum değeriyle değiştirmektedir. Tamamen bağlı katman, tüm nöronların birbirini takip eden her katman nöronuna bağlandığı çok katmanlı bir algılayıcıdır. Bu katman, özellikleri çıktıya haritalamak için kullanılmaktadır [5].  $x$  girdileri için tek nöronun çıktısı Eş. 1'deki gibi hesaplanmaktadır.

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

Eş. 1'de,  $w$  filtre ağırlığı ve  $b$  ise bias değeridir.  $f(\cdot)$ , ağırlıklı bir girdi toplamına uygulanan doğrusal olmayan aktivasyonu ifade etmektedir. 2B ESA modeli, giriş verilerini etkinleştirmeden önce iki boyutlu bir çekirdek kullanarak evrişim işlemini gerçekleştirmektedir. Bu, giriş görüntüsünden uzamsal özellikleri çıkarmaya yardımcı olmaktadır. Her nöronun 2B evrişim çıktısı için Eş. 1 yeniden Eş. 2'deki gibi formüle edilmektedir [5].

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

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


3B evrişim, üç boyutlu spektral görüntülerden hem uzamsal hem de spektral özelliklerin çıkarılmasına yardımcı olmaktadır. 3B ESA modelinden çıkarılan özellik Eş. 3'teki gibi formüle edilmektedir [5].

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

Eş. 3'te  $b$  spektral boyut boyunca 3B çekirdeğin boyutudur. Çekirdek ( $k$ ), üç boyutludur ve özellikler, 3B giriş verileri üzerinde 3B evrişim gerçekleştirilerek hesaplanmaktadır.

*LeNet5*: Bu mimari, 1998 yılında Yann LeCun vd. [20] tarafından geliştirilmiştir. Bu derin öğrenme mimarisi, 'Belge Tanımaya Uygulanan Gradyan Tabanlı Öğrenme' araştırma makalesinde önerilen en eski önceden eğitilmiş modellerden biridir. LeNet5, el yazısı ve makine baskılı karakterleri tanımak için ve MNIST veri setine dayalı olarak bankalar tarafından el yazısıyla yazılan çekleri tespit etmek için kullanılmıştır. Diğer tüm ConvNet'ler için standart şablon olarak kabul edilmektedir. Bu derin öğrenme mimarisinin popülaritesinin arkasındaki ana neden, basit ve anlaşılır bir mimariye sahip olmasıdır. Ayrıca görüntü sınıflandırması için çok katmanlı bir evrişim sinir ağı mimarisi sunmaktadır. LeNet-5 mimarisi Şekil 1'de gösterildiği gibi iki evrişim katmanından, iki ortalama havuzlama katmanından, bir düzleştirme katmanından, iki tam bağlantılı katmandan ve elde edilen özellikleri ilgili sınıfa sınıflandıran bir softmax sınıflandırıcıdan oluşmaktadır. Bu çalışma kapsamında 3B ESA tabanlı LeNet5 mimarisi kullanıldığı için evrişim ve ortalama havuzlama katmanlarında kullanılan filtre boyutları 3 boyutludur. Birinci evrişim katmanında (5x5x5) filtre boyutuna sahip 6 filtre, ikinci evrişim katmanında (5x5x5) filtre boyutuna sahip 16 filtre kullanılmaktadır. Her iki ortalama havuzlama (Average pooling) katmanında da kullanılan filtre boyutu (2x2x2) 'dir. Evrişim katmanlarından sonra, ağı daha düzenli hale getirmek ve öğrenme sürecinin aşırı uyum göstermesini önlemek için batch normalization (BN) kullanılmıştır. Burada doğrusal olmayan aktivasyon fonksiyonu olarak RELU kullanılmıştır. Evrişim ve ortalama havuzlama katmanlarından sonra çıktı düzleştirilir (flatten) ve sonunda sırasıyla 120 ve 84 nörondan oluşan iki tam bağlantılı katman (Fully connected-FC) dan geçtikten sonra softmax aktivasyon fonksiyonu ile sınıf sayısına indirgenmektedir. Aşırı öğrenmeyi önlemek için, tamamen bağlı her katmandan sonra %0,4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır.

*AlexNet*: Mimari, 2012 yılında Alex Krizhevsky vd. [21] tarafından "Imagenet Classification with Deep Convolution Neural Network" adlı araştırma makalesinde önerilmiştir. Bu mimaride ağı derinliği LeNet5'e göre artırılmıştır. AlexNet mimarisi Şekil 2'de gösterildiği gibi 5 evrişim katmanından (conv), 3 maksimum havuzlama katmanından (MaxPooling3D), 2 tam bağlantılı katmandan (FC), düzleştirme (flatten) ve softmax katmanından oluşmaktadır. Her evrişim katmanından sonra, ağı daha düzenli hale getirmek için Batch normalization (BN) ve doğrusal olmayan aktivasyon fonksiyonu olan ReLU kullanılmaktadır. Çalışma kapsamında 3B ESA kullanıldığından, AlexNet mimarisinin ilk evrişim katmanında (11x11x11) filtre boyutuna sahip 96 filtre, ikinci evrişim katmanında (5x5x5) filtre boyutuna sahip 256 filtre, üçüncü, dördüncü ve beşinci evrişim katmanlarında (3x3x3) filtre boyutuna sahip sırasıyla 384, 384 ve 256 filtre kullanılmaktadır. Tüm maksimum havuzlama katmanları (3x3x3) filtre boyutundadır. Üçüncü maksimum havuzlama katmanından sonra elde edilen çıktı düzleştirilmekte ve sonunda sırasıyla 4096 nörondan oluşan iki tam bağlantılı katman




Şekil 1. LeNet5 Mimarisi (LeNet5 Architecture)

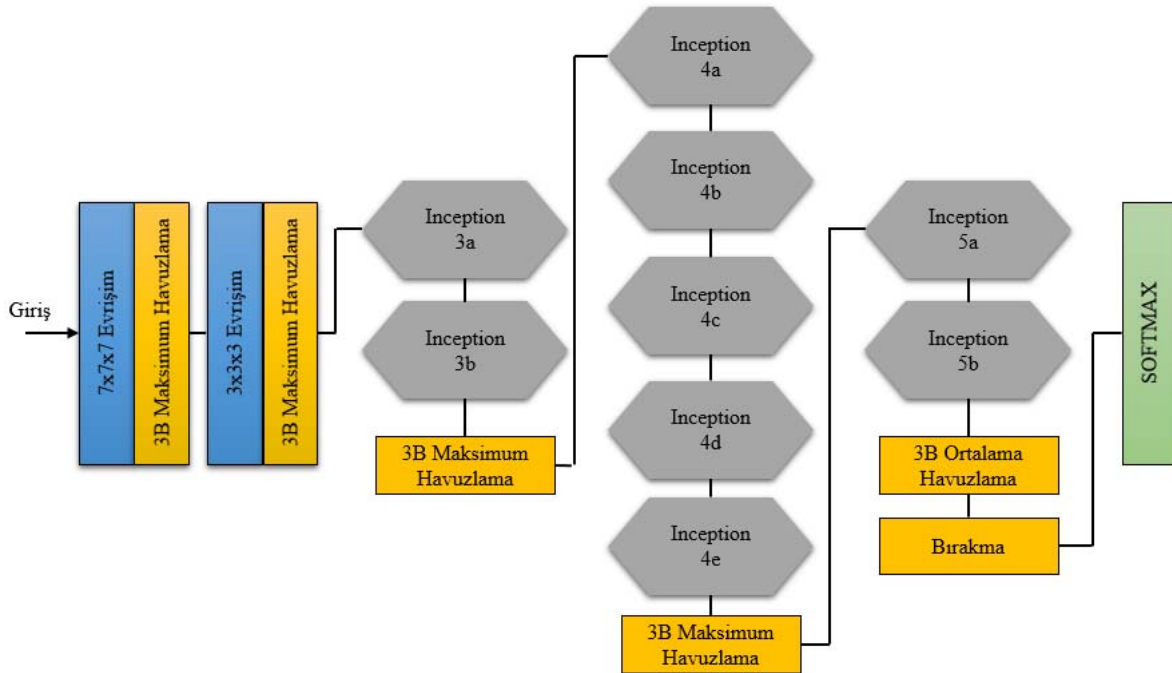


(Fully connected-FC)'dan geçtikten sonra softmax aktivasyon fonksiyonu ile sınıf sayısına indirgenmektedir. Aşırı öğrenmeyi önlemek için, tamamen bağlı her katmandan sonra %0,4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır. *GoogleNet*: Bir ağ derinleştikçe aşırı öğrenme problemiyle karşı karşıya kalabilmektedir. Bu problemi çözmek için, "Going deeper with convolutions" araştırma makalesinde Szegedy vd. [22] tarafından, aynı düzeyde çalışabilen birden çok boyutta filtreler sahip olma fikriyle ve geleneksel ESA'lara kıyasla hesaplama karmaşıklığını azaltmak amacıyla 2015 yılında GoogleNet mimarisi önerilmiştir. Bu fikirle, ağ aslında daha derinden daha geniş hale gelmektedir. GoogleNet mimarisi Şekil 3'te gösterildiği gibi 22 katman (havuzlama katmanları dahil 27 katman) derinliğindedir. Toplamda doğrusal olarak yığılmış 9 Inception modülü ağın yapı taşını oluşturmaktadır (Şekil 4). Inception modülünün arkasındaki motivasyon, ince bilgileri kaybetmeden alıcı alanı arttırmaktır. Çalışma kapsamında bu ağ mimarisi 3B ESA ile birlikte kullanılmaktadır. Şekil 3'te gösterildiği gibi ağ mimarisinin ilk evrişim katmanında (7x7x7) filtre boyutunda 64 filtre kullanılmaktadır. Ardından (3x3x3) filtre boyutunda maksimum havuzlama işlemi gerçekleştirilmektedir. İkinci evrişim katmanında (3x3x3) filtre boyutunda 192 filtre kullanılmaktadır. Ardından tekrar (3x3x3) filtre boyutunda maksimum havuzlama işlemi gerçekleştirilmektedir. İlk iki evrişim ve maksimum havuzlama

katmanlarından sonra ard arda 9 Inception modülü kullanılmaktadır. Inception modülü Şekil 4'te gösterildiği gibi (1x1x1), (3x3x3), (5x5x5) evrişim katmanlarından ve bir tane (3x3x3) maksimum havuzlama katmanının birleşiminden oluşmaktadır. Inception modülünün kullanılmasının iki ana avantajı vardır: i) her katmanda farklı boyutlarda filtreler kullanarak daha doğru konumsal bilgileri tutmaktadır; ayrıca ii) ağın serbest parametrelerinin sayısını önemli ölçüde azaltmakta, bu da ağın aşırı öğrenme problemini önlemeye yardımcı olmasına ve daha derin olmasına izin vermektedir. GoogleNet mimarisinde bazı Inception modülleri arasında (3x3x3) filtre boyutunda maksimum havuzlama katmanları kullanılmaktadır. Bu maksimum havuzlama katmanlarının amacı, ağ üzerinden beslenirken girdiyi aşağı örneklemektir. Bu, girdi verilerinin yüksekliğinin ve genişliğinin azaltılmasıyla elde edilmektedir. Inception modülleri arasındaki giriş boyutunun azaltılması, ağı hesaplamaya yükünü azaltmanın bir başka etkili yöntemidir. En son Inception modülünden (Inception5b) sonra elde edilen tüm özellik haritalarının (1x1x1) filtre boyutunda ortalama havuzlama katmanı (AvgPooling3D) kullanılarak ortalaması alınmaktadır. Ardından elde edilen özellik haritası çıktısı düzleştirilmekte ve doğrusal katmandan hemen önce %0,4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır. En sonda ise softmax aktivasyon fonksiyonu kullanılarak istenilen sınıf sayısına indirgeme işlemi gerçekleştirilmektedir.



Şekil 2. AlexNet Mimarisi (AlexNet Architecture)

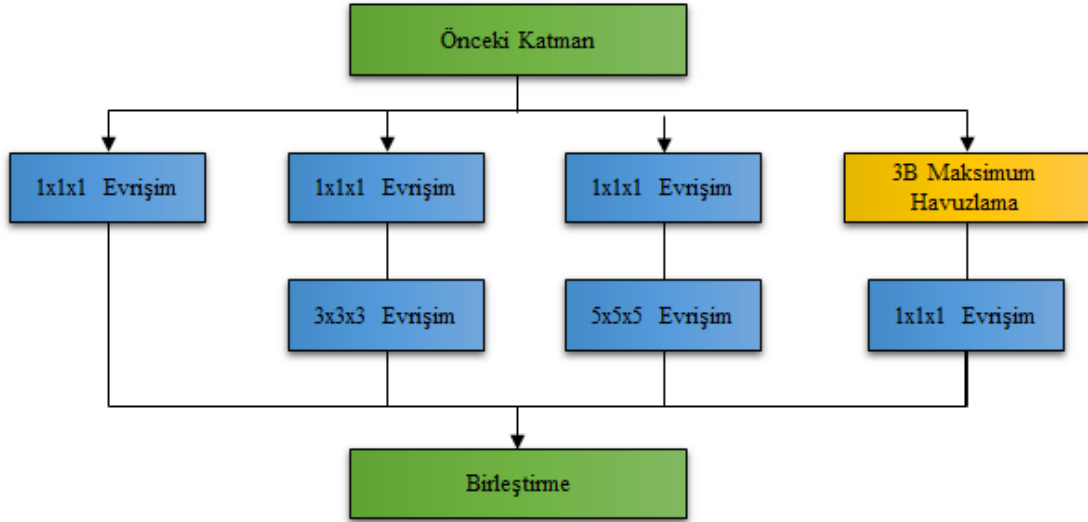


Şekil 3. GoogleNet Mimarisi (GoogleNet Architecture)


**Artık Ağ (ResNet):** Derin olmayan ağ mimarisiyle (yani LeNet, AlexNet) 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 ağı 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 problemi nedeniyle çok zordur. Kaybolan gradyan problemi, daha derin ağlardaki eğitim sürecinde ortaya çıkmaktadır. Eğitim ilerledikçe, bir katmandan diğerine geçerken gradyan sinyalleri biraz kaybolmakta ve derin olmayan katmanlarda sifıra yaklaşmaktadır. Bu durum ağı yakınsamasını en başından engellemektedir. Kaybolan gradyan ve bozunma problemini çözmek için Şekil 5'de gösterilen artık öğrenme bloğu He vd. [23] tarafından önerilmektedir. Ağ girişi  $x$  ve çıktı olarak elde edilecek özellik haritası  $H(x)$  olarak ifade edilsin. Artık haritalama  $H(x) = F(x)+x$ , kimlik kısayol bağlantıları eklenerek gerçekleştirilmektedir. Böylece ikinci katmanın çıktısına girdi verileri eklenerek geçmiş katmanın verilerinin ileri katmanlara etkin bir şekilde iletilmesi amaçlanmaktadır. İleriye yayılma sürecinde, artık öğrenme blokları sayesinde derin ağı kimlik haritalaması gerçekleştirilmektedir. Böylece ağ, kaybolan gradyan ve bozulma problemlerinden kaçınılabilir katman sayısını arttırabilmektedir. ResNet, artık öğrenme blokları adı verilen çok sayıda temel yapısal öğenin istiflenmesiyle oluşturulmaktadır. ResNet mimarisinin en önemli katkılarından biri, yapay sinir ağı katman sayısını artırırken ağı daha hızlı ve başarılı bir şekilde eğitilmesini sağlamasıdır. Bu çalışma kapsamında ResNet50 mimarisi kullanılmıştır. ResNet50 mimarisi iki ana bloktan oluşmaktadır. Kimlik ve Evrişim blokları [24].

Kimlik bloğu (Identity Block), ResNet'te kullanılan standart blok tür ve giriş aktivasyonunun çıkış aktivasyonu ile aynı boyuta sahip

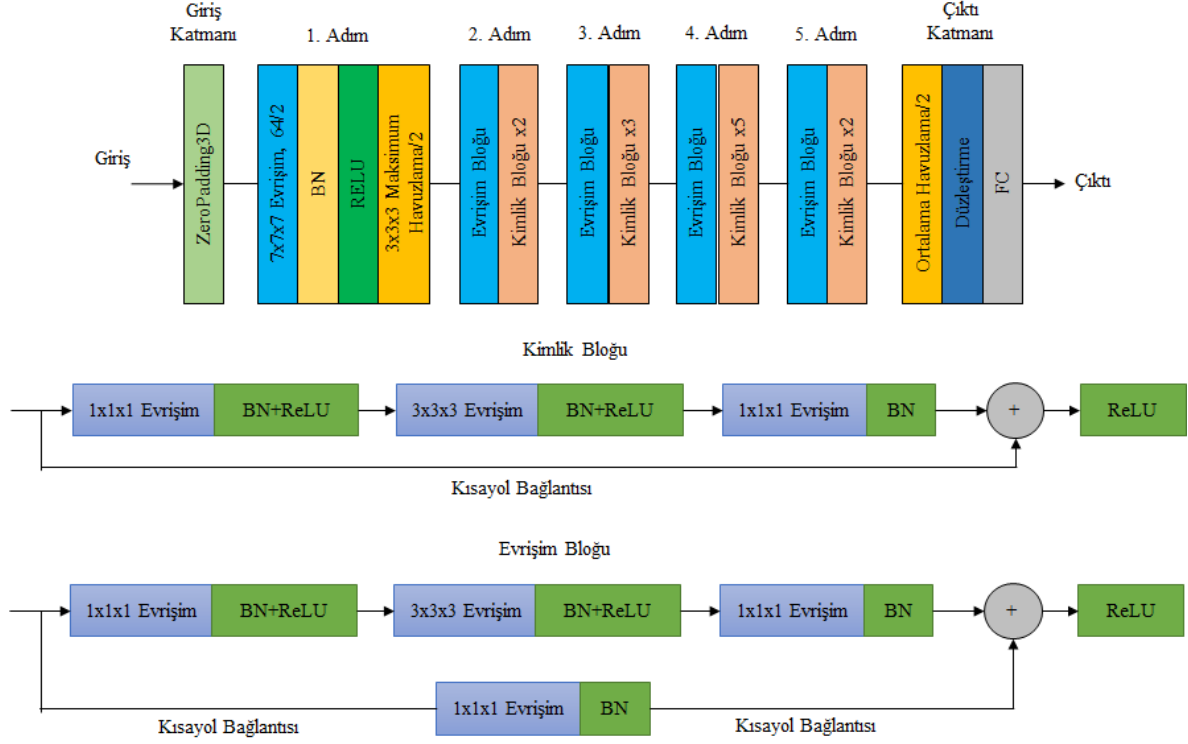
olduğu duruma karşılık gelmektedir. Kimlik bloğu üç bileşenli bir yapıdan oluşmaktadır. Birinci bileşen  $(1 \times 1 \times 1)$  filtre boyutu ile  $(1, 1, 1)$  stride değerine sahip 3B evrişim katmanından oluşmaktadır. 3B evrişimden sonra, ağı daha düzenli hale getirmek ve öğrenme sürecinin aşırı uyum göstermesini önlemek için batch normalization (BN) kullanılmıştır. Özellikle gradyan azalması ile eğitim süresi açısından RELU'lar diğer aktivasyon fonksiyonlarından daha hızlı olma eğilimindedir. Burada doğrusal olmayan aktivasyon fonksiyonu olarak RELU kullanılmıştır. İkinci bileşen birincisine benzerdir. Ancak filtre boyutu  $(3 \times 3 \times 3)$ 'tür. Üçüncü bileşen, birinci bileşene benzerdir. Ancak ReLU aktivasyon fonksiyonuna sahip değildir. Son olarak, ReLU aktivasyon fonksiyonu uygulanmadan önce kısayol bağlantısı ile çıkışa giriş verileri eklenmektedir. Evrişim bloğunda giriş ve çıkış boyutları eşleşmemektedir. Kısayol bağlantı yoluna 3B evrişim katmanı eklenerek kimlik bloğundan farkı gösterilmektedir. Evrişimli bloğun yapısı, kısayol bağlantı yolunda ilave bir 3B evrişim katmanına sahip kimlik bloğundakiyle aynı prosedürü takip etmektedir. Bu kısayol bağlantısında, giriş ana yolla eşleşecek şekilde yeniden boyutlandırılmaktadır. Kısayol bağlantısında yer alan 3B evrişim katmanı  $(1 \times 1 \times 1)$  filtre boyutuna sahiptir. Bu evrişim katmanı ReLU aktivasyon fonksiyonuna sahip değildir. Son olarak, ReLU aktivasyon fonksiyonu uygulanmadan önce kısayol bağlantısı ile çıkışa giriş verileri eklenmektedir. Kısayol bağlantısına 3B evrişim katmanının eklenmesinin avantajı, kaybolan gradyan problemini kontrol etmektir [25]. Kimlik ve evrişim bloklarının birleştirilmesiyle elde edilen ResNet50 mimarisi Şekil 6'da gösterilmektedir. Literatürde 18, 34, 50, 101 ve 152 katmanlı ResNet mimarileri bulunmaktadır. Çalışma kapsamında ise, ResNet34'ten daha derin katmanlara ve ResNet101 ile ResNet152'den daha az parametreye sahip olduğundan hiperspektral görüntü sınıflandırılması için ResNet50 kullanılmaktadır. ResNet50 mimarisinin girişinde  $(3 \times 3 \times 3)$  filtre boyutunda 3B ZeroPadding işlemi uygulanmaktadır. Diğer işlemler ise şu şekildedir.



Şekil 4. Inception Modülü (Inception Module)



Şekil 5. Artık öğrenme bloğu (Residual learning block)



Şekil 6. ResNet50 Mimarisi (ResNet50 Architecture)

*Adım 1:* (7x7x7) filtre boyutuna ve (2, 2, 2) stride değeri ile 64 filtreye sahip 3B evrişimden oluşmaktadır. Daha sonra BN ve Aktivasyon fonksiyonu olarak ReLU kullanılmaktadır. En sonunda ise (3x3x3) filtre boyutunda 3B maksimum havuzlama (max-pooling) işlemi gerçekleştirilmektedir.

*Adım 2:* Bir 3B evrişim bloğundan ve iki kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (1, 1, 1) stride değerine sahip olan üç filtre seti [64, 64, 256] kullanılmaktadır.

*Adım 3:* Bir 3B evrişim bloğundan ve üç kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (2, 2, 2) stride değerine sahip olan üç filtre seti [128, 128, 512] kullanılmaktadır.

*Adım 4:* Bir 3B evrişim bloğundan ve beş kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (2, 2, 2) stride değerine sahip olan üç filtre seti [256, 256, 1024] kullanılmaktadır.

*Adım 5:* Bir 3B evrişim bloğundan ve iki kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (2, 2, 2) stride değerine sahip olan üç filtre seti [512, 512, 2048] kullanılmaktadır.

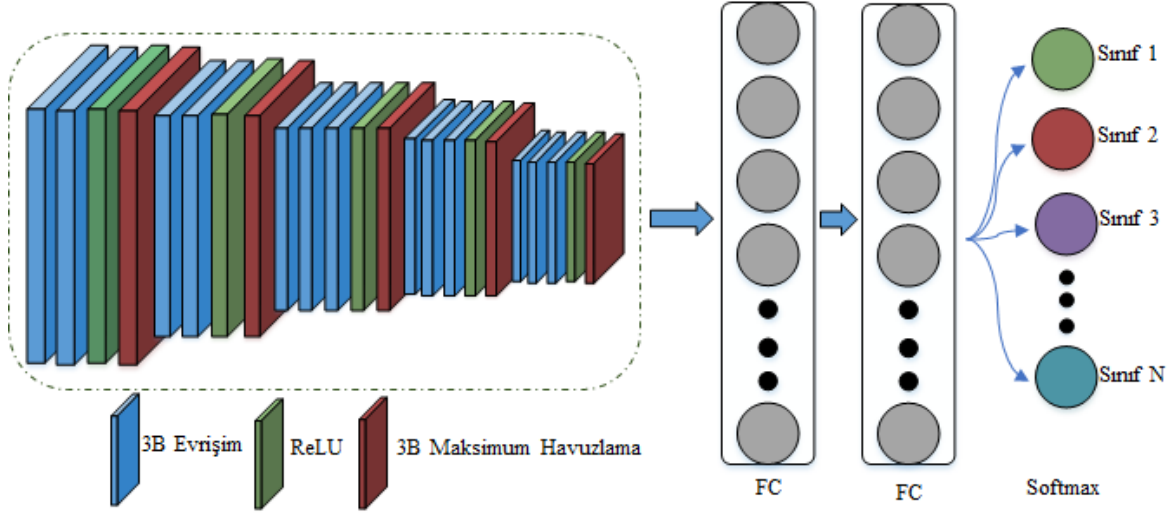
*Adım 6:* (2x2x2) filtre boyutunda 3B ortalama havuzlama (average pooling) işlemi gerçekleştirilir. Ardından çıktı düzeştirilir ve sonunda tam bağlantılı katman (Fully connected-FC) girdiyi bir softmax aktivasyon fonksiyonu ile sınıf sayısına indirmek için kullanılmaktadır.

*VGGNet:* VGGNet mimarisi, 2014 yılında Oxford'un Görsel Geometri Grubu tarafından çok derin bir evrişimsel sinir ağı oluşturmak ve eğitmek için başarılı bir çaba olarak icat edilmiştir [26]. Bu mimari, bir ağı derinliğinin, evrişimsel sinir ağlarında tanıma veya sınıflandırmada yüksek performans elde etmek için kritik bir bileşen olduğunu göstermiştir. VGG, evrişim çekirdeklerini 3x3'e küçültürken, ancak her bir evrişim katmanındaki evrişimsel katman dizilerinin ve özellik haritalarının sayısını artırarak, tanıma görevleri için AlexNet ile karşılaştırılabilir uygun alıcı alanla daha derin

mimariyi eğitebilmektedir. VGG16 Şekil 7'de gösterildiği gibi 16 katman derinliğine sahip evrişimli bir sinir ağıdır. VGG16 ile ilgili en benzersiz şey, çok sayıda hiper parametreye sahip olmak yerine, stride değeri 1 olan 3x3 filtre boyutunda evrişim katmanlarına sahip olmaya odaklanmaları ve her zaman aynı dolguyu (padding=same) ve stride değeri 2 olan 2x2 filtre boyutuna sahip maksimum havuzlama (max-pool) katmanlarını kullanmalarıdır. Tüm mimari boyunca tutarlı bir şekilde bu evrişim ve maksimum havuz katmanları düzenlemesini takip etmektedir. Sonunda 2 FC'ye (tamamen bağlı katmanlar) ve ardından çıktı için bir softmax'a sahiptir. Çalışma kapsamında VGG16 mimarisi ile birlikte 3B ESA kullanıldığı için evrişim ve maksimum havuzlama katmanlarının filtre boyutları 3 boyutlu olarak alınmaktadır. Uygulanan VGG16 mimarisi (3x3x3) filtre boyutuna sahip evrişim işlemlerinin gerçekleştirildiği evrişim katmanlarından, stride değeri 2 olan ve (2x2x2) filtre boyutuna sahip 3B maksimum havuzlama katmanı ve evrişim katmanlarından sonra aktivasyon fonksiyonu olarak kullanılan ReLU'dan oluşmaktadır. Evrişim katmanlarının 1 ve 2. katmanında 64 filtre, 3 ve 4. Katmanında 128 filtre, 5, 6 ve 7. katmanında 256 filtre, 8, 9, 10, 11, 12 ve 13. katmanında ise 512 filtre kullanılmaktadır. Evrişim ve havuzlama katmanlarından sonra elde edilen çıktı düzeştirilmektedir. Ardından çıktı 4096 nörona sahip iki tam bağlantılı katmandan geçirildikten sonra girdi, bir softmax aktivasyon fonksiyonu ile sınıf sayısına indirmektedir. Her tam bağlantılı katmandan sonra aktivasyon fonksiyonu olarak ReLU kullanılmakta ve aşırı öğrenmeyi (overfitting) önlemek için, tamamen bağlı her katmandan sonra %0,4 bırakma oranına (dropout rate) sahip bir bırakma (dropout) katmanı uygulanmaktadır.

### 3. Önerilen Yöntem (Proposed Method)

Önerilen Yöntem Şekil 8'de gösterildiği gibi üç bölümden oluşmaktadır. (1) Boyut indirgeme, (2) Örnek oluşturma ve (3) Özellik çıkarma ve sınıflandırma. İlk olarak, hyperspektral görüntü  $X$ ,  $M \times N \times D$  boyutunda 3 boyutlu bir küp olarak belirtilmiştir.



Şekil 7. VGG16 Mimarisi (VGG16 Architecture)



Şekil 8. Hiperspektral görüntü sınıflandırması için çerçeve (Framework for hyperspectral image classification)

Burada  $M$  ve  $N$ , görüntünün uzamsal genişliği ve yüksekliğidir.  $D$  ise, spektral bantların sayısını belirtmektedir. Yüzerce spektral banttan oluşan hiperspektral görüntünün analizini kolaylaştırmak ve hesaplama karmaşıklığını azaltmak için spektral bant fazlalığını gidermek gerekmektedir. Bu doğrultuda, ilk önce orijinal hiperspektral görüntü verilerine spektral bantlar boyunca geleneksel TBA uygulanmaktadır. TBA, aynı uzamsal boyutları (yani, genişlik  $M$  ve yükseklik  $N$ ) korurken spektral bant sayısını  $D$ 'den  $B$ 'ye düşürür. Herhangi bir nesneyi tanımak için çok önemli olan uzamsal bilgiyi koruyacak şekilde yalnızca spektral bantları azaltılmış oldu. Böylelikle, istenilen bant sayısına indirgenmiş oldu. İkinci olarak, görüntü sınıflandırma tekniklerini kullanmak için, hiperspektral veri küpü, merkezi piksele dayalı gerçek etiketlerin oluşturulduğu küçük üst üste binen 3B uzamsal parçalara bölünmüştür. Uzamsal konumda (a,b) merkezlenmiş ve  $S \times S$  penceresini veya uzamsal boyutu ve tüm  $B$  spektral bantlarını kapsayan hiperspektral veri küpünden 3B komşu parçaları  $S \times S \times B$  oluşturuldu. Hiperspektral veri küpünden üretilen toplam 3B parça sayısı ( $n$ ),  $(M - S + 1) \times (N - S + 1)$  ile bulunur. Son olarak, oluşturulan 3B hiperspektral veri küpü, özellik çıkarma ve sınıflandırma için 3B ESA tabanlı derin öğrenme mimarilerinin girişine verilmektedir. 3B ESA, 2B ESA'da 2B evrişim yerine 3B evrişim gerçekleştiren 2B ESA modellerinin değiştirilmiş şeklidir. Evrişim işlemleri, 3B verilere uygulandığında hem uzamsal hem de spektral boyutlardan özelliklerin yakalanması istenilmektedir. Bu amaçla, 3B giriş verilerinden ortak uzamsal spektral özellikleri hesaplama için 3B evrişim işlemlerinin 3B özellik küplerine

uygulandığı 3B ESA kullanılmaktadır. 3B evrişim, 3B spektral görüntülerden uzamsal-spektral özelliklerin çıkarılmasına yardımcı olmaktadır [27].

#### 4. Verisetleri ve Uygulama Sonuçları (Datasets And Application Results)

3B ESA tabanlı derin öğrenme mimarilerinin sınıflandırma performanslarını karşılaştırmak için Indian Pines (IP), Salinas (SA), Botswana (B) ve HyRANK-Loukia (HL) veri setlerini içeren dört gerçek hiperspektral veriseti kullanılmıştır [28].

















IP veriseti, Kuzeybatı Indiana'daki Indian Pines test alanında Havadan Görünür / Kızılötesi Görüntüleme Spektrometresi (Airborne Visible/Infrared Imaging Spectrometer-AVIRIS) sensörü tarafından elde edilmiştir. Bu verisetindeki her spektral görüntü  $145 \times 145$  uzamsal boyutundadır. Sensör, 0,4-2,5 mikrometre dalga boyu aralığında toplam 224 spektral bant elde etmiştir. Bu 224 banttan, 24 bant tam su absorpsiyonu (emme) bölgesindedir ve bunlar sınıflandırma işlemi için yararlı değildir. 24 su emme bandı çıkarıldıktan sonra kalan 200 bant deneyler için kullanılmıştır. IP veriseti 16 tür arazi örtüsü ve 10.249 örnek içermektedir. SA veriseti, California, Salinas Valley üzerinden AVIRIS sensörü tarafından toplanmıştır. Veriseti, piksel başına 3,7 metre uzamsal çözünürlüğe sahiptir. 224 bant içeren, 217 piksel genişliğinde ve 512 piksel yüksekliğinde bir uzaktan algılama görüntüsüdür. 20 su emme bandı çıkarıldıktan sonra kalan 204 bant deneyde kullanılmıştır. SA veriseti,

















toplam 16 tür arazi örtüsü ve 54.129 örnek içermektedir. B veriseti, 2001 yılında Botswana, Okavango Deltası üzerinde EO-1 üzerinde Hyperion sensörü tarafından toplandı. Elde edilen veriler orijinal olarak 30 m piksel çözünürlüklü 10 nm pencerelerde spektrumun 400–2500 nm bölümünü kapsayan 242 banttandır oluşuyordu. Kalibre edilmemiş (Ayarlanmamış) ve su emilimini örten gürültülü bantlar [10-55, 82-97, 102-119, 134-164, 187-220] çıkarıldıktan sonra deneylerde sadece 145 bant kullanıldı. Kullanılan veriler, arazi örtüsü türlerini temsil eden 14 tanımlanmış sınıftan ve gözlemlerle 1476 x 256 pikselden oluşmaktadır. Toplam 3248 örnek içermektedir. HL, Hyperion Earth Observing-1 sensörü kullanılarak elde edilen HyRANK veri kümesindeki bir görüntüyü temsil etmektedir. 30 m uzamsal çözünürlüğe ve 400 ile 2500 nm spektral kapsama alanına sahiptir. Görüntü 249 × 945 piksel boyutunda 176 yüzey yansıtma bandı sağlamaktadır [29-30]. HL veriseti 14 tür arazi örtüsü ve 13.503 örnek içermektedir. Verisetlerinin sınıf ve örnek sayısı bilgileri Tablo 1'de listelenirken, sahte renkli (false-color) görüntüleri ve bunlara karşılık gelen temel doğruluk (ground truth) haritaları Şekil 9'te gösterilmektedir.

Tüm uygulamalar Google Colab olarak bilinen çevrimiçi bir platformda gerçekleştirilmiştir. Colab, herhangi bir ortamı çalıştırmak için iyi bir internet hızı gerektiren çevrimiçi bir platformdur. Colab, kodların Tensor İşlem Birimi (TPU), 35 GB Rasgele Erişim Belleği (RAM) ve veri hesaplaması için 107,77 GB depolama alanı içeren python 3 masaüstü bilgisayarda çalıştırılması için bir seçenek sunmaktadır. Tüm deneylerde, test-eğitim seti %30-70 oranına bölünmüştür. 0.0001 öğrenme oranına sahip kategorik çaprazentropi ve optimizasyon için kullanılan 1e-06 bozunma işlevine sahip Adam optimizasyon algoritması kullanılmıştır. Eğitim süreci, 256 batch size ve 100 epochs boyunca tekrar etmektedir. Tüm verisetlerinde, evrişim için 15x15 komşuluk çıkarımı kullanılmaktadır. Bununla birlikte, TBA tekniğinden sonra çıkarılan bantların sayısı tüm verisetleri için 15 temel bileşen olarak alınmıştır. Her modelin sınıflandırma performansını değerlendirmek için genel doğruluk (GD), ortalama doğruluk (OD) ve kappa istatistiği (K) kullanılmıştır. GD, test verilerindeki doğru sınıflandırılmış örnekler ile toplam test örneği sayısı arasındaki oranla hesaplanmıştır. OD her kategorinin doğruluğunun ortalama değeridir. K, temel gerçek (ground truth)

**Tablo 1.** Hiperspektral verisetlerindeki her sınıfın örnekleri ile ilgili bilgiler (Information on instances of each class in hyperspectral datasets)

Indian Pines (IP)			Salinas (SA)		Botswana (B)	
Sınıf Adı	Örnek	Sınıf Adı	Örnek	Sınıf Adı	Örnek	
 Yonca	46	Brokoli_yeşil_otlar_1	2009	Su	270	
 Mısır-işlenmemiş	1428	Brokoli_yeşil_otlar_2	3726	Su aygırı otu	101	
 Mısır-az işlenmiş	830	Nadas	1976	Taşkın yatağı otları 1	251	
 Mısır	237	Nadas_kaba_saban	1394	Taşkın yatağı otları 2	215	
 Çimen-Otlak	483	Nadas_düzgün	2678	Sazlık	269	
 Çimen-Ağaç	730	Anız	3959	Kıyıdaş	269	
 Çimen-Otlak (biçilmiş)	28	Kereviz	3579	Yangın izi	259	
 Saman	478	Üzümler_yetiştirilmemiş	11,271	Ada içi	203	
 Yulaf	20	Toprak_bağ_gelişen	6203	Akasya ormanları	314	
 Soya fasülyesi (işlenmemiş)	972	Mısır_yaşlanmış_yeşil_otlar	3278	Akasya çalıları	248	
 Soya fasülyesi (az işlenmiş)	2455	Roman_marulu_4 hafta	1068	Akasya otlakları	305	
 Soya fasülyesi	593	Roman_marulu_5 hafta	1927	Kısa mopane	181	
 Buğday	205	Roman_marulu_6 hafta	916	Karışık mopane	268	
 Odun	1265	Roman_marulu_7 hafta	1070	Açıkta kalan topraklar	95	
 Bina-çimen-ağaçlar-sürücüler	386	Bağ_yetiştirilmemiş	7268			
 Taş-çelik-kuleler	93	Bağ_dikey_çardak	1807			
Toplam Örnek Sayısı	10,249		54,129		3248	

HyRANK-Loukia (HL)					
Sınıf Adı	Örnek	Sınıf Adı	Örnek	Sınıf Adı	Örnek
 Yoğun kentsel yapı	288	 Geniş yapraklı orman	223	 Seyrek bitki örtüsü olan alanlar	404
 Mineral çıkarım sahaları	67	 İğne yapraklı orman	500	 Kayalar ve kum	487
 Sulanmayan ekilebilir arazi	542	 Karışık orman	1072	 Su	1393
 Meyve ağaçları	79	 Yoğun sklerofil bitki örtüsü	3793	 Kıyı suyu	451
 Zeytinlikler	1401	 Seyrek sklerofil bitki örtüsü	2803		
Toplam Örnek Sayısı					13,503

haritası ile sınıflandırma haritası arasında güçlü bir anlaşma ile ilgili karşılıklı bilgi sağlayan bir istatistiksel ölçüm metriğidir.

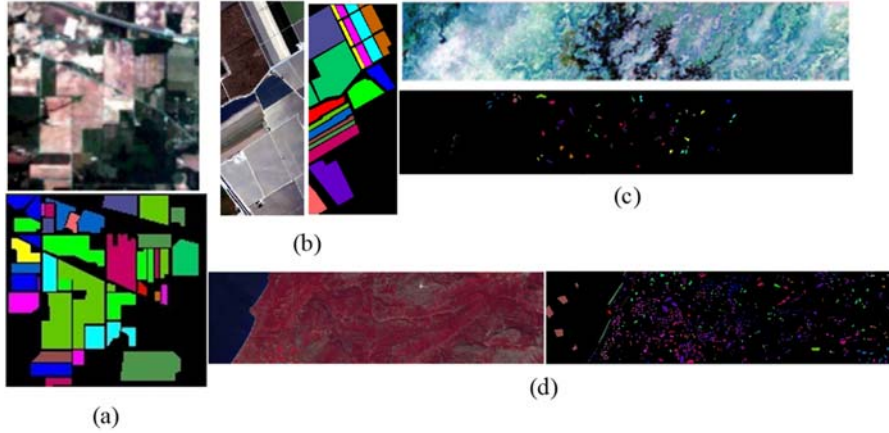
Tablo 2, IP veriseti kullanılarak LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 derin öğrenme mimarilerinin sınıf bazlı ve genel değerlendirme metriklerinin (GD, OD ve K) sonuçlarını göstermektedir. GD, OD ve K değerlendirme metrikleri incelendiğinde en iyi sonucun sırasıyla %99,77, %99,77, %99,74 ile VGG16 ve %99,71, %99,85, %99,67 ile ResNet50 mimarilerinde elde edildiği görülmektedir. Bu mimarilere en yakın sınıflandırma sonucu %99,58 GD, %99,68 OD ve %99,52 K ile AlexNet'te elde edilmiştir. 1, 7, 8, 13 ve 16 nolu sınıflarda tüm derin öğrenme mimarilerinde %100 sınıflandırma sonucu elde edilmiştir. 2 nolu sınıf için %99,77 ile VGG16, 3 nolu sınıf için %100 ile VGG16 ve ResNet50, 4 nolu sınıf için %100 ile AlexNet, VGG16, GoogleNet, ResNet50, 5 nolu sınıf için %100 ile LeNet5 ve ResNet50, 6 nolu sınıf için %100 ile AlexNet, 9 nolu sınıf için %100 ile AlexNet, VGG16, ResNet50, 10 ve 11 nolu sınıflar için %100 ile VGG16, 12 nolu sınıf için %100 ile LeNet5, VGG16, ResNet50, 14 nolu sınıf için %100 ile AlexNet ve ResNet50, 15 nolu sınıf için %100 ile LeNet5, AlexNet ve ResNet50 mimarilerinde en iyi sınıflandırma sonucu elde edilmiştir. IP veriseti için tüm mimariler göz önüne alındığında VGG16 ve ResNet50 gibi derin ağ mimarileri ile daha başarılı sınıflandırma sonuçlarının elde edildiği görülmektedir. VGG16, ResNet50'den farklı olarak atlama bağlantıları içermeyen geleneksel evrişim katmanları kullanmaktadır. Bu VGG16'nın tasarımının kolay olmasını sağlamak ve model eğitimi kolaylaştırmaktadır. ResNet50 mimarisi VGG16'ya göre daha fazla katmandan oluşmakta ve daha derindir. Ancak ResNet50 mimarisinde VGG16'dan farklı olarak eğitim sürecini düzenlemek için batch normalization katmanları kullanılmaktadır. VGG16 ile ResNet50'de OD değerleri göz önüne alındığında, ResNet50 ile çok az da olsa daha doğru özniteliklerin elde edildiği görülmektedir. Şekil

10'da tüm derin öğrenme mimarileri ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma haritaları gösterilmektedir. Şekil 10 incelendiğinde, VGG16 ve ResNet50 ile elde edilen sınıflandırma haritalarının ground truth'a oldukça yakın olduğu görülmektedir.


**Tablo 2.** IP verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%)  
(Classification results obtained using different deep learning architectures in IP dataset (%))

Sınıf	LeNet5	AlexNet	VGG16	GoogleNet	ResNet50
1	100	100	100	100	100
2	98,36	99,53	99,77	98,83	99,06
3	99,60	99,20	100	99,20	100
4	98,60	100	100	100	100
5	100	98,62	99,31	99,31	100
6	99,54	100	99,54	99,09	99,54
7	100	100	100	100	100
8	100	100	100	100	100
9	16,6	100	100	83,33	100
10	98,63	98,97	100	97,60	99,31
11	99,86	99,73	100	98,78	99,73
12	100	98,88	100	97,19	100
13	100	100	100	100	100
14	99,73	100	99,47	98,68	100
15	100	100	98,27	99,14	100
16	100	100	100	100	100
GD	99,32	99,58	99,77	98,76	99,71
OD	94,44	99,68	99,77	98,20	99,85
K	99,22	99,52	99,74	98,59	99,67

B verisetini kullanan beş derin öğrenme mimarisinin sınıf bazlı ve genel değerlendirme metriklerinin sınıflandırma sonuçları Tablo 3'te



**Şekil 9.** Verisetleri için sahte renkli (false-color) görüntü ve temel doğruluk (ground truth) haritaları. (a) Indian Pines (IP), (b) Salinas (SA), (c) Botswana (B), (d) HyRANK-Loukia (HL).  
(False-color images and ground truth maps for datasets. (a) Indian Pines (IP), (b) Salinas (SA), (c) Botswana (B), (d) HyRANK-Loukia (HL))



**Şekil 10.** IP veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50  
(Classification maps for the IP dataset. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50)

görülmektedir. Tablo 3 incelendiğinde, sınıf bazlı ve GD, OD ve K değerlendirme metriği açısından %100 ile en iyi sonuç VGG16 ve ResNet50 mimarilerinde elde edilmiştir. ResNet50 ve VGG16 ile karşılaştırıldığında, LeNet5 mimarisi ile GD, OD ve K açısından sırasıyla %0,41, %0,35, %0,44, AlexNet ile %0,31, %0,27, %0,33 ve GoogleNet ile %0,1, %0,25, %0,11 daha az sınıflandırma sonucunun elde edildiği görülmektedir. Bu sonuçlara bakıldığında ResNet50 ve VGG16 mimarilerine en yakın sınıflandırma sonuçları GoogleNet ile elde edilmiştir. LeNet5 ve AlexNet mimarileri ile 5 nolu sınıf için sırasıyla %95,06 ve %96,30 ile en kötü ve diğer tüm sınıflarda ise %100 ile en iyi sınıflandırma sonucu elde edilmiştir. GoogleNet mimarisi ile 14 nolu sınıf için %96,55 ile en kötü ve diğer tüm sınıflarda %100 ile en iyi sınıflandırma sonucu elde edilmiştir. B verisetinde toplam 3248 örnek bulunmaktadır. Sınıflandırma için kullanılan B veriseti kolay bir verisetidir. Bu verisetinde de derin ağ mimarileri diğer klasik ağ mimarilerinden daha iyi sonuç verdiği görülmektedir. Düşük örnek sayısına sahip B veriseti için VGG16 ve ResNet50 ile daha doğru özneteliklerin elde edildiği sonucu çıkarılabilmektedir. Tüm mimariler ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma haritaları Şekil 11'de gösterilmektedir. Şekil 11'e göre VGG16 ve ResNet50 mimarilerinin sınıflandırma haritası ground truth ile aynı, diğer mimarilerden GoogleNet'in ground truth'a oldukça yakın olduğu görülmektedir.

HL veriseti kullanılarak elde edilen sınıflandırma sonuçları Tablo 4'te gösterilmektedir. GD, OD ve K değerlendirme metrikleri göz önüne alındığında sırasıyla %98,86, %97,92 ve %98,65 ile en iyi sonuçların VGG16 ile elde edildiği görülmektedir. VGG16'ya en yakın sonuçlar %97,93, %97,71 ve %97,54 ile ResNet50 mimarisi ile yapılan uygulamalarda elde edilmiştir. Sınıf bazlı performanslar incelendiğinde ise, 2, 13 ve 14 nolu sınıflar için tüm mimarilerde %100 ile en iyi sınıflandırma sonuçları elde edilmiştir. 1 nolu sınıf için %97,67 ile LeNet5 ve VGG16, 3 nolu sınıf için %99,39 ile ResNet50, 4 nolu sınıf için %95,83 ile ResNet50, 5 ve 11 nolu sınıflar için %100 ile VGG16, 6, 7, 8, 9 ve 10 nolu sınıflar için sırasıyla %97,01, %98, %99,38, %98,77, %97,98 ile VGG16, 12 nolu sınıf için %100 ile LeNet5, AlexNet, VGG16 ve ResNet50 mimarilerinde en iyi sınıflandırma sonuçları elde edilmiştir. HL verisetinde de B ve IP


verisetlerinde olduğu gibi, derin ağ mimarileri ile daha iyi sonuçların elde edildiği görülmektedir. Derin ağ mimarilerinden VGG16'nın test doğruluğu ResNet50'den %0,93 GD, %0,21 OD ve %1,11 K değeri ile daha yüksek elde edilmiştir. VGG16'nın çok az da olsa ResNet50'den daha iyi sonuç vermesi, katman sayısının az olması ve ResNet50'ye göre daha sığ mimari olması ile açıklanabilmektedir. VGG16 ve ResNet50'de OD değerleri birbirine oldukça yakındır. OD değerlerinde, her iki mimaride de her sınıf için doğru sınıflandırma sayısının birbirine yakın olduğu sonucu çıkarılabilmektedir. Böyle bir veriseti için her iki mimari ile daha doğru ve daha ayırt edici öznetelikler elde edileceğini göstermektedir. Tüm derin öğrenme mimarileri ile elde edilen sınıflandırma haritaları Şekil 12'de gösterilmektedir. Ground truth'a en yakın sınıflandırma haritası sonucu VGG16 ve ResNet50 ile elde edilmiştir.

**Tablo 4.** HL verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%) (Classification results obtained using different deep learning architectures in HL dataset (%))

Sınıf	LeNet5	AlexNet	VGG16	GoogleNet	ResNet50
1	97,67	93,02	97,67	95,35	95,35
2	100	100	100	100	100
3	98,16	96,32	98,77	95,09	99,39
4	62,5	91,66	83,33	87,5	95,83
5	99,29	97,14	100	98,09	98,81
6	76,12	74,63	97,01	80,60	91,04
7	88	88,66	98	90,66	94,67
8	98,14	95,34	99,38	96,58	98,45
9	97,01	96,75	98,77	96,22	97,72
10	94,17	89,89	97,98	97,03	96,67
11	98,35	96,69	100	96,69	100
12	100	100	100	97,94	100
13	100	100	100	100	100
14	100	100	100	100	100
GD	96,49	95,04	98,86	96,64	97,93
OD	93,53	94,29	97,92	95,13	97,71
K	95,84	94,10	98,65	96,02	97,54

**Tablo 3.** B verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%) (Classification results obtained using different deep learning architectures in B dataset (%))


Mimari	1	2	3	4	5	6	7	8	9	10	11	12	13	14	GD	OD	K
LeNet5	100	100	100	100	95,06	100	100	100	100	100	100	100	100	100	99,59	99,65	99,56
AlexNet	100	100	100	100	96,30	100	100	100	100	100	100	100	100	100	99,69	99,73	99,67
VGG16	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
GoogleNet	100	100	100	100	100	100	100	100	100	100	100	100	100	96,55	99,90	99,75	99,89
ResNet50	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100



**Şekil 11.** B veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50 (Classification maps for the B dataset. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50)

Tablo 5, SA veriseti kullanılarak beş farklı derin öğrenme mimarisi ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçlarını göstermektedir. GD, OD ve K değerlendirme metrikleri ve sınıf bazlı performanslar göz önüne alındığında %100 ile en iyi sonuçların LeNet5 ve VGG16'da elde edildiği görülmektedir. Diğer mimarilerden LeNet5 ve VGG16'ya en yakın sınıflandırma sonucu ResNet50 ile elde edilmiştir. Ancak AlexNet ve GoogleNet ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçlarının da LeNet5 ve VGG16'ya oldukça yakın olduğu görülmektedir. Sınıf bazlı değerlendirme yapıldığında ise, 4 nolu sınıf için %99,52 ve %99,76 ile AlexNet ve ResNet50, 5 nolu sınıf için %99,87, %99,75 ve %99,87 ile AlexNet, GoogleNet ve ResNet50, 6 nolu sınıf için %99,92 ile GoogleNet, 8 nolu sınıf için %99,97 ile AlexNet ve GoogleNet, 15 nolu sınıf için %99,91 ve %99,95 ile AlexNet ve GoogleNet mimarilerinde en kötü sınıflandırma sonuçları elde edilmiştir. SA veriseti 54,129 örnek içermektedir. Ancak, bu veriseti de B verisetinde olduğu gibi sınıflandırma için kullanılan

kolay bir verisetidir. SA verisetinde, beş farklı mimari ile de elde edilen sonuçlar birbirine oldukça yakındır. LeNet5 ile %100 sonuç elde edilmesinin nedeni olarak Bölüm 2'de açıklandığı üzere katman sayısının az olması, oldukça basit bir tasarımının olması ve eğitilebilir parametre sayısının oldukça az olmasından kaynaklanmaktadır. Eğitilebilir parametre sayısının az olması eğitimi hızlandırmakta ve sınıflandırma doğruluğunu arttırmaktadır. VGG16 ise LeNet5 ve AlexNet'e göre daha fazla evrişim katmanından oluşmakta ve daha derindir. Ayrıca, ilk birkaç katmanda daha küçük alıcı alanlara (receptive fields) sahip bir evrişimsel katman yığını kullanılmaktadır. Aynı zamanda VGG16'da tüm evrişim katmanları sıralıdır. Bu modelin daha kolay eğitilmesini sağlamaktadır. SA veriseti kullanılarak elde edilen sınıflandırma haritaları Şekil 13'te gösterilmektedir. Şekil 13 incelendiğinde LeNet5 ile VGG16 mimarilerinin ground truth ile aynı olduğu, diğer mimariler ile de ground truth'a oldukça yakın sınıflandırma haritaları elde edildiği görülmektedir.




Şekil 12. HL veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50 (Classification maps for the HL dataset. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50)

Tablo 5. SA verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%) (Classification results obtained using different deep learning architectures in SA dataset (%))

Sınıf	LeNet5	AlexNet	VGG16	GoogleNet	ResNet50
1	100	100	100	100	100
2	100	100	100	100	100
3	100	100	100	100	100
4	100	99,52	100	100	99,76
5	100	99,87	100	99,75	99,87
6	100	100	100	99,92	100
7	100	100	100	100	100
8	100	99,97	100	99,97	100
9	100	100	100	100	100
10	100	100	100	100	100
11	100	100	100	100	100
12	100	100	100	100	100
13	100	100	100	100	100
14	100	100	100	100	100
15	100	99,91	100	99,95	100
16	100	100	100	100	100
GD	100	99,96	100	99,97	99,99
OD	100	99,95	100	99,97	99,98
K	100	99,96	100	99,97	99,99





**Şekil 13.** SA veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50  
(Classification maps for the SA dataset. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50)

## 5. Sonuçlar (Conclusions)

Hiperspektral görüntü sınıflandırması için, 2B evrişim işlemi giriş verilerini uzamsal boyutta evrişim işlemine tabi tutarken, 3B evrişim işlemi giriş verilerini hem uzamsal hem de spektral boyutta eş zamanlı olarak evrişim işlemine tabi tutmaktadır. 2B evrişim işlemi, ister 2B veriye ister 3B veriye uygulanıp uygulanmadığına bakılmaksızın, çıktısı 2B'dir. Hiperspektral görüntüye 2B evrişim işlemleri uygulandığında önemli spektral bilgiler kaybedilirken, 3B evrişim giriş hiperspektral görüntü verilerinin spektral bilgilerini koruyarak bir çıktı hacmi elde edebilmektedir. Bu, zengin spektral bilgi içeren hiperspektral görüntüler için çok önemlidir. Bu durum göz önünde bulundurularak bu çalışmada, hiperspektral görüntülerin sınıflandırılması için 3B ESA tabanlı LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 derin öğrenme mimarilerinin sınıflandırma performansları karşılaştırılmaktadır. Ayrıca, hiperspektral görüntülerdeki spektral fazlalığı gidermek için TBA boyut indirgeme yöntemi kullanılmaktadır. Indian pines, Salinas, Botswana ve HyRANK-Loukia verisetleri kullanılarak 3B ESA tabanlı bu beş derin öğrenme mimarisi ile uygulamalar gerçekleştirilmiştir. Gerçekleştirilen uygulamalar sonucunda GD, OD ve K değerlendirme metrikleri göz önüne alınarak, Salinas verisinde %100 ile LeNet5 ve VGG16, HyRANK-Loukia verisinde sırasıyla %98,86, %97,92, %98,65 ile VGG16, Botswana verisinde %100 ile ResNet50, Indian pines verisinde sırasıyla %99,77, %99,77, %99,74 ile VGG16 derin öğrenme mimarisinde en iyi sınıflandırma doğrulukları elde edilmiştir. Gelecek çalışmalarda hiperspektral görüntü sınıflandırması için, (1) derin öğrenmenin kodlayıcı-kod çözücü mimarileri ile derinlemesine ayrılabilir evrişim ve dilated evrişim, (2) derin öğrenme ile birlikte metazezgisel yöntemlerin [31-32] kullanılması planlanmaktadır.

## Kaynaklar (References)

- Meng Z., Li L., Tang X., Feng Z., Jiao L. ve Liang M., Multipath residual network for spectral-spatial hyperspectral image classification, *Remote Sensing*, 11 (16), 1–19, 2019.
- Jia J., Wang Y., Chen J., Guo R., Shu R. ve Wang J., Status and application of advanced airborne hyperspectral imaging technology: A review, *Infrared Physics and Technology*, 104, 103115, 2020.
- Mohan A. ve Meenakshi Sundaram V., V3O2: hybrid deep learning model for hyperspectral image classification using vanilla-3D and octave-2D convolution, *Journal of Real-Time Image Processing*, 18, 1681-1695, 2021.
- Gowtham B., Kumar I.A., Reddy T.S., Harikiran J. ve Chandana B.S., Hyperspectral Image Analysis using Principal Component Analysis and Siamese Network, *Turkish Journal of Computer and Mathematics Education*, 12 (7), 1191–1198, 2021.
- Mohan ve Venkatesan M., HybridCNN based hyperspectral image classification using multiscale spatiospectral features, *Infrared Physics and Technology*, 108, 103326, 2020.
- Ham J. S., Chen Y., Crawford M.M. ve Ghosh J., Investigation of the random forest framework for classification of hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 43 (3), 492–501, 2005.
- Melgani F. ve Bruzzone L., Classification of Hyperspectral Remote Sensing Images With Support Vector Machines, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 1778–1790, 2004.
- Li J., Bioucas-Dias J.M. ve Plaza A., Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning, *IEEE Transactions on Geoscience and Remote Sensing*, 48 (11), 4085–4098, 2010.
- Palmason J.A., Benediktsson J.A. ve Sveinsson J.R., Classification of hyperspectral data from urban areas based on extended morphological profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 43 (3), 480–491, 2005.
- Camps-Valls G. ve Bruzzone L., Kernel-based methods for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 43 (6), 1351–1362, 2005.
- Fang L., Li S., Duan W., Ren J. ve Benediktsson J.A., Classification of Hyperspectral Images by Exploiting Spectral-Spatial Information of Superpixel via Multiple Kernels, *IEEE Transactions on Geoscience and Remote Sensing*, 53 (12), 6663–6674, 2015.
- Fang L., Li S., Kang X. ve Benediktsson J.A., Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation, *IEEE Transactions on Geoscience and Remote Sensing*, 52 (12), 7738–7749, 2014.
- Fauvel M., Chanussot J. ve Benediktsson J.A., A spatial-spectral kernel-based approach for the classification of remote-sensing images, *Pattern Recognition*, 45(1), 381–392, 2012.
- Yang X., Ye Y., Li X., Lau R. Y. K., Zhang X. ve Huang X., Hyperspectral image classification with deep learning models, *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5408–5423, 2018.
- Data H., Deep Learning-Based Classification of Hyperspectral Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, 1–14, 2015.
- Roy S.K., Krishna G., Dubey S.R. ve Chaudhuri B.B., HybridSN: Exploring 3D-2D CNN Feature Hierarchy for Hyperspectral Image Classification, *arXiv*, 17 (2), 277–281, 2019.
- Mingyi He H.C., Li B., Multi-scale 3D deep convolutional neural network for hyperspectral image classification, 2017 IEEE International Conference on Image Processing, Beijing-China, 3904–3908, 17-20 September, 2017.
- Song L., Li W., Fang S., Hyperspectral Image Classification with Deep Feature Fusion Network, *IEEE Transactions on Geoscience and Remote Sensing*, 99, 3173–3184, 2018.
- Ge Z., Cao G., Li X. ve Fu P., 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*, 13, 5776–5788, 2020.
- LeCun Y., Bottou L., Bengio Y. ve Haffner P., Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278–2323, 1998.
- Krizhevsky A., Sutskever I. ve Hinton G.E., ImageNet Classification with Deep Convolutional Neural Networks, in *International Conference on Neural Information Processing Systems*, 1097–1105, 2012.
- Szegedy C., Going deeper with convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston-USA, 1–9, 7-12 June, 2015.

23. He K., Zhang X., Ren S. ve Sun J., Deep residual learning for image recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas-USA, 770-778, 26 June-01 July, 2016.
24. Firat H. ve Hanbay D., Classification of Hyperspectral Images Using 3D CNN Based ResNet50, 29th Signal Processing and Communications Applications Conference, Istanbul-Turkey, 6-9, 9-11 June, 2021.
25. Shehab L.H., Fahmy O.M., Gasser S.M. ve El-Mahallawy M.S., An efficient brain tumor image segmentation based on deep residual networks (ResNets), Journal of King Saud University - Engineering Sciences, 1-9, 2020.
26. Simonyan K. ve Zisserman A., Very deep convolutional networks for large-scale image recognition, 3rd International Conference on Learning Representations, San Diego-USA, 1-14, 7-9 May, 2015.
27. Firat H. ve Hanbay D., 4CF-Net: New 3D convolutional neural network for spectral spatial classification of hyperspectral remote sensing images, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (1), 439-454, 2022.
28. Grupo De Inteligencia Computacional (GIC). Hyperspectral Remote Sensing Scenes. [http://www.ehu.eus/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes), Erişim tarihi Temmuz 15,2021. The ISPRS HyRank Benchmark. The HyRank Hyperspectral Dataset and Benchmark Framework. <https://www2.isprs.org/commissions/comm3/wg4/hyrank>, Erişim tarihi Temmuz 15,2021.
29. Dou P. ve Zeng C., Hyperspectral image classification using feature relations map learning, Remote Sensing, 12 (18), 2020.
30. Firat Hü., Asker M.E., Hanbay D., Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN, Remote Sensing Applications:Society and Environment, 2022.
31. Canayaz M., MH-COVIDNet:Diagnosis of COVID-19 using deep neural networks and meta-heuristic-based feature selection on X-ray images, Biomedical Signal Processing and Control, 64, 102257, 2021.
32. Abd Elaziz M., Dahou A., Abualigah L., Advanced metaheuristic optimization techniques in applications of deep neural networks: a review., Neural Computing and Applications, 33, 14079-14099, 2021.