

FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI



OKAN ÜNİVERSİTESİ  
İSTANBUL

UZAKTAN ALGILANMIŞ HİPERSPEKTRAL GÖRÜNTÜLERİN  
UZAMSAL-İZGESEL PİKSEL SINIFLANDIRMASI

YÜKSEK LİSANS TEZİ

YAVUZ KÖMEÇOĞLU

tarafından

YÜKSEK LİSANS

derecesi şartını sağlamak için hazırlanmıştır.

HAZİRAN 2018

Program: Bilgisayar Mühendisliği Yüksek Lisans

UZAKTAN ALGILANMIŞ HİPERSPEKTRAL GÖRÜNTÜLERİN  
UZAMSAL-İZGESEL PİKSEL SINIFLANDIRMASI

YÜKSEK LİSANS TEZİ

YAVUZ KÖMEÇOĞLU

tarafından

OKAN ÜNİVERSİTESİ

Bilgisayar Mühendisliği Ana Bilim Dalına

Yüksek Lisans

derecesi şartını sağlamak için sunulmuştur.

Onaylayan:

---

Danışman  
Doç. Dr. Erchan Aptoula  
Gebze Teknik Üniversitesi

---

Üye  
Doç. Dr. Pınar Yıldırım  
Okan Üniversitesi

---

Üye  
Dr. Öğr. Üyesi Rüyam Acar  
Okan Üniversitesi

---

HAZİRAN 2018

Program: Bilgisayar Mühendisliği Yüksek Lisans

## ÖZET

Uzaktan algılanan hiperspektral görüntülerin sınıflandırılması son yıllarda birçok araştırmanın konusu olmuştur. Hiperspektral görüntüler sivil ve askeri alanda, tarım, yer bilimi, tıp, savunma ve güvenlik, hedef belirleme, şehir planlama gibi farklı disiplinlerdeki birçok alanda kullanılmaktadır.

Bu tez çalışmasında uzaktan algılanan hiperspektral görüntünün her bir pikseline uygun bir sınıf etiketi atanması probleminde, Yansıtıcı Optik Sistem Görüntüleme Spektrometresi (YOSGS) sensörüne ait Pavia Üniversitesi veri seti üzerinde, hiperspektral verinin spektral (izgesel) bilgisi ile birlikte uzamsal bilginin ayrı ayrı ve birlikte kullanılmasının evrimsel sinir ağları ile eğitilerek sınıflandırma başarılarına etkileri incelenmiştir. Ayrıca sadece spektral bilgiyi içeren vektörler ile uzamsal bilgiyi de içeren tensörler aynı anda farklı evrimsel sinir ağları ile eğitilmiş ve kaynaştırma yönteminin sınıflandırma başarımına etkisi incelenmiş ve karşılaştırmalar yapılmıştır.

**Anahtar Kelimeler:** Uzaktan Algılama, Hiperspektral Görüntüleme, Derin Öğrenme, Evrimsel Sinir Ağları

## ABSTRACT

Classification of remotely sensed hyperspectral images has been the subject of many researchers in recent years. Hyperspectral imagery is used in many disciplines such as civil and military field, agriculture, location science, medicine, defense and security, goal setting, city planning.

In this thesis, assigning a class tag to each pixel of the remotely sensed hyperspectral view was applied to the Pavia University dataset of the ROSIS sensor and spectral (spectral) information of hyperspectral data and the spatial and temporal effects of spatial and temporal information on the success of classifications in training with neural networks. Furthermore, only the vectors containing spectral information and the tensors including spatial information are trained with different convolutional neural networks at the same time and the effect of the fusing method on the classification performance was examined and compared.

**Keywords:** Remote Sensing, Hyperspectral Imaging, Deep Learning, Convolutional Neural Networks

## TEŞEKKÜR

Bu çalışmanın gerçekleşmesinde, rehberliđi, deđerli önerileri ve katkıları için danışmanım Sayın Doç. Dr. Erchan Aptoula'a ve arařtırmalarım sırasında sabır ve sürekli destekleri için aileme teşekkürlerimi sunarım.



# İÇİNDEKİLER

TABLO LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
KISALTMALAR.....	xi
I. GİRİŞ.....	1
1.1. Motivasyon ve Kapsam .....	2
1.2. Tezin Organizasyonu .....	2
II. UZAKTAN ALGILAMA VE DERİN ÖĞRENME.....	4
2.1. Uzaktan Algılama .....	4
2.2. Hiperspektral Görüntüleme.....	5
2.2.1. Hiperspektral verilerin gösterimi .....	7
2.2.1.1. Görüntü uzayında gösterim.....	8
2.2.1.2. Spektral uzayda gösterim.....	9
2.2.2. Hiperspektral görüntülerin kullanım alanları.....	11
2.3. Derin Öğrenme .....	13
2.3.1. Evrişimsel sinir ağları (Convolutional neural networks).....	14
2.3.1.1. Evrişim katmanı .....	14
2.3.1.2. Ortaklama katmanı (Pooling layer).....	15
2.3.1.3. Tam bağlantılı katman (Fully connected layer) .....	16
2.3.2. Etkileşim fonksiyonları (Activation functions) .....	16
2.3.3. Softmax .....	21
2.3.4. Yitim fonksiyonu, eğim düşümü ve geri yayılım algoritması .....	21
2.3.5. Caffè.....	23
2.3.6. Başarı ölçülmesinde kullanılan metrikler .....	23
2.4. Literatür İncelemesi .....	24

III. Problemin Tanımı ve Hipotez.....	30
IV. YÖNTEM.....	31
4.1. Veriseti.....	31
4.2. Hiperspektral Görüntülerde Uzamsal ve İzgesel (Spektral) Piksel Sınıflandırma.....	33
4.2.1. Bir boyutlu piksel vektörleri ile sınıflandırma.....	34
4.2.2. Uzamsal bilgiden yararlanılarak sınıflandırma.....	35
4.2.3. TBA ile boyut indirgenmiş görüntüler ile sınıflandırma.....	37
4.2.4. Farklı ölçekli yamaların kaynaştırılması ile sınıflandırma.....	39
4.2.5. Farklı ölçekli yamaların kaynaştırılması ile sınıflandırma.....	41
4.2.6. Çalışma ortamı.....	41
V. SONUÇLAR.....	42
5.1. Spektral İmzalar ile.....	42
5.2. Spektral ve Uzamsal İmzalar ile.....	42
5.3. Temel Bileşenler Analizi ile.....	43
5.4. Spektral ve Uzamsal İmzalarla Farklı Ölçekli Kaynaştırma ile.....	44
5.5. Veri Arttırılmış Spektral ve Uzamsal İmzalar ile.....	44
5.6. Veri Arttırılmış Spektral ve Uzamsal İmzalarla Farklı Ölçekli Kaynaştırma ile.....	46
5.7. Tartışma.....	53
VI. GELECEK ÇALIŞMALAR.....	54
KAYNAKÇA.....	55
ÖZGEÇMİŞ.....	61

## TABLO LİSTESİ

Tablo 4.1. Pavia Üniversitesi Veri Seti.....	31
Tablo 5.1. Deney 1 Sonuçları .....	42
Tablo 5.2. Deney 2 Sonuçları .....	43
Tablo 5.3. Deney 3 Sonuçları .....	43
Tablo 5.4. Deney 4 Sonuçları .....	44
Tablo 5.5. Deney 5 Sonuçları .....	44
Tablo 5.6. Deney 6 Sonuçları .....	45
Tablo 5.7. Deney 7 Sonuçları .....	46
Tablo 5.8. Tüm Deney Sonuçları.....	52



## ŞEKİL LİSTESİ

Şekil 2.1 . Uzaktan Algılama Süreci.....	4
Şekil 2.2. Hiperspektral Görüntüleme'deki Maddelere Ait Spektral İmzalar.....	6
Şekil 2.3. Elektromanyetik Spektrum .....	7
Şekil 2.4. KYM Uzayında Gösterim.....	8
Şekil 2.5. Hiperspektral Küp Gösterimi.....	9
Şekil 2.6. Farklı Maddelere Ait Spektral İmzalar .....	10
Şekil 2.7. Sigmoid Fonksiyonu Grafiği .....	17
Şekil 2.8. Tanh Fonksiyonu Grafiği.....	18
Şekil 2.9. DDB Fonksiyonu Grafiği .....	19
Şekil 2.10. Sızıntılı DDB Fonksiyonu Grafiği.....	20
Şekil 4.1. Pavia Üniversitesi Veriseti Renkli Görüntü ve Yer Gerçeği.....	32
Şekil 4.2. Pavia Üniversitesi Veriseti Test Pikselleri ve Eğitim Pikselleri Resmi .....	32
Şekil 4.3. Girdisi Spektral Vektörler Olan ESA Ağı .....	34
Şekil 4.4. Girdisi Yama Olan ESA Ağı .....	36
Şekil 4.5. Pavia Üniversitesi TBA ile İndirgen 4 Bantın Görüntüleri .....	38
Şekil 4.6. Spektral Vektörlerin ve Yamaların Aynı Anda Eğitilip Kaynaştırıldığı ESA Modeli .....	39
Şekil 4.7. Farklı Boyutlardaki Yamaların Aynı Anda Eğitilip Kaynaştırıldığı ESA Modeli .....	40
Şekil 5.1. Deney Sonuçlarının Sınıflandırma Haritaları .....	48
Şekil 5.2. 1x103 Giriş Datasınının Karışıklık Matrisi .....	49

Şekil 5.3. 5x5x103 Giriş Datasının Karışıklık Matrisi .....	50
Şekil 5.4. 9x9x103 Giriş Datasının Karışıklık Matrisi .....	51



## KISALTMALAR

BGÖM	Berkeley Görme ve Öğrenim Merkezi
ESA	Evrişimsel Sinir Ağları
HSG	Hiperspektral Görüntü
DDB	Düzeltilmiş Doğrusal Birim (Rectified Linear Unit)
KYM	Kırmızı-Yeşil-Mavi (Red-Green-Blue)
YOSGS	Yansıtıcı Optik Sistem Görüntüleme Spektrometresi (Reflective Optics System Imaging Spectrometer - ROSIS)
TBA	Temel Bileşenler Analizi
YSA	Yapay Sinir Ağları

## I. GİRİŞ

Hiperspektral görüntülerin geniş spektrum bantlarından dolayı çok fazla sayıda bilgi içermesi, uzaktan algılama alanında yapılan birçok araştırma için temel motivasyon kaynağı olmuştur. Özellikle uzaktan algılanan hiperspektral görüntülerin spektral (izgesel)-uzamsal sınıflandırılması son yıllarda birçok araştırmanın konusu olmuştur.

Yüzlerce dar ve bitişik bantla elektromanyetik spektrum bilgisini toplayan hiperspektral görüntüleme teknolojisinin, farklı objeleri benzersiz spektral imzalara göre ayırt edebilme yeteneğine sahip olması gibi avantajlarının yanı sıra; bu bantlar arasındaki yüksek korelasyona bağlı olarak sınıflandırma karmaşıklığına sahip olması gibi dezavantajları da mevcuttur.

Tez çalışmasının temel motivasyonunu oluşturan hiperspektral görüntülerin piksel sınıflandırılması probleminde spektral (izgesel) ve uzamsal olmak üzere iki temel yaklaşımdan bahsetmek mümkündür.

Spektral (izgesel) sınıflandırma yaklaşımında, pikseller birbirinden bağımsızdır ve sınıflandırma yapmak için yalnızca mevcut etiketlere sahip pikseller kullanılmaktadır. Uzamsal yaklaşımda ise, etiketli piksellerin komşuluk bilgisi de kullanılabilir. Böylelikle sınıflandırma için hem etiketlenmiş hem de etiketlenmemiş pikseller kullanılması mümkün olmaktadır.

Tez çalışması kapsamında piksel sınıflandırılması probleminin amacı olan, uzaktan algılanan hiperspektral görüntünün her bir pikseline uygun bir sınıf etiketi atama görevi için hiperspektral görüntülerin en büyük avantajı olan spektral (izgesel) bilgiye uzamsal bilgi de dahil edilmiştir ve uygun farklı mimariler literatürde önemli yere sahip Pavia

Üniversitesi veri kümesi üzerinde uygulanmış, sonuçları karşılaştırılmış ve yorumlanmıştır.

### **1.1. Motivasyon ve Kapsam**

Hiperspektral görüntüleme yüksek önem taşıyan sınıflandırma görevinde, sınırlı sayıda etiketlenmiş olan alanın sınıflandırma haritasını oluşturmaya yönelik çözümler sunulmaktadır.

Spektral olarak yüksek çözünürlüğe sahip olan hiperspektral görüntülerin sınıflandırılması, düşük uzlamsal çözünürlüğe sahip ve yüksek boyutlu olmasının haricinde artık bilgi içermesi, etiketlenmiş eğitim ve test verisi miktarındaki dengesiz dağılımlar gibi sebeplerden dolayı zorlaşmaktadır.

Sınıflandırma problemini zorlaştıran etmenler yalnızca verinin yapısı ile ilgili değil, çevresel faktörlere bağlı da olabilir. Bu faktörler ise nesnelerin farklı meteorolojik ve aydınlatma koşulları altında, farklı lokasyonlarda bulunması ve görüntülerin farklı sensörlerden elde edilmesi v.b. olabilir. Bahsedilen tüm bu faktörler nedeniyle aynı nesne için farklı spektral imzalar üretilmektedir.

Bu tez çalışması kapsamında, sonraki kullanımlar için görüntünün tamamını en doğru şekilde sınıflandırarak bir sınıflandırma haritası oluşturmak amacıyla piksel sınıflandırma problemine odaklanılmıştır.

### **1.2. Tezin Organizasyonu**


Tez çalışmasında, 1. Bölüm ile konuya genel bir giriş yapılarak, tez çalışmasının motivasyonu ve kapsamından bahsedilmiş ve son olarak tezin organizasyonu hakkında bilgi verilmiştir. 2. Bölüm'e uzaktan algılama süreci, hiperspektral görüntüleme

teknolojisi, hiperspektral görüntülerin gösterim şekilleri ve kullanım alanları detaylı olarak anlatılarak başlangıç yapılmıştır. Bölümün devamında derin öğrenme olarak isimlendirilen çok katmanlı yapay sinir ağlarından ve çalışmada kullanılan kütüphane, fonksiyon ve algoritmalarından bahsedilmiştir. Bölüm sonunda ise benzer çalışmalarla ilgili literatür analizine yer verilmiştir. 3. Bölüm’de tez konusunu oluşturan piksel sınıflandırma probleminin tanımı ve hipotezlere yer verilmiştir. Hemen ardından gelen 4. Bölüm’de tez kapsamında kullanılmış olan ve hiperspektral görüntü sınıflandırma çalışmalarında da oldukça sık kullanılan, literatürde önemli bir yere sahip Pavia Üniversitesi veri kümesi tanıtılmış ve sınıflandırma probleminin çözümüne yönelik spektral ve uzamsal bilgiden faydalanılan yöntemlerden bazıları anlatılmıştır. 5. Bölüm’de ise bir önceki bölümde bahsedilen yöntemler ile yapılan farklı deneylerin sonuçları sınıflandırma haritalarıyla birlikte sunulmuş sonuçlar değerlendirilmiştir. Son olarak 6. Bölüm’de ise gelecekte yapılacak çalışmalar için önerilerde bulunulmuştur.

## II. UZAKTAN ALGILAMA VE DERİN ÖĞRENME

### 2.1. Uzaktan Algılama

Uzaktan algılama, incelenen nesne, alan veya olay ile doğrudan fiziksel teması olmayan belirli bir cihaz veya sensör tarafından toplanan verilerin analiz edilmesi yoluyla bilgi alma, değerlendirme gibi işlevleri gerçekleştirmeye yönelik tasarlanmış teknikler olarak tanımlanmaktadır. Bu süreç Şekil 2.1’de gösterildiği şekilde gerçekleşmektedir. Günümüzde jeoloji, hidrojeoloji, meteorolojik, çevre değişimi, haritacılık, arazi örtüsü gibi yer küre ile uğraşan tüm bilim dallarında etkili bir şekilde kullanılan uzaktan algılama alanında yaşanan devrim niteliğindeki gelişmeden biri de hiperspektral görüntüleme ve ilgili analiz teknikleridir.



Şekil 2.1 . Uzaktan Algılama Süreci<sup>1</sup>

<sup>1</sup> Esat, K. (2005). Uydu Görüntüleri ve Jeolojideki Kullanımlarına Genel Bakış. *Mavi Gezegen Popüler Yer Bilim Dergisi*, 11, 37 [1].

Uzaktan algılama teknolojisinin bir parçası olarak kabul edilen hiperspektral görüntüleme, klasik görüntüleme tekniklerinden farklı olarak tek veya az sayıda bant yerine, mor ötesinden uzak kızıl ötesine geniş bant aralığında, yüzlerce dar ve bitişik bantta görüntü toplayabilmektedir.


## **2.2. Hiperspektral Görüntüleme**

Uzaktan algılama fiziksel bir temas olmaksızın, yansıyan ve yayılan enerjinin kaydı ve analizi ile; ulaşılması ve görüntülenmesi zor olan yerkürenin herhangi bir yeri veya nesnelerin gözle görülmeyen özellikleri hakkında ayrıntılı bilgi almaya olanak sağlar. Bitki tipini ayırmada, maden ve yeryüzü kaynaklarının aranmasında, buz erimesi ve buz hareketini gözlemede, gemi atıklarını izlemede, kıyı alanlarının değişiminin izlenmesinde, orman yangınlarının izlenmesinde, arazi örtüsünün belirlenmesinde ve bunlara benzer birçok uygulamada uzaktan algılama etkili bir biçimde kullanılmaktadır. Hiperspektral görüntülerin analiziyle, tek bir pikselden o pikseldeki materyalin ne olduğu anlaşılabilir. Bu özelliğiyle hiperspektral görüntüleme, yeryüzünün uzaktan algılanmasını gerektiren jeoloji, zirai ve askeri alanlarda, özellikle sınıflandırma ve hedef tespiti uygulamalarında tercih edilen bir yöntem olmaktadır. Bir malzemenin yansıyan, soğrulan veya iletilen ışınım miktarlarının dalga boyuna göre elde edilen oranın eğrisine spektral imza adı verilmektedir. Şekil 2.2’de hiperspektral imza örnekleri görülmektedir.





- 3000-5000 nm bant aralığında orta-dalga kızılötesi bantındaki görüntüler ile savunma sanayinde hedef tespiti, jeolojide gaz, petrol gibi alanlarda yapılan uygulamalar,
- 8000-12000 nm bant aralığında uzun-dalga kızılötesi bandındaki görüntüleri ile minerallerin haritalandırılması ve kamuflej tespiti gibi alanlarda yapılan uygulamalar örnek olarak verilebilir.



Şekil 2.3. Elektromanyetik Spektrum<sup>3</sup>

### 2.2.1. Hiperspektral verilerin gösterimi

Hiperspektral verilerin analizi için matematiksel ve kavramsal olarak çeşitli gösterim uzayları mevcuttur [31]. Multispektral ve hiperspektral verilerin nicelik ve görsel

<sup>3</sup> Gur, D., Leshem, B., Pierantoni, M., Farstey, V., Oron, D., Weiner, S., & Addadi, L. (2015). Structural basis for the brilliant colors of the sapphirinid copepods. *Journal of the American Chemical Society*, 137(26), 8408-8411 [3].

sunumunda kullanılan ve temel kabul edilen gösterim şekilleri bu bölümde anlatılmaktadır.

### 2.2.1.1. Görüntü uzayında gösterim

Kırmızı-Yeşil-Mavi (KYM) görüntü uzayında görsel olarak sahnenin uzamsal değişimi ve her bir sınıfa ait pikselin kendi ait olduğu sınıf ile ilişkisi kolayca gözlemlenebilir. KYM uzayında her bir renk katmanı için hiperspektral görüntünün bir bandı seçilerek yapay bir görüntü oluşturulur. Bununla birlikte KYM görüntüler seçilen bantlara bağlı olarak sadece bu üç bandın uzamsal bilgisini taşırlar.




Şekil 2.4. KYM Uzayında Gösterim<sup>4</sup>

Şekil 2.4’de belirlenen bantların KYM uzayında gösterimi ile elde edilen yapay resim KYM görüntülerin yanı sıra hiperspektral görüntülerde uzamsal ve spektral bilgileri birleştiren hiperspektral küpler de oldukça yoğun olarak kullanılır. Hiperspektral

---

<sup>4</sup> Medjahed, S. A., Saadi, T. A., Benyettou, A., & Ouali, M. (2016). Gray Wolf Optimizer for hyperspectral band selection. *Applied Soft Computing*, 40, 178-186 [4].

küplerde düşey doğrultudaki uzamsal bilgiler, bant dilimleri halinde değerlendirilebilirken dikey yönde spektral olarak her bir pikselin yansıma veya ışınma değerleri gibi spektral bileşenleri Şekil 2.5’de görülebileceği gibi eş zamanlı olarak gösterilebilmektedir.




Şekil 2.5. Hiperspektral Küp Gösterimi<sup>5</sup>

### 2.2.1.2. Spektral uzayda gösterim

Hiperspektral bir sahnedeki farklı frekanslardaki elektromanyetik dalgalarla aydınlatılmış bir nesnenin, frekansa bağlı olarak elektromanyetik enerjiyi yansıtmaya, soğurma, iletme ve yansıtmaya gibi etkilerinin sonucu olarak oluşan ve dalga boyunun fonksiyonu olarak tanımlanan bir grafiksel gösterim olan eğrilere spektral imza adı verilir.

<sup>5</sup>Lv, Q., Niu, X., Dou, Y., Xu, J., & Xia, F. (2016). Leveraging local receptive fields based random weights networks for hyperspectral image classification. *Journal of Intelligent & Fuzzy Systems*, 31(2), 1017-1028 [5].

Teorik olarak saf veya birden fazla sınıfın birleşmesinden oluşmuş olan her bir pikselin kendine ait özel bir şekle ve değişime sahip spektral bir eğrisi olduğu Şekil 2.6'daki örneklerle gösterilmiştir. Bu özellik sayesinde, spektral eşleşme (spectral matching) veya spektral açısıl haritalama (spectral angle mapper) gibi uzaktan algılama alanında kullanılan yöntemlerle bilinmeyen bir spektral eğrinin daha önceden etiketlenmiş spektral eğriler aracılığı ile sınıflandırılması sağlanabilmektedir.



Şekil 2.6. Farklı Maddelere Ait Spektral İmzalar<sup>6</sup>

<sup>6</sup> Hu, W., Huang, Y., Wei, L., Zhang, F., & Li, H. (2015). Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015 [6].

## 2.2.2. Hiperspektral görüntülerin kullanım alanları

Bilimsel çalışmalarda disiplinlerarası uygulamaların hızla artması ile hiperspektral görüntüleme alanında yapılan çalışmalarının da geniş bir alana uygulanabilmesine yol açmıştır. Özellikle uzaktan algılama alanında, hiperspektral görüntü verilerinin jeolojiden uzay-gezegen araştırmalarına, ormancılıktan tıpa kadar çok geniş bir yelpazede işlenmesi, bu alana doğru ilginin artmasını ve farklı alanlarla kullanımı artan bir teknolojiye dönüşmesini getirmiştir.

Hiperspektral görüntülerin kullanım alanları incelendiğinde, özellikle jeoloji alanında yapılan maden ve minerallerin tespiti, jeolojik haritalama, petrol ve gaz yataklarının tespiti, jeobotanik ve jeotermal araştırmaların gibi birçok farklı uygulamanın olduğu göze çarpmaktadır.

Her bir mineralin spektral imzasının farklı olduğu gibi tarımsal ürünlerin ve doğal bitki yapısında gerek gelişim safhasından kaynaklanan gerekse yağış, hastalık, kuraklık gibi dış etkenlerin etkisi ile normalden farklı bir spektral imzaya sahip olması sebebiyle tarım alanında birçok farklı çalışmaya ulaşmak mümkündür. Bu uygulamalardan bazıları; farklı ürün türlerinin sınıflandırılması, potansiyel ürünlerin ve toprak şartlarının tespit edilmesi, yağış, hastalık ve kuraklık nedenleriyle ürünlerin gördükleri zararların değerlendirilmesi veya toprak karakteristiklerinin planlamasıdır.

Yeryüzünde bulunan tüm kaynakların bilinçli kullanımı, gelişmekte olan dünyada öncül öneme sahip olan ve çevre bilincinin artmasına sebep olan bir konudur. Hiperspektral görüntüleme bu önemli alanda da başarılı uygulamaları bulunan bir teknolojidir. Çevre yönetimi konusu dâhilinde yapılan uygulamalarda; ekosistem durum ve yönelim çalışmaları, vahşi yaşam nüfusa analizinin yapılması, ormancılık, su

kalitesinin analizinin yapılması, kirlilik ve yayılım tespitinin yapılması gibi temel başlıklardan bahsetmek mümkündür.

Hızlı ve büyük miktarda üretim yapan meyve-sebze işletme tesisleri, et-tavuk üretim tesisleri gibi alanlarda tarım ve hayvancılıkla elde edilen ürünlerin kalitesinin tespiti insan sağlığı için çok büyük öneme sahiptir. Hiperspektral uzaktan algılayıcılar yoluyla tarımsal ve hayvansal ürünlerin yüzeyindeki hastalık, çürüme veya farklı faktörler sebebiyle oluşan anormallikler fabrika otomasyon sistemleriyle hızlı, güvenilir ve kabul edilebilir bir netlikle gerçekleştirilebilir [7].

Deri yüzeyinden veya kanserli iç organlardan elde edilen doku örneklerinin analizi ve sınıflandırılması gibi uygulama alanlarında gelecek vaat eden hiperspektral uzaktan algılama yöntemlerinin, yakın bir gelecekte mikroskobik düzeye inerek her türlü biyomedikal veri türünün analizinin yapılabilmesini öngörmektedir [8, 9].

Hiperspektral uzaktan algılama alanında yapılan çalışmaların kullanım alanlarından bir diğeri ise savunma sanayisidir. Optik görüntüleme sistemleri sivil veya askeri amaçlı uygulamalarda oldukça önemli bir yere sahiptir. Bu alanda özellikle karasal yüzeyde mayın tespiti, farklı savaş araçlarının tespiti ve sınıflandırılması gibi uygulamalar üzerinde farklı birçok uygulamayı görmek mümkündür [10]. Özellikle askeri alanda, hiperspektral algılayıcı sistemlerin hedef teşhis ve tanımlamada en önemli bilgi kaynaklarından birini oluşturacağı belirtilmektedir [11].



### 2.3. Derin Öğrenme

Derin öğrenmenin babaları sayılan Yann LeCun, Yoshua Bengio ve Geoffrey Hinton'a göre [12] derin öğrenme, çok sayıda işlem katmanından oluşan bir hesaplama modelidir ve bu tabakalar yoluyla çok katmanlı veri zengin temsilleri öğrenir. Kronolojik olarak Warren McCulloch ve Walter Pitts, AND, OR, NOT gibi mantıksal kapıları çalıştıran ve ikili işlemleri gerçekleştiren bir hesaplama modeli önermektedir. 1958'de Frank Rosenblatt, Perceptron olarak adlandırılan daha karmaşık bir model önermiş ve tek bir nöron üzerinde basit bir eğitim algoritması ile ikili sınıflandırma problemlerini çözmüştür.

1990'lara geldiğimizde, çok katmanlı bir perceptron önerilmiştir ve geri yayılım algoritması ile eğitilmiştir. Bu dönemde, evrimsel sinir ağlarının ilk örnekleri de ortaya çıkmıştır. Bu modeller, derin öğrenmenin evrimi için gerçekten önemlidir. Ancak her ikisi de çok fazla parametre kullanmaktan dolayı başarısız olmuş ve konveks olmayan optimizasyon problemleri için kullanamamaktadır. 2006 yılında büyük bir atılım gerçekleşti ve nöral ağlarla veri boyutunun azaltılması için denetimsiz öğrenmeyi kullanarak katman katman şeklinde inşa edildi.

Gerçek devrim, 2012'de yaşandı. Derin öğrenme, birleşik (compositional), uçtan uca öğrenim (end-to-end learning) ve ayrık gösterim (distributed representations) olmak üzere üç ana fikre dayanıyor. Lineer olmayan dönüşümler ve çoklu katman gösterimleri dizisine dayanan hiyerarşik bir yapı kullanır. Uçtan uca bir yöntemle dayanarak, özellikler veri odaklı bir yaklaşımla öğrenilir. Ve sonunda, hiçbir tek nöron her şeyi kodlar ve nöron grupları birlikte çalışır. Bu yüzden dağıtılmış temsilleri teşvik eder.



### 2.3.1. Evrişimsel sinir ağıları (Convolutional neural networks)

Biyolojik süreçten ilham alınarak tasarlanan, derin öğrenmede en sık kullanılan mimarilerden biri olan evrişimsel sinir ağıları (ESA), birbiri ardına yerleştirilmiş birçok eğitilebilir bölümlerden oluşan çok katmanlı bir yapıya sahiptir [13]. Bu mimaride giriş verisinin alınmasının ardından katmaların sırasıyla işlenmesiyle eğitim süreci gerçekleştirilmiş olur ve sonuçta doğru sonuçlarla karşılaştırma yapmak üzere bir sonuç çıktısı üretilir. Üretilen çıktı ile arzu edilen sonuç arasındaki fark kadar bir hata oluşur ve bu hatanın tüm ağırlıklara aktarılması için bir geriye yayılım algoritması kullanılır. Her iterasyonla bu ağırlıkların güncellenmesi sağlanarak hatanın azaltılması hedeflenir. Evrişimsel sinir ağıları temel olarak görüntü işleme uygulamaları üzerinde yoğunlaşmış gibi gözükse de özellikle son yıllarda giriş verisi olarak görüntü haricinde ses, video veya herhangi bir sinyal de almak üzere tasarlanmış uygulamalarla diğer alanlarda kullanımını artırmıştır.

ESA, bir giriş ve bir çıkış katmanının yanı sıra birçok gizli katmanlardan oluşur. Bir ESA'nın gizli katmanları evrişim katmanı, ortaklama katmanı (pooling layer), tam bağlı katmandan (fully connected layer) oluşur.

#### 2.3.1.1. Evrişim katmanı

Evrişim katmanı, evrişimsel sinir ağıları mimarisinin temelini ifade etmenin yanı sıra, belirli boyutta bir filtrenin tüm görüntü üzerinde dolaştırılması işlemi ile bir dönüşüm sağlar ve bu özelliğinden dolayı dönüşüm katmanı olarak da isimlendirilir. Bu katmandaki evrişim işleminin gerçekleştirilmesini sağlayan, mimarinin en önemli bileşeni 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilen filtrelerdir. Her bir filtreye özgü

özelliklerin keşfedildiği bölgeleri ifade eden aktivasyon haritası evrişim işlemi sonucunda elde edilir.

Evrişim katmanının matematiksel ifadesi Denklem 2.1'deki şekilde ifade edilmektedir.

$$x_j^l = f \left( \sum_{i \in M_j^{l-1}} x_i^{l-1} k_{ij}^l + b_j^l \right) \quad (2.1)$$

Burada  $l$  katman,  $k$  evrişim çekirdeği,  $b$  yanlılık (bias) ve  $M_j$  öznetelik haritası gösterir.

### 2.3.1.2. Ortaklama katmanı (Pooling layer)

Ortaklama katmanı genellikle oluşturulan modellerde etkileşim fonksiyonlarının (activation functions) sonrasına yerleştirilen, isteğe bağlı gerçekleştirilen bir katmandır. Bu katmanda gerçekleştirilen işlem bir sonraki evrişim katmanı için derinlik boyutunu etkilemeksizin giriş boyutunu azaltma görevini amaç edinir ve “aşağı örnekleme” olarak da isimlendirilir. Giriş boyutunun azaltılması ile ortaya çıkan bilgi kaybı; bir çok katmanın yer aldığı mimaride, bir sonraki katman için hesaplama yükünün azaltılmasının yanı sıra, sistemin ezberleme potansiyelinin azaltılması gibi iki önemli fayda üretir. Evrişim katmanında olduğu gibi bu katmanda da belirli filtreler tanımlanır ve kullanılır. Tanımlanan bu filtrelerin görüntülerin üzerinde belirli bir adım atma değerine bağlı olarak gezdirilmesiyle görüntüdeki piksellerin tercihe bağlı olarak en büyük değerleri veya ortalamaları alınır. Ortaklama işlemi, evrişim katmanının sonucunda oluşturulan filtre sayısınınca görüntülerin tamamı için gerçekleştirilir.

### **2.3.1.3. Tam bağlantılı katman (Fully connected layer)**

Evrişimsel sinir ağları mimarisinde birbiri ardına tanımlanmış evrişim, etkileşim fonksiyonları ve ortaklama katmanlarından hemen sonra gelen katman tam bağlantılı katmandır. Farklı mimarilerin yapısına bağlı olarak sayısı değişiklik gösterebilen bu katman, kendinden önceki katmanın tüm alanlarına bağlı olduğundan dolayı “tam bağlantılı” kavramı ile isimlendirilmiştir.

### **2.3.2. Etkileşim fonksiyonları (Activation functions)**

Bir ağa doğrusal olmayanlığı tanıtmak için bir aktivasyon fonksiyonu kullanılır. Bu, bağımsız değişkenlerle doğrusal olmayan şekilde değişen bir sınıf etiketini / skorunu modellememize olanak sağlar. Doğrusal olmayan, çıktıların doğrusal bir giriş kombinasyonu ile kopyalanamayacağı anlamına gelir; bu model, mevcut verilerin karmaşık eşleştirmeleri öğrenmesini sağlar ve böylece ağ, bir evrensel fonksiyona dönüşür, oysa doğrusal bir işlev kullanan bir model (örn. Etkileşim fonksiyonu) konuşma, video vb. gibi karmaşık verilerden anlam ifade edemez ve sadece tek bir katman için etkilidir.


Etkileşim fonksiyonunun bir başka önemli yönü de ayırt edilebilir olması gerektiğidir. Bu, ağıma geri dönüp gradyanları hesaplarken ve böylece ağırlıkları buna göre ayarladığımızda gereklidir. Doğrusal olmayan fonksiyonlar süreklidir ve girişi (normalde sıfır merkezli, ancak, bu değerler kendi ağırlıkları ile çarpılarak orjinal ölçeğinin ötesine geçer)  $(0, 1)$ ,  $(-1, 1)$  aralığında dönüşürler. Bir nöral ağda, bazı nöronların lineer etkileşim fonksiyonlarına sahip olması mümkündür, fakat aynı ağın diğer kısımlarında lineer olmayan etkileşim fonksiyonlarına sahip nöronlar eşlik

etmelidir. Derin sinir ağılarda en sık kullanılan etkileşim fonksiyonları sigmoid, tanh, DDB ve sızıntılı DDB'dir.

Sigmoid fonksiyonu aynı zamanda lojistik aktivasyon fonksiyonu olarak bilinir. Reel bir sayı alır ve 0 ile 1 arasında bir değere sıkıştırır.

Şekil 2.7'de görüldüğü gibi büyük negative sayıları 0'a ve büyük pozitif sayıları 1'e dönüştürür. Matematiksel olarak;

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$



Şekil 2.7. Sigmoid Fonksiyonu Grafiği

Sigmoid fonksiyonunun üç büyük dezavantajı:


- Kaybolan gradyan problem (Vanishing gradients): Sigmoidin gradyanı 0 ve 1 civarındadır. Ağ üzerinden sigmoid aktivasyonu ile geri yayılım sırasında, çıkışı 0'a yakın olan nöronlarda gradyanlar veya 1 yaklaşık 0'dır. Bu nöronlar, doymuş nöronlar olarak adlandırılır. Böylece, bu nöronlardaki ağırlıklar güncellenmez. Aynı zamanda, aynı nöronlara bağlı nöronların

ağırlıkları da yavaş yavaş güncellenir. Bu problem kaybolan gradyan problemi (vanishing gradients) olarak bilinir.

- Sıfır merkezli olmaması: Sigmoid çıkışları sıfır merkezli değildir.
- Hesaplama maliyeti: Üstel fonksiyon işlemi, diğer doğrusal olmayan etkileşim işlemleriyle karşılaştırıldığında hesaplama açısından maliyetlidir.

Tartışacağımız sıradaki doğrusal olmayan etkileşim fonksiyonu, sigmoid'deki sıfır merkezli problemini ele almaktadır.

Hiperbolik tanjant fonksiyonu, sigmoide benzer şekilde, tanh reel bir sayı alır ancak -1 ile 1 arasında bir değere sıkıştırır. Sigmoid fonksiyonundan farklı olarak, tanh çıkışları -1 ile 1 arasında olduğundan, çıktısı sıfır merkezlidir ve bu sebeple sigmoid fonksiyonuna göre daha çok tercih edilmektedir. Şekil 2.8'de görüldüğü gibi sıfırdan uzaklaştıkça doyuma ulaşmasından dolayı kaybolan gradyan problemiyle karşı karşıya olması en önemli dezavantajıdır.



Şekil 2.8. Tanh Fonksiyonu Grafiği


Yok olan gradyan problemini ele almak için, önceki iki etkileşim fonksiyonundan çok daha iyi olan ve günümüzde en yaygın şekilde kullanılan düzeltilmiş doğrusal birim

(rectified linear unit) olarak bilinen başka bir doğrusal olmayan etkileşim fonksiyonunu tartışalım.

Şekil 2.9'da fonksiyon grafiği verilen düzeltilmiş doğrusal birim (DDB) fonksiyonu, bilgisayarlı görüde, özellikle nesne tespiti ve sınıflandırma uygulamalarında en çok kullanılan fonksiyondur ve bu alandaki uygulamalarda durgunluğa giren yapay sinir ağı çalışmalarını hızlandırmıştır. Matematiksel olarak;

$$f(x) = \max(0, x) \quad (2.3)$$

Şeklinde ifade edilebilen DDB fonksiyonunu, ağı daha hızlı bir şekilde yakınsamasını sağlar. Pozitif girişler için gradyanı her zaman sıfırdan farklıdır.



Şekil 2.9. DDB Fonksiyonu Grafiği


En azından pozitif bölgede ( $x > 0$  olduğunda) kaybolan gradyan problemine karşı dirençli olduğu anlamına gelir. Bu nedenle nöronlar, bölgelerinin en azından yarısı kadar tüm sıfırları geri döndürmezler. DDB, basit eşikleme kullanılarak uygulandığı için hesaplama açısından çok verimlidir. Ancak DDB etkileşim fonksiyonun da bazı dezavantajları vardır:

- Sıfır merkezli olmaması: Çıkışlar sigmoid etkileşim fonksiyonu gibi sıfır merkezli değildir.
- DDB ile ilgili diğer bir konu ise, ileri geçişte  $x < 0$  ise, nöronun pasif kalması ve geriye doğru geçiş sırasında gradiyenti öldürmesidir. Böylece ağırlıklar güncellenmez ve ağ öğrenmez. Eğer  $x = 0$  olduğunda, eğim bu noktada tanımsızdır, ancak bu problem, uygulama sırasında sol ya da sağ eğimi seçerek halledilir.

DDB etkileşim fonksiyonunda  $x < 0$  olduğunda yok olan gradyan probleminin çözümü için sızıntılı DDB (leaky rectified linear unit) önerilmektedir. Matematiksel olarak;

$$f(x) = \max(0.1 * x, x) \quad (2.4)$$

Şeklinde ifade edilen sızıntılı DDB, DDB etkileşim fonksiyonunun tüm özelliklerine sahip olmakla birlikte, Şekil 2.10'de görüldüğü gibi  $x < 0$  olduğunda, 0.1'lik küçük bir pozitif eğime sahip olacaktır. Bu sayede kaybolan gradyan problemi ortadan kaldırmaktadır.



Şekil 2.4. Sızıntılı DDB Fonksiyonu Grafiği

### 2.3.3. Softmax

YSA'nın bu bölüme kadar anlatılan bileşenleri, veriden öznitelik çıkarmak ve veri akışını düzenlemek için kullanılmaktadır. Softmax regresyon, bir derin ağın son katmanı olup sınıflandırma görevinin tamamlandığı yerdir. Önceki katmanların gerçeklediği fonksiyonlar sayesinde elde edilen öznitelik vektörü, softmax regresyon katmanının girdisidir.

Softmax regresyon, lojistik regresyonun genellenmiş halidir ve çok sınıflı sınıflandırma problemlerinde kullanılır.

Varsayalım ki,  $m$  örnek sayısı ve  $k$  sınıf sayısı olmak üzere eğitim kümesi:

$$\left\{ \left( (x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)}) \right) \right\}, x^{(i)} \in \mathbb{R}^{n+1}, y^{(i)} \in \{1, 2, \dots, k\}$$

şeklinde tanımlansın.

Softmax regresyon fonksiyonu Denklem 2.5 şeklinde tanımlanır.

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | x^{(i)}; \theta) \\ \vdots \\ p(y^{(i)} = k | x^{(i)}; \theta) \end{bmatrix} = \frac{\begin{bmatrix} \exp(\theta_1^T x^{(i)}) \\ \vdots \\ \exp(\theta_k^T x^{(i)}) \end{bmatrix}}{\sum_j \exp(\theta_j^T x^{(i)})} \quad (2.5)$$

Burada  $p(y^{(i)} = 1 | x^{(i)}; \theta)$ ,  $x^{(i)}$ 'nin 1. sınıfa ait olma olasılığını gösterir.

$\theta_j^T \in \mathbb{R}^{n+1}$  ise modelin parametresidir.

### 2.3.4. Yitim fonksiyonu, eğim düşümü ve geri yayılım algoritması

YSA'nın eğitimi, bir eniyileme problemidir. Bu eniyileme problemi için kullanılan yitim fonksiyonu ise Denklem 2.6'da tanımlanmıştır. Hata miktarını ölçen bu fonksiyon, YSA'nın parametrelerinin doğruluğu hakkında bilgi sağlamaktadır.



$$J(\theta) = \frac{-1}{m} \left[ \sum_{i=1}^m \sum_{j=1}^k l(y^{(i)} = j) \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T x^{(i)}}} \right] \quad (2.6)$$

Burada  $l(y^{(i)} = j)$  gösterge fonksiyonu, eğer  $y^{(i)} = j$  ise  $l(y^{(i)} = j) = 1$ , diğer durumlarda  $l(y^{(i)} = j) = 0$ 'dır.

Eğim düşümü (gradient descent) algoritması, çapraz entropiyi küçültmek için kullanılan algoritmadır. Bu algoritma, küçültülecek fonksiyonun gradyan (eğim) yüzeyi üzerinde iteratif olarak, önceden belirlenmiş adım boyu mesafesinde, artan gradyanın tersi yönünde ilerleyerek fonksiyonun en küçük değerini arar.

Gradyan hesaplandıktan sonra YSA'daki her katmandaki model parametreleri Denklem 2.7 ve Denklem 2.8'de formüller yardımıyla güncellenir.

$$v^{i+1} = \varepsilon v^i - \alpha \cdot \nabla J(\theta)^{(i)} \quad (2.7)$$

$$\theta^{(i+1)} = \theta^{(i)} + v^{i+1} \quad (2.8)$$

Burada  $i$  iterasyon sayısı,  $\alpha$  öğrenme hızı,  $\nabla J(\theta)^{(i)}$  ise  $i$  grubundaki yitim fonksiyonu  $J(\theta)^{(i)}$ 'nin kısmi türevidir ve  $v$  parameter vektörü  $\theta$  ile aynı boyutta olan mevcut hız vektörüdür. Son olarak  $\varepsilon \in (0,1]$  önceki güncellemelerin kaç kez yinelenen mevcut güncellemeye dahil edildiğini belirler. Genel olarak, ilk öğrenme stabilize edene ve daha sonra 0.9'a veya daha yüksek bir değere yükselene kadar  $\varepsilon$  değeri 0.5'e ayarlanır. Gradyanın, YSA'daki tüm parametreler üzerinden bir defada hesaplanması mümkün değildir. Burada geri yayılım (back-propagation) algoritması devreye girmektedir [14]. Bu algoritma, en üst katmandan başlayarak (softmax regresyon), her katmanda sadece katmanın ağırlıklarını kullanarak gradyan hesaplar ve buradaki hatayı bir alt katmana aktarır. Bu işlem, zincir kuralı ile yapılır.

### 2.3.5. Caffe

Caffe, hali hazırda bilinen derin öğrenme algoritmalarını ve referans modeller için temiz ve değiştirilebilir C++ tabanlı bir derin öğrenme kütüphanesidir.

Modüler yapıda olması, Python ve Matlab desteği oluşu, CUDA ve çoklu GPU desteği oluşu ve algoritmaların hızlı şekilde entegre edilebilirliği sayesinde araştırma projelerinin yanı sıra ticari uygulamalar içinde kullanılabilir kararlılıktadır.

Berkeley Görme ve Öğrenim Merkezi (BGÖM) tarafından açık kaynak [15] olarak topluluğun yardımlarıyla geliştirilmektedir. Ancak görüntü üzerine uygulamalar haricindeki çalışmalar için gerekli yapıların entegrasyonun geç yapılması ve topluluk katkılarının ana kod deposuna birleştirilmemiş oluşundan dolayı güncelliğini koruyamamıştır [16].

### 2.3.6. Başarı ölçülmesinde kullanılan metrikler

Derin öğrenme çalışmalarında modelin başarımının ölçülmesinde en çok kullanılan metrik doğruluk (accuracy) oranıdır. Doğruluk oranı, doğru sınıflandırılmış örnek sayısının, toplam örnek sayısına oranı şeklinde hesaplanır. Ayrıca hiperspektral görüntülerin sınıflandırma problemlerinde doğruluk oranı dışında kappa katsayısı (k) başarı ölçütü için sıklıkla kullanılmaktadır.

$$\text{Kappa katsayısı (k)} = \frac{p_o - p_c}{1 - p_c} \quad (2.11)$$

Kappa katsayısının hesaplanmasındaki  $p_o$  değeri gözlenen uyum oranını,  $p_c$  değeri ise rastlantısal uyum oranıdır.

Kappa katsayısı negatif ( $K < 0$ ) değerler için güvensiz olarak değerlendirilirken, 0,2'den az kötü, 0,2 ile 0,4 aralığı makul, 0,4 ile 0,6 aralığı orta, 0,6 ile 0,8 aralığı iyi, 0,8 ile 1 aralığı çok iyi olarak değerlendirilir [17].

#### **2.4. Literatür İncelemesi**

Hiperspektral görüntülerin piksel sınıflandırması üzerine derin öğrenme yöntemleri kullanılarak yapılan çalışmalar 2015 yılından itibaren artış göstermeye başlamıştır. Literatürde öne çıkan çalışmaların birçoğunun, "Indian Pines", "Salinas", "Pavia Center", "University of Pavia" ve "Kennedy Space Center" hiperspektral görüntüleri üzerinde denendiği gözlenmiştir.

2015 yılında Indian Pines, Salinas ve Pavia Üniversitesi hiperspektral görüntüleri üzerinde Hu vd. tarafından denenen çalışmada; ilki bir boyutlu evrişim katmanının ardından onu takip eden bir tam bağlantılı katmandan oluşan, basit bir derin öğrenme modeli önerilmiştir. Bu yapı ile elde edilen sonuçlar, eğitim süresi ve sınıflandırma başarısı destek vektör makinesi yöntemi ile karşılaştırmışlardır. Çalışmada önerilen ESA mimarisi, destek vektör makinelerine karşın önemli bir üstünlük sağlayamamıştır [18].

2015 yılında hiperspektral görüntülerin sınıflandırılması problemine yönelik Chen vd. tarafından yapılan bir diğer çalışmada, tam bağlantılı katmanların kullanılması ile hem spektral hem de uzamsal sınıflandırma gerçekleştirilmiştir. Tam bağlantılı katman ile uzamsal sınıflandırmanın yapılabilmesi için öncelikle temel bileşen analizi algoritması ile görüntünün boyutu düşürülmüş ve ardından sınıflandırılacak pikselin çevresinden alınan veri küpü tek boyutlu bir vektör haline getirilmiş ve sonunda çalışmada önerilen

yapay sinir aęları mimarisine verilerek sonuçlar elde edilmiştir. Yapay sinir aęları mimarisi, Pavia Üniversitesi ve Indian Pines görüntüleri üzerinde farklı sayıda katmanlarla denenmiştir ve destek vektör makineleri yöntemi ile karşılaştırılarak, önerilen yöntemin başarılı olduğu görülmüştür [19].

Indian Pines görüntü veri kümesi üzerinde uygulanan, 3 evrişimin ardından uygulanan 2 tam bağlantılı katmandan oluşan bir yapay sinir aęları mimarisi önerilen ve yine 2015 yılında Slavkovikj vd. tarafından yapılan çalışmada; ilk evrişim katmanı 3 boyutlu veri alırken, uzamsal boyutlarda evrişim yapılmamaktadır. Uzamsal boyutlarda evrişim yerine, test edilen pikselin komşulukları üzerinde spektral boyutta evrişim yapılmaktadır. Bahsi geçen bu çalışmada başka bir sınıflandırıcı ile karşılaştırma yapılmamış, önerilen veri artırım yönteminin başarısı üzerine yoğunlaşmıştır [20].

Gözetimsiz öğrenme ile öznitelik çıkarımı yapan bir yapay sinir aęı mimarisi öneren Tao vd., bir oto-kodlayıcı aę oluşturmuştur ve çalışmada bu aęın başarısı farklı öznitelik çıkarma yöntemleri kullanarak destek vektör makinesi ile sınıflandırma yapan farklı çalışmaların sonuçları ile kıyaslanmıştır. Kıyaslamalar sonucunda çalışmada önerilen oto-kodlayıcı aęın, karşılaştırmalarda yüksek başarı gösterdiği gözlenmiştir [21].

Salman vd. tarafından, 2016 yılında Pavia Üniversitesi görüntü veri kümesinin kullanıldığı bir çalışmada, üç adet bir boyutlu evrişim aęının ardından bir tam bağlantılı aę kullanılarak bir mimari tasarlanmıştır. Sonuçlar daha önceki birçok çalışmada da olduğu gibi destek vektör makineleri ile karşılaştırılmış ve başarılı sonuçlar elde edilmiştir [22].

Spektral ve uzamsal olarak çıkarılan özniteliklerin tek bir sınıflandırıcı ile sınıflandırılmasını yaklaşımını öneren ve bu bağlamda yaptığı çalışmada uzamsal özniteliklerin çıkarılmasında evrişimsel ağ kullanan Zhao vd. tarafından çalışma, 2016 yılında Pavia Center ve University of Pavia hiperspektral görüntü kümeleri üzerinde test edilmiştir. Çalışma kapsamında önerilen öznitelik çıkarma yöntemleri, temel bileşen analizi ve doğrusal ayırmsayıcı analiz algoritmaları ile kıyaslanmış ve başarılı sonuçlar elde edildiği görülmüştür [23].

Hiperspektral bir görüntüden en uygun spektral bantların parçacık sürü eniyileme algoritması aracılığı ile seçilerek, ardından 3 tane 3 boyutlu evrişimsel ağ ile oluşturulan mimarinin başarısının iyileşeceği ön görülerek Ghamisi vd. tarafından gerçekleştirilen çalışma, Indian Pines ve University of Pavia veri kümeleri üzerinde denenenmiştir. Önerilen mimarinin sonuçları öncelikle parçacık sürü eniyileme algoritması kullanılmayan haliyle elde edilen sonuçlarla ve daha sonra ise destek vektör makinesi sınıflandırıcı ile elde edilen sonuçlarla karşılaştırılmıştır. Çalışmada elde edilen başarılı sonuçlar ön görüyü doğrular nitelikte olmuştur [24].

2016 yılında Chen vd. tarafından yapılan çalışmada Kennedy Space Center, Indian Pines ve Pavia Üniversitesi olmak üzere 3 farklı veri kümesinden yararlanılmıştır. Yapılan çalışma kapsamında, bu veri kümeleri üzerinde 1 boyutlu ve 3 boyutlu evrişimsel ağları karşılaştırılmıştır. Ayrıca, çalışmada kullanılması önerilen veri çoğaltma yönteminin de başarıyı artırdığı gözlenmiştir. Çalışmada önerilen modeller destek vektör makineleri ile elde edilen sonuçlarla karşılaştırıldığında ise 3 adet 3 boyutlu evrişim ağı kullanılarak bulunan sonuçların en başarılı sonuçlar olduğu görülmüştür [25].

Hiperspektral görüntülerin piksel sınıflandırması üzerine derin öğrenme yöntemleri kullanılarak yapılan çalışmalardan bir diğeri Lee vd. tarafından 2016 yılında yapılmıştır. Bu çalışmada önerilen ağın ilk katmanında paralel olarak eğitilen 3 boyutlu evrişimsel ağ ve bir boyutlu evrişimsel ağ kullanılmıştır. Paralel olarak eğitilmiş olan bu katmanların çıktıları ise vektörel olarak uç uca eklenerek sıralı 8 tane bir boyutlu evrişim katmanına aktarılmıştır. Derinliği toplamda 9 katman olan bu mimari, Indian Pines veriseti üzerinde test edilmiş ve destek vektör makinesi algoritmasına göre daha başarılı sonuçlar vermiştir [26].

Ying Li vd. Tarafından 2017 yılında yapılan çalışmada, hiperspektral küpün spektral-uzamsal özelliğinden faydalanarak herhangi bir ön işleme tabi tutmadan basit bir 3 boyutlu evrişimsel sinir ağları önerilmiştir. Önerilen yöntem yığılı otokodlayıcılar (stacked autoencoder), derin kısa ağ ve 2 boyutlu evrişimsel sinir ağı tabanlı yöntemler ile karşılaştırılmış ve 3 boyutlu evrişimsel sinir ağı modelinin daha yüksek sınıflandırma başarımı gösterdiği gözlenmiştir [27].

Öznelik profilleri, geometrik ve spektral özelliklerin yakalanabilmesi için en önemli yaklaşımlardan biri olarak kabul edilir. Bir dizi filtrelenmiş görüntü evrişimsel sinir ağına ile işlenerek daha etkili piksel tanımlarına yol açtığını gösterilmiştir [28].

Hiperspektral görüntü sınıflandırmadaki en büyük problemlerden birisi az sayıda etiketli piksel olmasıdır. Wei Li vd. tarafından 2017 yılında önerdikleri piksel çifti veri artırma yaklaşımında, mevcut etiketli herhangi iki örneği eşleştirilerek yeni bir veri kombinasyonu oluşturulması ve veri girişinin yeniden etiketlenen piksel çiftleri ile derin evrişimsel sinir ağına girdi olarak verilmiştir. Az etiketli veri ile derin öğrenme mimarileri ile de yüksek başarımlar elde edilebileceği gösterilmiştir [29].

Son dönemde Qingshan Liu vd. tarafından klasik evrişimli sinir ağlarından farklı olarak, iki yönlü-evrişimsel uzun kısa süreli bellek (bidirectional-convolutional long short term memory) ağı adı verilen yeni bir derin öğrenme ağı önerilmiştir.

Spektral bilgileri yeterince yakalamak için çift yönlü tekrarlayan bağlantı operatörleri ile uzamsal alanda evrişimsel sinir ağları kullanılmıştır. Sınıflandırma aşamasında, öğrenilen özellikler bir vektöre birleştirilir ve tam bağlı bir operatör aracılığıyla bir softmax sınıflandırıcısına beslenir. Önerilen iki yönlü-evrişimsel uzun kısa süreli bellek çerçevesinin etkinliğini doğrulamak için, yaygın olarak kullanılan üç HSG üzerinde evrişimsel sinir ağları da dahil olmak üzere birçok modern yöntemle karşılaştırırız. Elde edilen sonuçlar, iki yönlü-evrişimsel uzun kısa süreli belleğin diğer metotlara kıyasla sınıflandırma performansını geliştirebileceğini göstermektedir [30].

Hiperspektral görüntülerin sınıflandırılması probleminin çözümüne yönelik literatürde yapılan bu çalışmalar incelendiğinde, klasik makine öğrenmesi yöntemlerinden destek vektör makinelerinin sıklıkla kullanıldığı görülmüştür. Yakın zamanda aynı probleme yönelik yapılan çalışmalarda ise klasik makine öğrenmesi yöntemlerinden farklı olarak derin öğrenme yöntemlerinden de yararlanılmıştır. Bahsi geçen bu çalışmaların birçoğunda derin öğrenme yöntemlerinin destek vektör makinesi yöntemine göre daha iyi sonuçlar verdiği gözlenmiştir. Ayrıca derin öğrenme ağları kullanılarak üretilen çözümlerde; oluşturulan kompleks derin öğrenme ağlarının, basit sığ ağlara göre daha yüksek sınıflandırma başarımları elde ettiği de görülmüştür.

Derin öğrenme yöntemlerini kullanabilmek için yüksek eğitim verisine ihtiyaç duyulmasına rağmen; az sayıda etiketli piksel ile derin öğrenme ağlarıyla başarılı sonuçlar alınmıştır.

Bu tez kapsamında basit bir derin öğrenme modelinin sınıflandırma gücü, spektral ve uzamsal bilginin birlikte kullanılması ile farklı ağların aynı anda eğitilerek kaynaştırılması yöntemleri ve farklı boyutlardaki çevre pikselden yararlanılmasının sınıflandırma başarımına etkisi deneysel sonuçlar ile ölçümlenmiştir.





### III. PROBLEMİN TANIMI VE HİPOTEZ

Yeryüzü şekillerini görüntüleyen hiperspektral görüntüleyiciler uçak, uydu veya hava araçları üzerinden bu görüntüleri elde etmektedirler. Bu yüzden çok geniş alanlar içeren görüntüler oluşmakta ve her bir pikselin temsil ettiği alan oldukça geniş olmaktadır. Makine öğrenmesi yöntemlerinden eğitici ve eğitici olmayan öğrenme yöntemleri ile bu görüntülerin sınıflandırılması, bir başka deyişle her bir pikselin bir kümeye veya bir sınıfa atanması yüksek doğrulukla sonuçlanmayabilir. Tek bir pikselin sahip olduğu spektral imza temelli bu yaklaşımdan ziyade çevredeki piksellerin de hesaba katılması başarıyı arttıracak bir yöntem sunar. Çevredeki piksellerle ilişki sağlanarak merkez piksel için tek bir öznelik elde edilmesi ve bu özneliğin merkez pikselin yeni spektral imzasını oluşturması sınıflandırma başarımlarını olumlu yönde etkileyecektir. Ayrıca yüksek boyutlu hiperspektral verilerin temel bileşen analizi yöntemiyle boyutunun azaltılması hesapsal karmaşıklığı azaltacağı gibi belirgin özelliklerin öne çıkmasını sağlayacak ve ayrıştırılabilirliği arttıracaktır.


## IV. YÖNTEM

### 4.1. Veriseti


Bu çalışma Yansıtıcı Optik Sistem Görüntüleme Spektrometresi (YOSGS) sensörü tarafından elde edilen Pavia Üniversitesi veriseti üzerinde yapılmıştır. Pavia Üniversitesi veriseti  $340 \times 610$  piksel boyutunda olup, 115 spektral bant içermektedir. Su emilimini ve geniş gürültü içeren bantlar çıkarılacak 103 spektral banta düşürülerek paylaşılmıştır. Orjinal görüntü  $0,4 \mu\text{m}$  ile  $0,85 \mu\text{m}$  spektral bant aralığına sahip olup, uzamsal çözünürlüğü 1,5 metredir. Pavia Üniversitesi verisi sınıfları arasında spektral farklılıklar yüksek bir veridir. Üç bantlı renkli kompozit görüntü ve yer gerçeği haritası Şekil 4.1’de gösterilmiştir.  $340 \times 610$  piksellik sahne içerisinde çimen, ağaç, çakıl, asfalt, zift, metal saç, tuğla, toprak, gölge sınıfları bulunmaktadır. 9 sınıfa ait toplam 3921 eğitim ve 42776 test verisi Şekil 4.2’de gösterilmiş ve Tablo 4.1’de verilmiştir.

Tablo 4.1. Pavia Üniversitesi Veri Seti

#	Eğitim Piksel Sayısı	Test Piksel Sayısı	Sınıf
1	548	6631	Asfalt
2	540	18649	Çimen
3	392	2099	Çakıl
4	524	3064	Ağaç
5	265	1345	Metal Saç
6	532	5029	Toprak
7	375	1330	Zift
8	514	3682	Tuğla
9	231	947	Gölge
	<b>3921</b>	<b>42776</b>	



Şekil 4.1. Pavia Üniversitesi Veriseti Renkli Görüntü ve Yer Gerçeği



Şekil 4.2. Pavia Üniversitesi Veriseti Test Pikselleri ve Eğitim Pikselleri Resmi

## 4.2. Hiperspektral Görüntülerde Uzamsal ve İzgesel (Spektral) Pikel Sınıflandırma

### Sınıflandırma

Hiperspektral verilerin sınıflandırılması için kullanılan piksel tabanlı yöntemler literatürde yaygın ve çok çeşitlidir. Bu yöntemler arasında maksimum olabilirlik veya Bayes kestirim yöntemleri [31], karar ağaçları [22], yapay sinir ağları, genetik algoritmalar [33] ve çekirdek tabanlı yöntemler [34] sadece birkaçıdır. Özellikle DVM, hiperspektral görüntü sınıflandırması uygulamalarında sıkça kullanım bulmakta ve eğitim örneği sayısı az olduğu durumlarda diğer yöntemlere göre üstün başarımlar göstermektedir. [35, 36, 37].

Bununla birlikte, uzamsal bilgilerin sınıflandırma işlemine dahil edilmesinin sadece spektral özellikleri kullanan piksel tabanlı sınıflandırmaya göre başarımları arttırdığı bilinmektedir. Bu tür yaklaşımlarda, pikselden elde edilen öznelik vektörü, sadece hiperspektral piksel vektörünün kendisi olmamakta, aynı zamanda başka piksel vektörlerinden de bilgiler içermektedir.

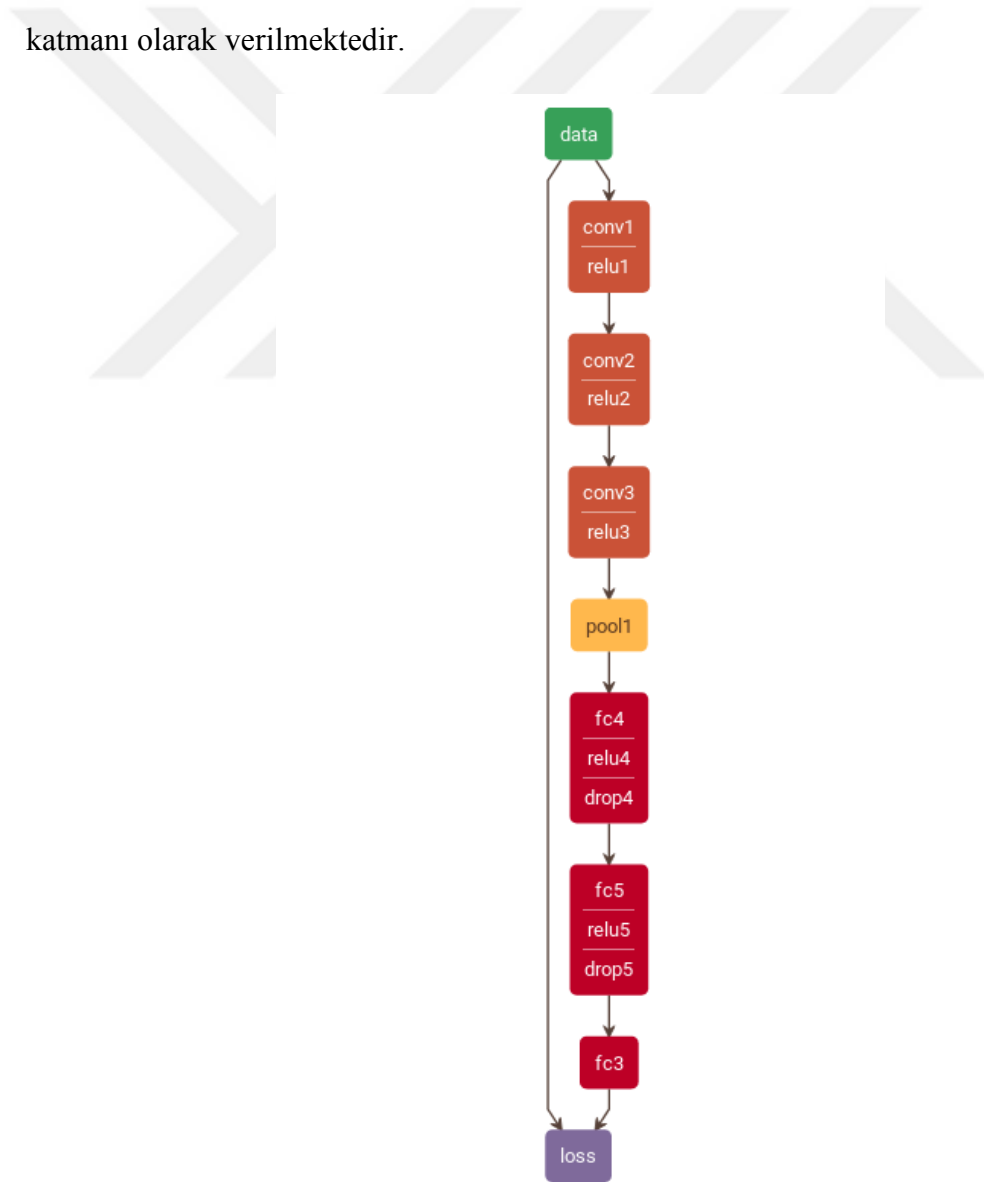
Uzamsal bilginin sınıflandırma işlemine dahil edilmesi için kullanılan yaklaşımlardan biri sabit pencere boyutu kullanılarak komşu piksellerden de bilgi alınması yaklaşımıdır. Bu yaklaşımı kullanan yöntemler arasında biçimbilimsel süzgeçlerin kullanılması [38] veya Markov rastsal alanlar [39] sayılabilir.

Bu tez kapsamında uzamsal bilgi kullanılarak hiperspektral verilerde sınıflandırma başarımlarının artırılması üzerine bu yaklaşım altında çalışmalar yürütülmüştür.

#### 4.2.1. Bir boyutlu piksel vektörleri ile sınıflandırma

Bu yaklaşımda sadece HSG'lerin sadece spektral (izgesel) bilgisinden yararlanılarak çok derin olmayan bir evrimsel sinir ağı modeli (ESA) ile sınıflandırmıştır.

Bu amaçla her eğitim pikseli tüm spektral bantlarıyla birlikte  $1 \times 103$  olacak şekilde bir boyutlu giriş vektörleri olarak seçilmiştir. Bu seçilen bir boyutlu vektörler Şekil 4.3'te tüm katmanları ve katmanların parametreleri gösterilmiş olan sinir ağı modeline giriş katmanı olarak verilmektedir.



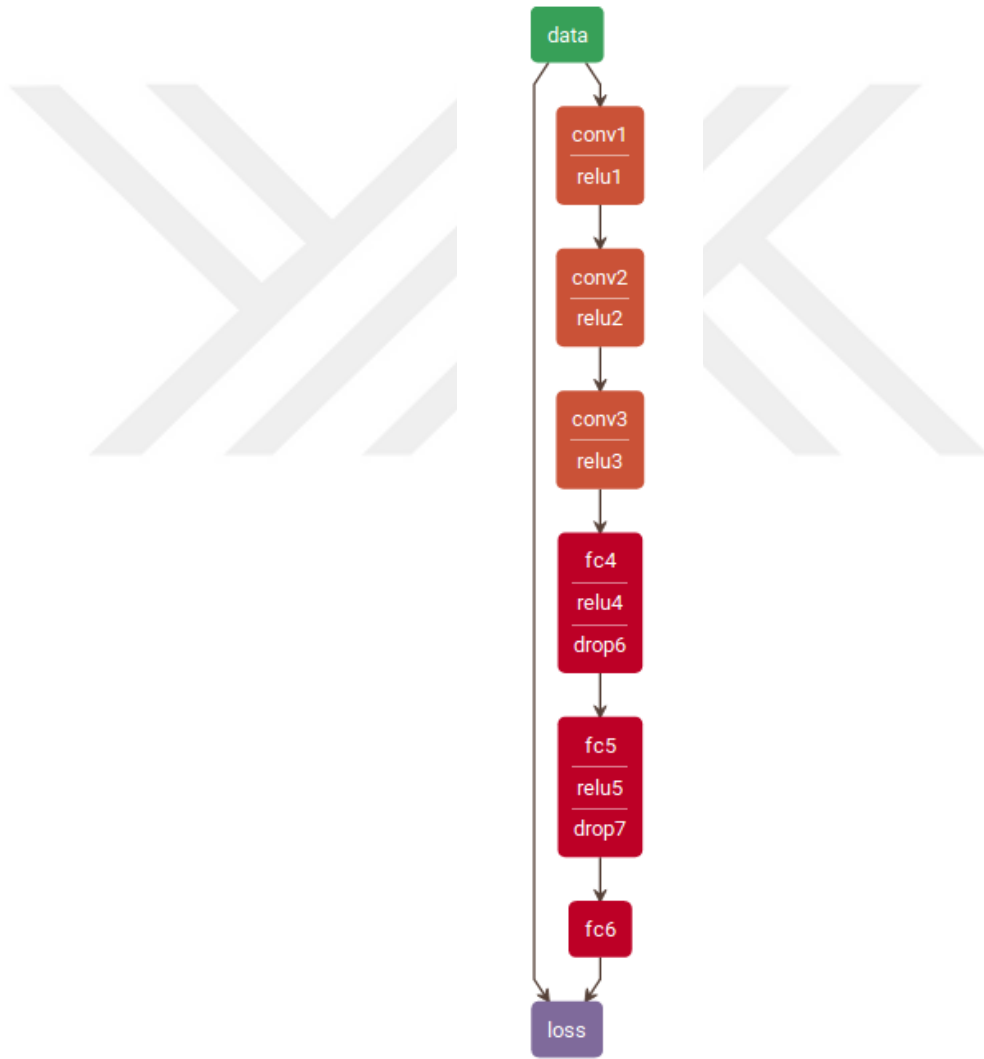
Şekil 4.3. Girdisi Spektral Vektörler Olan ESA Ağı

- **Giriş**
  - 1x103 (1D vektör)
- **Katmanlar**
  - **Evrişim1 (Con1) katmanı:** 1 piksel dolgulama (padding), 1 adım (stride) ile 9x1 lik 48 filtre + **DDB**
  - **Evrişim2 (Con2) katmanı:** 1 piksel dolgulama (padding), 1 adım (stride) ile 7x1 lik 96 filtre + **DDB**
  - **Evrişim3 (Con3) katmanı:** 1 piksel dolgulama (padding), 1 adım (stride) ile 7x1 lik 96 filtre + **DDB**
  - **Ortaklama (Pooling):** Maksimum ortaklama, 1 adım (stride) ile 2x1
  - **Tam Bağlı (Fully Connected) Katman:** 1024 + **DDB** + **Seyreltme (Dropout): 0.5**
  - **Tam Bağlı (Fully Connected) Katman:** 1024 + **DDB** + **Seyreltme (Dropout): 0.5**
  - **Tam Bağlı (Fully Connected) Katman:** 9
  - **Softmax fonksiyonu**

#### 4.2.2. Uzamsal bilgiden yararlanılarak sınıflandırma

HSG’lerde spektral (izgesel) özelliklerin yanı sıra uzamsal bilginin de kullanılması sınıflandırma başarımının artırılmasına katkı sağlar. Örneğin, Dell'Acqua vd. [40] yaptıkları çalışmada şehir alanlarına ait hiperspektral görüntüleri haritalayabilmek için spektral ve uzamsal sınıflayıcıları birlikte kullanan yöntemleri araştırmışlardır. Benediktsson vd. [41] daha iyi bir sınıflandırma başarımı sağlamak için hiperspektral görüntünün spektral ve uzamsal bilginin yanı sıra biçimbilimsel özellikleri de kullanan bir yöntem geliştirmiştir. Spektral ve uzamsal bilgiyi birlikte kullanarak sınıflandırma başarımını arttırmak amacıyla “bileşik çekirdek” yapıları Camps-Valls vd. [42] tarafından önerilmiştir.

Bu yaklaşımda  $m = (x, y)$  için,  $p$  pencere boyutu,  $b$  bant sayısı olmak üzere,  $m$ 'nin çevresini içeren  $p \times p \times b$  boyutlu tensörler seçilmiştir. Pencere boyutu olan  $p$  değeri 3-5-7-9 şeklinde en küçük boyuttan büyüyerek komşu piksellerin etkisi gözlemlenmiştir. Bu seçilen tensörler Şekil 4.4'de tüm katmanları ve katmanların parametreleri gösterilmiş olan sinir ağı modeline giriş katmanı olarak verilmektedir.



Şekil 4.4. Girdisi Yama Olan ESA Ağı


9x9x103 lük tensörü için ESA'nın parametleri aşağıdaki gibidir;

- **Giriş**
  - 9x9x103 (tensör)
- **Katmanlar**
  - **Evrişim1 (Con1) katmanı:** 1 piksel dolgulama (padding), 1 adım (stride) ile 5x5 lik 48 filtre + **DDB**
  - **Evrişim2 (Con2) katmanı:** 1 piksel dolgulama (padding), 1 adım (stride) ile 3x3 lik 96 filtre + **DDB**
  - **Evrişim3 (Con3) katmanı:** 1 piksel dolgulama (padding), 1 adım (stride) ile 3x3 lik 96 filtre + **DDB**
  - **Tam Bağlı (Fully Connected) Katman:** 1024 + **DDB** + **Seyreltme (Dropout): 0.5**
  - **Tam Bağlı (Fully Connected) Katman:** 1024 + **DDB** + **Seyreltme (Dropout): 0.5**
  - **Tam Bağlı (Fully Connected) Katman:** 9
  - **Softmax fonksiyonu**

#### 4.2.3. TBA ile boyut indirgenmiş görüntüler ile sınıflandırma

Hiperspektral görüntülerde daha büyük boyutlu yamalar seçebilmek ve evrişimsel sinir ağlarının işlem yükünün azaltılması için, önemli bir veri kaybı olmadan [43] temel bileşen analizi (TBA) yöntemi kullanılarak bant boyutunun azaltılması işlemi uygulanmıştır. 103 bantlı Pavia Üniversitesi görüntüsüne TBA boyut indirgelem işlemi uygulanarak aşağıdaki Şekil 4.5'te 4 banta indirgenmiştir.



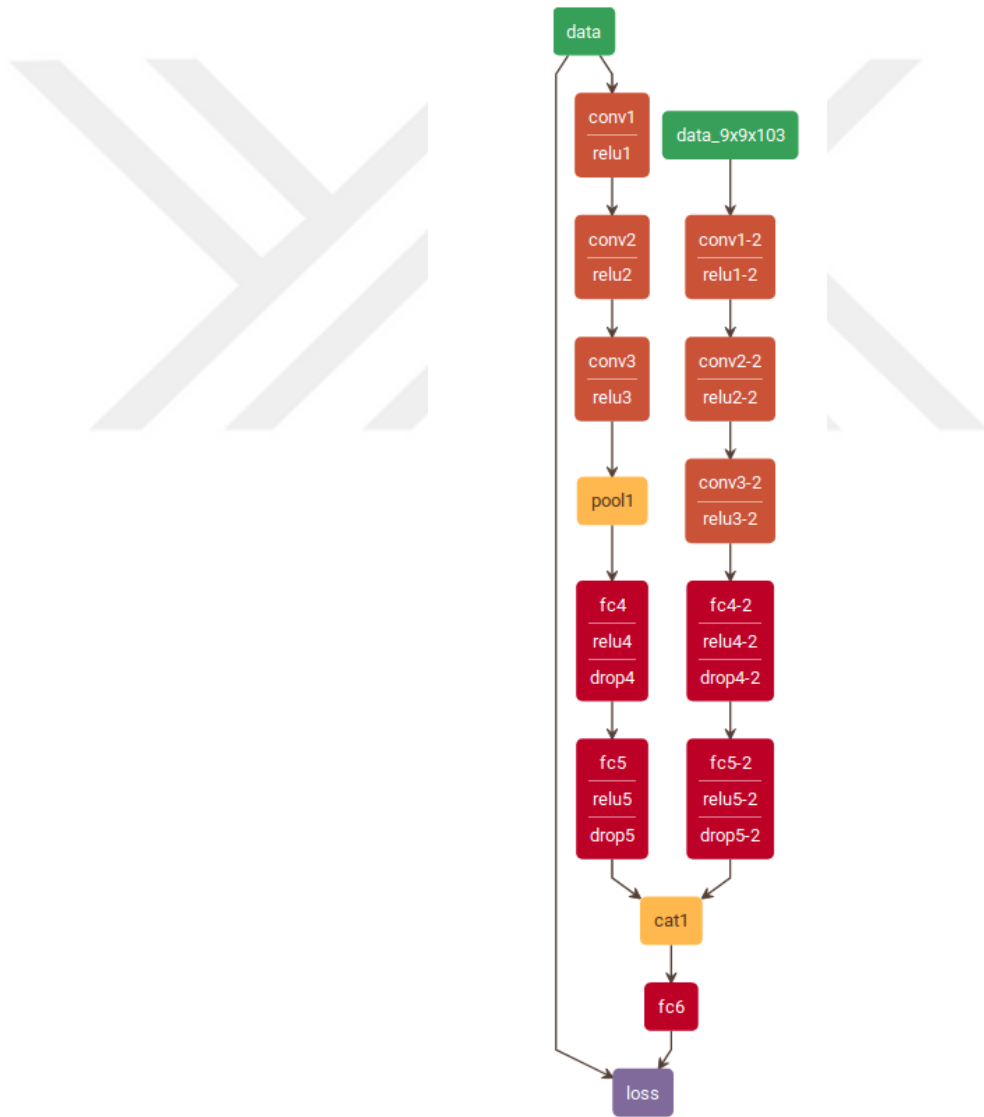


Şeki 4.5. Pavia Üniversitesi TBA ile İndirgen 4 Bantın Görüntüleri

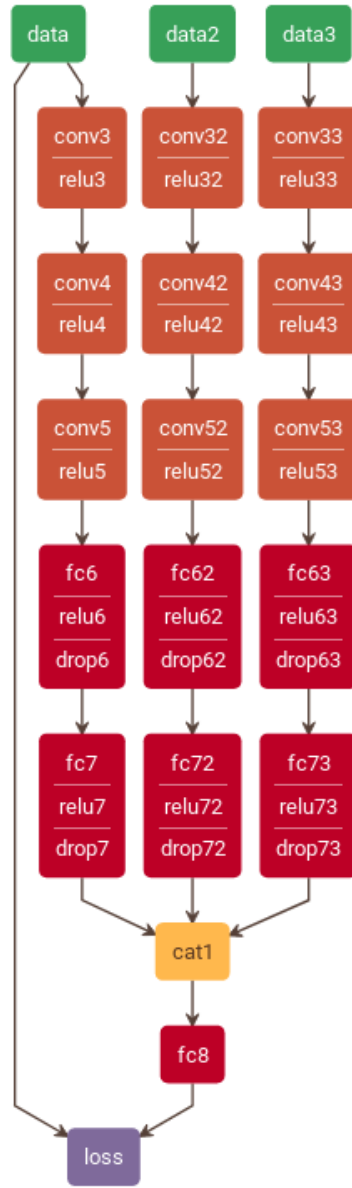
TBA ile indirgenmiş görüntüler üzerinden  $5 \times 5 - 9 \times 9 - 15 \times 15$  piksel boyutlu pencereler ile  $5 \times 5 \times 4$ ,  $9 \times 9 \times 4$  ve  $15 \times 15 \times 4$  büyüklüğünde yamalar seçilerek elde edilen tensörler Şekil 4.4'deki aynı model ile sınıflandırılmıştır.

#### 4.2.4. Farklı ölçekli yamaların kaynaştırılması ile sınıflandırma

Bu yöntem de ise Şekil 4.6'da ve Şekil 4.7'de görülebileceği gibi sadece spektral bilgiyi içeren bir boyutlu piksel vektörleri ile yama tabanlı tensörleri evrişimsel sinir ağı modellerini koruyarak aynı anda eğitip, son katmandan bir önce uç uca kaynaştırılması ile oluşturulmuştur modeldir.



Şekil 4.6. Spektral Vektörlerin ve Yamaların Aynı Anda Eğitilip Kaynaştırıldığı  
ESA Modeli



Şekil 4.7. Farklı Boyutlardaki Yamaların Aynı Anda Eğitilip Kaynaştırıldığı  
ESA Modeli

#### 4.2.5. Farklı ölçekli yamaların kaynaştırılması ile sınıflandırma

HSG'lerde piksel sınıflandırma yapmanın zorluklarından en önemlilerinden bir tanesi eğitim piksel sayısının çok az sayıda olmasıdır. Bu sorunu aşmak için bazı temel veri artırma yöntemleri kullanılabilir. Etiketli her piksel merkez pikseli olacak şekilde sabit bir pencere ile seçilen tensörler dikey yansıtma, yatay yansıtma,  $45^\circ$  -  $135^\circ$  -  $225^\circ$  -  $270^\circ$  derece döndürme işlemlerinin ile eğitim için kullanılacak toplam tensor sayısı 7 katına çıkartılmıştır. Bu veri artırma tekniği hem orjinal 103 spektral bantlı görüntüden elde edilen tensörlere hem de TBA ile 4 banta indirgenmiş tensörler uygulanarak eğitim veri sayısı arttırılmıştır. Yukarıda bahsedilmiş olan modeller üzerinde hem veri arttırma işlemi uygulanmadan hem de veri arttırılmış datalar ile sınıflandırma başarımları incelenmiştir. Deney sonuçları 5. Bölüm'de gösterilmiştir.

#### 4.2.6. Çalışma ortamı

Hesaplamalar Ubuntu 16.04 LTS üzerinde GeForce Nvidia GTX 1080 GPU'lu Intel 7700 3,60 GHz  $\times$  8 işlemci ile Caffè kütüphanesi kullanılarak yapılmıştır.

## V. SONUÇLAR

Hiperspektral görüntüleme uzaktan algılama alanındaki en güçlü araçlardan biridir. Hiperspektral görüntülerin içerdikleri yüksek miktardaki spektral bilgi kullanılarak, sınıflandırma, tespit ve tanıma gibi görüntü işleme işlevleri standart görüntülere göre çok daha başarılı olarak gerçekleştirilebilmektedir. Hiperspektral görüntüler spektral imza ile birlikte uzamsal bilginin de kullanılması başarımı attıran bir yaklaşımdır. Komşu piksellerin benzer etiketlere sahip olma olasılığı yüksektir.

### 5.1. Spektral İmzalar ile

**Deney 1: Sadece spektral (izgesel) bilgi ile:** Giriş olarak her pikseli olduğu gibi tüm spektral bantlarla birlikte verilmesi ile elde edilen deney sonuçları Tablo 5.1’de verilmiştir.

Tablo 5.1. Deney 1 Sonuçları

		<b>ACC</b>	<b>KAPPA</b>
a	1x103 piksel vektör	0,84	0,79

### 5.2. Spektral ve Uzamsal İmzalar ile

**Deney 2: Uzamsal ve spektral (izgesel) bilgi ile:** Giriş olarak her piksel için seçilen çerçeve kadar etrafındaki komşu piksellerin tüm spektral bantlarla birlikte verilmesi ile elde edilen deney sonuçları Tablo 5.2’de verilmiştir.

Tablo 5.2. Deney 2 Sonuçları

		<b>ACC</b>	<b>KAPPA</b>
a	3x3x103 tensör	0,85	0,85
b	5x5x103 tensör	0,87	0,81
c	7x7x103 tensör	0,86	0,85
d	9x9x103 tensör	0,90	0,85

### 5.3. Temel Bileşenler Analizi ile

**Deney 3: Uzamsal bilgi ve temel bileşenler analizi yaklaşımı ile:** Giriş olarak her piksel için seçilen çerçeve kadar etrafındaki komşu piksellerin TBA ile indirgenmiş 4 spektral bantla birlikte verilmesi

Tablo 5.3. Deney 3 Sonuçları

		<b>ACC</b>	<b>KAPPA</b>
a	5x5x4 tensör	0,83	0,80
b	9x9x4 tensör	0,84	0,82
c	15x15x4 tensör	0,84	0,75

#### 5.4. Spektral ve Uzamsal İmzalarla Farklı Ölçekli Kaynaştırma ile

**Deney 4: Kaynaştırma ile:** 1D Vektör ve 3D Tensör ile ayrı iki modelin eğitilerek son tam bağlantılı katmanda kaynaştırılması ile elde edilen deney sonuçları Tablo 5.4’de verilmiştir.

Tablo 5.4. Deney 4 Sonuçları

		<b>ACC</b>	<b>KAPPA</b>
a	1x103 ve 9x9x103	0,83	0,76

**Deney 5:** Farklı boyutlardaki yamaların kaynaştırma ile elde edilen deney sonuçları Tablo 5.5’de verilmiştir.

Tablo 5.5. Deney 5 Sonuçları

		<b>ACC</b>	<b>KAPPA</b>
a	5x5x103 ve 9x9x103	0,85	0,85
b	5x5x4 ve 9x9x4	0,81	0,79
c	5x5x4 ve 9x9x4 ve 15x15x4	0,85	0,84

#### 5.5. Veri Arttırılmış Spektral ve Uzamsal İmzalar ile

**Deney 6:** Dikey Yansıtma / Yatay Yansıtma /Döndürme (45° - 135° - 225°- 270°) ile eğitim piksel sayısı 7 katına çıkartılmış ve farklı boyutlarda yamalar seçilerek elde edilen deney sonuçları Tablo 5.6’da verilmiştir.

Tablo 5.6. Deney 6 Sonuçları

		<b>ACC</b>	<b>KAPPA</b>	<b>Eğitim Piksel Sayısı</b>	<b>Yöntem</b>
a	3x3x103 tensör	0,83	0,75	27447	Dikey Yansıtma/Yatay Yansıtma/Döndürme (45°-135°-225°-270°)
b	5x5x103 tensör	0,83	0,77	27447	Dikey Yansıtma/Yatay Yansıtma/Döndürme (45°-135°-225°-270°)
c	7x7x103 tensör	0,84	0,79	27447	Dikey Yansıtma/Yatay Yansıtma/Döndürme (45°-135°-225°-270°)
d	9x9x103 tensör	0,86	0,82	27447	Dikey Yansıtma/Yatay Yansıtma/Döndürme (45°-135°-225°-270°)




## 5.6. Veri Arttırılmış Spektral ve Uzamsal İmzalarla Farklı Ölçekli Kaynaştırma ile

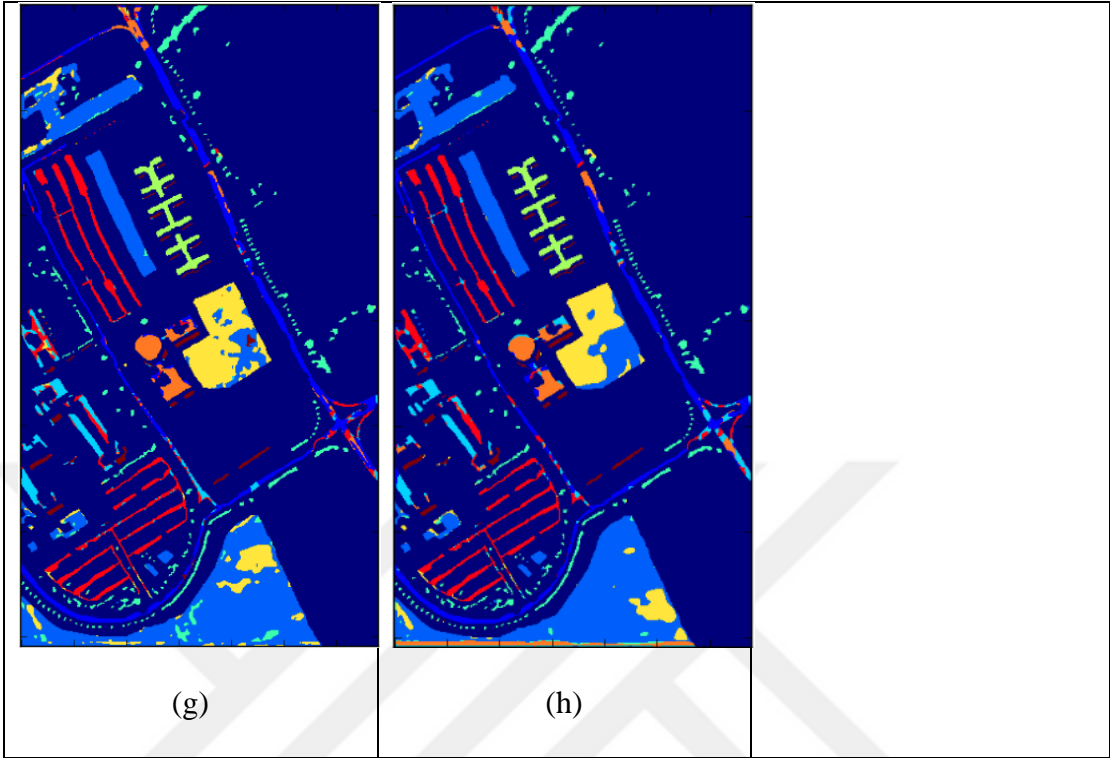
**Deney 7:** Veri arttırılmış 1D Vektörler ve 3D Tensörler ile ayrı iki modelin eğitilerek son tam bağlantılı katmanda kaynaştırılmasıyla elde edilen deney sonuçları Tablo 5.7 de verilmiştir.

Tablo 5.7. Deney 7 Sonuçları

		ACC	KAPPA	Eğitim Piksel Sayısı	Yöntem
a	1x103 ve 9x9x103	0,83	0,76	27447	Dikey Yansıtma/Yatay Yansıtma/ Döndürme (45°- 135°-225°-270°)
b	5x5x103 ve 9x9x103	0,86	0,85	27447	Dikey Yansıtma/Yatay Yansıtma/ Döndürme (45°- 135°-225°-270°)

Tüm deney sonuçlarının sınıflandırma haritaları Şekil 5.1’de gösterilmektedir.






Şekil 5.1. Deney Sonuçlarının Sınıflandırma Haritaları


- (a) Deney 1-a: 1x103,
- (b) Deney 2-a: 3x3x103,
- (c) Deney 2-b: 5x5x103,
- (d) Deney 2-c: 7x7x103,
- (e) Deney 2-d: 9x9x103,
- (f) Deney 3-a: 5x5x4,
- (g) Deney 3-b: 9x9x4,
- (h) Deney 3-c: 15x15x4,

### Sınıf içi sınıflandırma değerleri


Deney 1-a'nın, Deney 2-b'nin ve Deney 2-d'nin sınıflandırma sonuçlarının karışıklık matrisi sırasıyla Şekil 5.2 - 5.4'te gösterilmiştir.



Şekil 5.2. 1x103 Giriş Datasının Karışıklık Matrisi



Şekil 5.3. 5x5x103 Giriş Datasının Karışıklık Matrisi



Şekil 5.4. 9x9x103 Giriş Datasının Karışıklık Matrisi

Tablo 5.8. Tüm Deney Sonuçları

#	BOYUT	ACC	KAPPA	EĞİTİM SAYISI
Deney 1	1x103	0,84	0,79	3921
Deney 2	3x3x103	0,85	0,85	3921
	5x5x103	0,87	0,81	3921
	7x7x103	0,86	0,85	3921
	<b>9x9x103</b>	<b>0,90</b>	<b>0,85</b>	3921
Deney 3	5x5x4	0,83	0,80	3921
	9x9x4	0,84	0,82	3921
	15x15x4	0,84	0,75	3921
Deney 4	1x103 ve 9x9x103	0,83	0,76	3921
Deney 5	5x5x103 ve 9x9x103	0,85	0,85	3921
	5x5x4 ve 9x9x4	0,81	0,79	3921
	5x5x4 ve 9x9x4 ve 15x15x4	0,85	0,84	3921
Deney 6	3x3x103 tensör	0,83	0,75	27447
	5x5x103 tensör	0,83	0,77	27447
	7x7x103 tensör	0,84	0,79	27447
	9x9x103 tensör	0,86	0,82	27447
Deney 7	1x103 ve 9x9x103	0,83	0,76	27447
	5x5x103 ve 9x9x103	0,86	0,85	27447

## 5.7. Tartışma

Hiperspektral görüntüleme alanında, sadece spektral imza kullanmak yerine mekansal alan bilgisini sınıflandırma görevine dahil etmek her zaman tercih edilen bir yöntem olmuştur. Bu çalışmada, komşu piksellerin bilgilerinin kullanılması, bir piksel grubunun aynı sınıfa ait olduğu bölgeleri tanımlayarak haritalamanın doğruluğunu geliştirmektedir. Spektral bilginin tamamı kullanılarak komşu piksellerden yararlanmak için farklı büyüklükte pencereler seçilmiş ve Tablo 5.8’de görüldüğü gibi tüm deney sonuçları arasında en ideal pencere boyutu 9x9 olarak belirlenmiştir. Daha büyük pencereler seçebilmek ve işlem hızını arttırmak için TBA ile 4 banta indirgenmiştir. 4 bant spektral bilgi ile en büyük 15x15 büyüklüğünde pencere seçilerek daha fazla komşu pikselin etiketleme başarımına etkisi incelenmiştir. Komşu piksel bilgisi yararlı olsa da, hala yanlış etiketlenmiş örnekler bulunmaktadır. Bu yüzden yansıtma ve döndürme işlemleri ile veri arttırma yöntemleri eğitim verisetindeki piksel sayısı arttırılmış ancak başarıma olumlu yönde katkısı görülmemiştir. Farklı bir model olarak, hem sadece spektral bilgiyi içerek 1D lik vektör ile komşu pikselleri içeren tensörler seçilerek hem de farklı boyutlardaki pencereler seçilerek aynı anda eğitilmiş ve kaynaştırma yöntemi kullanılmıştır.



## VI. GELECEK ÇALIŞMALAR

Hiperspektral görüntülerde etiketli piksel sayısı az olduğundan, derin öğrenme yöntemlerini daha verimli kullanabilmek adına veri arttırma yöntemleri araştırılabilir. Bu tez çalışmasında dikey ve yatay yansıtma,  $45^\circ$  -  $135^\circ$  -  $225^\circ$  -  $270^\circ$  derecelerde döndürme işlemi ile veri arttırma uygulanmış ancak sınıflandırma başarımına etkisi gözlemlenmemiştir. Bant sayısı ile orantılı ve sınıf içi dağılımı da dengeleyecek şekilde yeni bir veri arttırma yaklaşımı üzerinde yapılacak çalışmalar sınıflandırma başarısını olumlu yönde etkileyebilir. Ayrıca bu tez çalışmasındaki aynı yaklaşımlar literatürde sıklıkla kullanılan Indian Pines, Salinas gibi farklı sınıf ve farklı bant sayısına sahip hiperspektral verisetleri üzerinde gerçekleştirilip ve sonuçları karşılaştırılarak yaklaşımın başarısı test edilebilir.

## KAYNAKÇA

- [1] Esat,K. (2005). Uydu Görüntüleri ve Jeolojideki Kullanımlarına Genel Bakış. *Mavi Gezegen Popüler Yer Bilim Dergisi*, 11, 37.
- [2] Yüksel, S. E., & Boyacı, M. (2018). LiDAR sensörünün hiperspektral verilerden gölgelik alan çıkarımı başarımına etkisi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 198-204.
- [3] Gur, D., Leshem, B., Pierantoni, M., Farstey, V., Oron, D., Weiner, S., & Addadi, L. (2015). Structural basis for the brilliant colors of the sapphirinid copepods. *Journal of the American Chemical Society*, 137(26), 8408-8411.
- [4] Medjahed, S. A., Saadi, T. A., Benyettou, A., & Ouali, M. (2016). Gray Wolf Optimizer for hyperspectral band selection. *Applied Soft Computing*, 40, 178-186.
- [5] Lv, Q., Niu, X., Dou, Y., Xu, J., & Xia, F. (2016). Leveraging local receptive fields based random weights networks for hyperspectral image classification. *Journal of Intelligent & Fuzzy Systems*, 31(2), 1017-1028.
- [6] Hu, W., Huang, Y., Wei, L., Zhang, F., & Li, H. (2015). Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015.
- [7] Kim, D. W., Lee, K., Lee, D., & Lee, K. H. (2005). A kernel-based subtractive clustering method. *Pattern Recognition Letters*, 26(7), 879-891.
- [8] Rajpoot, K., & Rajpoot, N. M. (2004). Hyperspectral colon tissue cell classification.
- [9] Maggioni, M., Davis, G. L., Warner, F. J., Geshwind, F. B., Coppi, A. C., DeVerse, R. A., & Coifman, R. R. (2006, February). Hyperspectral microscopic analysis of

normal, benign and carcinoma microarray tissue sections. In *Optical Biopsy VI* (Vol. 6091, p. 60910I). International Society for Optics and Photonics.

[10] Cathcart, J. M., Bock, R. D., & Campbell, R. (2006). Analysis of Soil and Environmental Processes on Hyperspectral Infrared Signatures of Landmines. In *Transformational Science And Technology For The Current And Future Force: (With CD-ROM)*(pp. 534-540).

[11] Briottet, X., Boucher, Y., Dimmeler, A., Malaplate, A., Cini, A., Diani, M., ... & Renhorn, I. (2006, May). Military applications of hyperspectral imagery. In *Targets and Backgrounds XII: Characterization and Representation* (Vol. 6239, p. 62390B). International Society for Optics and Photonics.

[12] LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning. nature, 521(7553), 436.*

[13] Matsugu, M., Mori, K., Mitari, Y., & Kaneda, Y. (2003). Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks, 16(5-6), 555-559.*

[14] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature, 323(6088), 533.*

[15] Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... & Darrell, T. (2014, November). Caffe: Convolutional architecture for fast feature embedding. In *Proceedings of the 22nd ACM international conference on Multimedia* (pp. 675-678). ACM.

[16] Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... & Darrell, T. (2014, November). Caffe: Convolutional architecture for fast feature

- embedding. In *Proceedings of the 22nd ACM international conference on Multimedia* (pp. 675-678). ACM.
- [17] Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.
- [18] Hu, W., Huang, Y., Wei, L., Zhang, F., & Li, H. (2015). Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015.
- [19] Chen, Y., Zhao, X., & Jia, X. (2015). Spectral–spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2381-2392.
- [20] Slavkovikj, V., Verstockt, S., De Neve, W., Van Hoescke, S., & Van de Walle, R. (2015, October). Hyperspectral image classification with convolutional neural networks. In *Proceedings of the 23rd ACM international conference on Multimedia* (pp. 1159-1162). ACM.
- [21] Tao, C., Pan, H., Li, Y., & Zou, Z. (2015). Unsupervised spectral–spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification. *IEEE Geoscience and remote sensing letters*, 12(12), 2438-2442.
- [22] Salman, M., & Yüksel, S. E. (2016, May). Hyperspectral data classification using deep convolutional neural networks. In *Signal Processing and Communication Application Conference (SIU)*, 2016 24th (pp. 2129-2132). IEEE.
- [23] Zhao, W., & Du, S. (2016). Spectral–spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4544-4554.

- [24] Ghamisi, P., Chen, Y., & Zhu, X. X. (2016). A self-improving convolution neural network for the classification of hyperspectral data. *IEEE Geoscience and Remote Sensing Letters*, 13(10), 1537-1541.
- [25] Chen, Y., Jiang, H., Li, C., Jia, X., & Ghamisi, P. (2016). Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 54(10), 6232-6251.
- [26] Lee, H., & Kwon, H. (2016, July). Contextual deep CNN based hyperspectral classification. In *Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International* (pp. 3322-3325). IEEE.
- [27] Li, Y., Zhang, H., & Shen, Q. (2017). Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sensing*, 9(1), 67.
- [28] Aptoula, E., Ozdemir, M. C., & Yanikoglu, B. (2016). Deep learning with attribute profiles for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 13(12), 1970-1974.
- [29] Li, W., Wu, G., Zhang, F., & Du, Q. (2017). Hyperspectral image classification using deep pixel-pair features. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 844-853.
- [30] Liu, Q., Zhou, F., Hang, R., & Yuan, X. (2017). Bidirectional-Convolutional LSTM Based Spectral-Spatial Feature Learning for Hyperspectral Image Classification. *Remote Sensing*, 9(12), 1330.
- [31] Landgrebe, D. A. (2005). *Signal theory methods in multispectral remote sensing* (Vol. 29). John Wiley & Sons.

- [32] Goel, P. K., Prasher, S. O., Patel, R. M., Landry, J. A., Bonnell, R. B., & Viau, A. A. (2003). Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computers and Electronics in Agriculture*, 39(2), 67-93.
- [33] Yang, H. (1999). A back-propagation neural network for mineralogical mapping from AVIRIS data. *International Journal of Remote Sensing*, 20(1), 97-110.
- [34] Vaiphasa, C. (2003, October). Innovative genetic algorithm for hyperspectral image classification. In *Proc. Int. Conf. Map Asia*(Vol. 20, p. 45).
- [35] Camps-Valls, G., & Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6), 1351-1362.
- [36] Gualtieri, J. A., & Crompton, R. F. (1999, January). Support vector machines for hyperspectral remote sensing classification. In *27th AIPR Workshop: Advances in Computer-Assisted Recognition*(Vol. 3584, pp. 221-233). International Society for Optics and Photonics.
- [37] Fauvel, M., Chanussot, J., & Benediktsson, J. A. (2006, May). Evaluation of kernels for multiclass classification of hyperspectral remote sensing data. In *Acoustics, Speech and Signal Processing, 2006. ICASSP 2006 Proceedings. 2006 IEEE International Conference on* (Vol. 2, pp. II-II). IEEE.
- [38] Fauvel, M., Benediktsson, J. A., Chanussot, J., & Sveinsson, J. R. (2008). Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 46(11), 3804-3814.

- [39] Farag, A. A., Mohamed, R. M., & El-Baz, A. (2005). A unified framework for map estimation in remote sensing image segmentation. *IEEE Transactions on Geoscience and Remote Sensing*, 43(7), 1617-1634.
- [40] Dell'Acqua, F., Gamba, P., Ferrari, A., Palmason, J. A., Benediktsson, J. A., & Árnason, K. (2004). Exploiting spectral and spatial information in hyperspectral urban data with high resolution. *IEEE Geoscience and Remote Sensing Letters*, 1(4), 322-326.
- [41] Benediktsson, J. A., Palmason, J. A., & Sveinsson, J. R. (2005). Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 480-491.
- [42] Camps-Valls, G., Gomez-Chova, L., Muñoz-Marí, J., Vila-Francés, J., & Calpe-Maravilla, J. (2006). Composite kernels for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 3(1), 93-97.
- [43] Agarwal, A., El-Ghazawi, T., El-Askary, H., & Le-Moigne, J. (2007, December). Efficient hierarchical-PCA dimension reduction for hyperspectral imagery. In *Signal Processing and Information Technology, 2007 IEEE International Symposium on* (pp. 353-356). IEEE.

# ÖZGEÇMİŞ

**Yavuz KÖMEÇOĞLU**

**E-posta:** komecoglu.yavuz@gmail.com

**Website:** http://yavuzkomecoglu.com

## EĞİTİM

Lise	2004 - 2008	Yüksel-İlhan Alanyalı Anadolu Öğretmen Lisesi
Lisans	2008 - 2012	Kocaeli Üniversitesi Fen-Edebiyat Fakültesi Matematik Bölümü
Yüksek Lisans	2014 - 2018	Okan Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği

## İŞ DENEYİMLERİ

04.2012 – 06.2012	Retua Desing Lab. Yazılım Geliştirici
09.2011 – 06.2012	Kocaeli Üniversitesi Fen-Edebiyat Fakültesi Web Sorumlusu
06.2013 – 05.2017	KumSaati – Tasarım ve Bilgi Sistemleri Yazılım Geliştirici

## YAYINLAR

### Ulusal Bildiri

2016	<b>Yavuz Kömeçoğlu</b> , Çetin Oktay, Nilgün İncereis, Levent Yıldız, Aslı Uyar, “Sequence Oyununun Minimaks Algoritması Kullanılarak Tasarlanması Ve Geliştirilmesi”, XVIII. Akademik Bilişim Konferansı, 2016
------	---