



**HİPERSPEKTRAL GÖRÜNTÜLERDE DERİN  
ÖĞRENME YAKLAŞIMININ SINIFLANDIRMA  
BAŞARIMI ÜZERİNE ETKİSİ**

**Gizem ORTAÇ**



T.C.  
BURSA ULUDAĞ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**HİPERSPEKTRAL GÖRÜNTÜLERDE DERİN ÖĞRENME YAKLAŞIMININ  
SINIFLANDIRMA BAŞARIMI ÜZERİNE ETKİSİ**

**Gizem ORTAÇ**  
**ORCID ID: 0000-0003-1228-9852**

Dr. Öğr. Üyesi Gıyasettin ÖZCAN  
ORCID ID: 0000-0002-1166-5919  
(Danışman)

**YÜKSEK LİSANS TEZİ**  
**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

BURSA – 2019

## TEZ ONAYI

Gizem ORTAÇ tarafından hazırlanan “HİPERSPEKTRAL GÖRÜNTÜLERDE DERİN ÖĞRENME YAKLAŞIMININ SINIFLANDIRMA BAŞARIMI ÜZERİNE ETKİSİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

**Danışman** : Dr. Öğr. Üyesi Gıyasettin ÖZCAN

**Başkan** : Dr. Öğr. Üyesi Gıyasettin ÖZCAN  
ORCID ID: 0000-0002-1166-5919  
Uludağ Üniversitesi, Mühendislik Fakültesi,  
Bilgisayar Mühendisliği Anabilim Dalı

İmza

**Üye** : Dr. Öğr. Üyesi Metin BİLGİN  
Uludağ Üniversitesi, Mühendislik Fakültesi,  
Bilgisayar Mühendisliği Anabilim Dalı

İmza

**Üye** : Dr. Öğr. Üyesi Ergün GÜMÜŞ  
ORCID ID: 0000-0002-1327-6845  
Bursa Teknik Üniversitesi,  
Mühendislik ve Doğa Bilimleri Fakültesi,  
Bilgisayar Mühendisliği Anabilim Dalı

İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN  
Enstitü Müdürü

.././.....

**U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;**

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

**beyan ederim.**

16/07/2019



**Gizem ORTAÇ**

## ÖZET

Yüksek Lisans Tezi

### HİPERSPEKTRAL GÖRÜNTÜLERDE DERİN ÖĞRENME YAKLAŞIMININ SINIFLANDIRMA BAŞARIMI ÜZERİNE ETKİSİ

**Gizem ORTAÇ**

Bursa Uludağ Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

**Danışman:** Dr. Öğr. Üyesi Gıyasettin ÖZCAN

Hiperspektral sensörlerin gelişimiyle beraber hiperspektral görüntüleme uzaktan algılama alanında oldukça ilgi çeken bir konu haline gelmiştir. Görüntülenen yüzey materyallerinden yansıyan enerjinin dar ve bitişik çok sayıda dalga boyunda ölçüm yapılmasını sağlayan hiperspektral görüntüleme, oldukça yüksek boyutta ve birbiriyle ilişkili veri elde edilmesini sağlamaktadır. Bu verilerin saklanması, işlenmesi ve yorumlanması; hesaplama karmaşıklığı ve işlem yükü sebebiyle oldukça zordur. Bu nedenle hiperspektral verilerin sınıflandırılmasında geleneksel olarak ön işlem aşamasında boyut indirgeme yöntemleri uygulanmaktadır. Bununla birlikte geleneksel sınıflandırıcılar ve boyut indirgeme yöntemleri spektral boyutta zorlu bir işlemdir ve ayırt edici özneliklerin çıkarımında yetersiz kalmaktadır. Aynı zamanda kesin bir sınıflandırıcı ve boyut indirgeme yöntemi seçim yöntemi de bulunmamaktadır. Son yıllarda ise derin öğrenme yöntemleri kullanılarak hiperspektral verilerin alt uzaya indirgenmeden daha gürbüz, uyarlanabilir ve ham verilerden çıkarılan öznelikler ile sınıflandırılması oldukça dikkat çekici bir yaklaşım olmuştur. Hiperspektral görüntülerin derin öğrenme yöntemlerinden özellikle evrişimsel sinir ağları ile sınıflandırımı umut vadeci sonuçlar sağlamaktadır.

Tez kapsamında, yaygın olarak tercih edilen hiperspektral veri setleri kullanılarak uzaysal, spektral ve uzaysal-spektral öznelikleri kullanan bir boyutlu, iki boyutlu ve üç boyutlu evrişimsel sinir ağları ile sınıflandırma yapılmıştır. Spektral ve uzaysal boyutlardaki özneliklerin hem ayrı ayrı hem de birlikte kullanımı ile hiperspektral sensörler tarafından sağlanan tüm öznelikler etkin olarak sınıflandırmaya dahil edilmiştir. Ayrıca yapılan çalışmada, geleneksel sınıflandırma ve konvolüsyonel sinir ağları arasında karşılaştırmalı bir çalışma ve analiz yapılmıştır. Yapılan deneysel çalışmalar ile evrişimsel sinir ağları kullanılarak oldukça yüksek sınıflandırma başarısı elde edilmiştir. Aynı zamanda önerilen konvolüsyonel sinir ağı mimarilerinin, geleneksel yöntemlerden %5 ve %9 oranında daha iyi bir sınıflandırma oranı sağladığı görülmüştür.

**Anahtar Kelimeler:** Hiperspektral görüntüleme, derin öğrenme, boyut indirgeme, evrişimsel sinir ağları **2019, viii + 103 sayfa.**

## ABSTRACT

MSc Thesis

### THE EFFECT OF DEEP LEARNING APPROACH ON CLASSIFICATION PERFORMANCE IN HYPERSPECTRAL IMAGES

**Gizem ORTAÇ**

Bursa Uludağ University  
Graduate School of Natural and Applied Sciences  
Department of Computer Engineering

**Supervisor:** Assist. Prof. Dr. Gıyasettin ÖZCAN

With the development of hyperspectral sensors, hyperspectral imaging has become a subject of interest in the field of remote sensing. Hyperspectral imaging, which allows measurement of reflected energy from the displayed surface materials at a narrow and adjacent plurality of wavelengths, provides extremely high dimensional and interrelated data. Storing, processing and interpreting and calculating this data is very difficult due to its complexity and processing load. Therefore, in the classification of hyperspectral data, size reduction methods are traditionally used as pre-processing step. However, conventional classifiers and dimension reduction methods are challenging in the spectral dimension and are inadequate in the extraction of distinctive features. There is also no definitive classifier and dimension reduction method selection method. In recent years, it has been a remarkable approach to classify the hyperspectral data with more robust, adaptable and extracted features from raw data by deep learning methods without reducing to subspace. Especially, the classification of hyperspectral images with convolutional neural networks, one of the deep learning methods, provides promising results.

Within the scope of this thesis, samples of widely used hyperspectral data sets are classified by using one-dimensional, two-dimensional and three-dimensional convolutional neural networks by extracting spatial, spectral and spatial-spectral features. All the features provided by hyperspectral sensors are included in the classification effectively by using both separately and together spectral and spatial features. In addition, a comparative study and analysis is conducted between conventional classification and convolutional neural networks. Experimental studies have shown that convolutional neural networks have achieved very high classification rates. It has also shown that the proposed convolutional neural network architectures provide a better classification rate of 5% and 9% than the conventional methods.

**Key words:** Hyperspectral imaging, deep learning, dimension reduction, convolutional neural networks **2019, viii + 103 pages.**

## TEŞEKKÜR

Yüksek lisans eğitim boyunca ve bu tezin gerçekleştirilmesinde bilgi ve tecrübeleriyle bilimsel çalışmalarımı yönlendiren ve destek olan başta danışmanım saygıdeğer Dr. Öğr. Üyesi Gıyasettin ÖZCAN olmak üzere; çalışma hayatımda her zaman desteğini ve yardımlarını hissettiğim Bursa Teknik Üniversitesi Bilgisayar Mühendisliği bölüm başkanı saygıdeğer hocam Doç. Dr. Turgay Tugay BİLGİN'e ve Bilgisayar Mühendisliği Bölümü hocalarıma, lisans ve yüksek lisans sürecimde desteğini ve yardımlarını esirgemeyen Süleyman Demirel Üniversitesi'nden saygıdeğer hocam Prof. Dr. Ecir Uğur KÜÇÜKSİLLE, yakın arkadaşlarım ve eğitim hayatımda her zaman yanımda olan başta babam olmak üzere tüm aileme şükran ve minnetlerimi sunarım.

Gizem ORTAÇ  
16/07/2019

## İÇİNDEKİLER

	Sayfa
ÖZET .....	i
ABSTRACT .....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ .....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ .....	viii
1. GİRİŞ .....	1
1.1. Genel Bakış .....	1
1.2. Problem .....	1
1.3. Probleme Yaklaşım .....	3
1.4. Tezin Ana Hatları .....	4
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI .....	5
2.1. Uzaktan Algılama.....	10
2.1.1. Uzaktan algılama sistemlerinin tarihi.....	12
2.1.2. Elektromanyetik spektrum .....	13
2.1.3. Uzaktan algılamada çözünürlük.....	14
2.2. Hiperspektral Uzaktan Algılama.....	16
2.2.1. Hiperspektral algılayıcılar .....	18
2.2.2. Hiperspektral görüntülerin yapısı.....	18
2.3.1. Algılayıcı (Perceptron).....	21
2.3.2. Çok katmanlı algılayıcılar (Multilayer perceptron) .....	23
2.3.3. Aktivasyon fonksiyonları .....	26
2.4. Derin Öğrenme.....	29
2.4.1. Evrimsel sinir ağları (ESA) .....	31

2.4.2. Evrişimsel sinir ağı eğitimi .....	38
2.5. Boyut İndirgeme.....	53
2.5.1. Öznitelik çıkarma .....	54
3. MATERYAL VE YÖNTEM .....	55
3.1. Materyal .....	55
3.1.1. Veri setleri.....	56
3.1.2. Deney kurulumu.....	59
3.1.3. Performans ölçütleri .....	59
3.2. Yöntem.....	61
3.2.1. Evrişimsel sinir ağı ile sınıflandırma .....	61
3.2.2. Boyut indirgeme yöntemleriyle sınıflandırma .....	74
4. BULGULAR ve TARTIŞMA.....	77
4.1. 1B –ESA Sınıflandırma Sonuçları .....	77
4.2. 2B-ESA Sınıflandırma Sonuçları.....	82
4.3. 3B-ESA Sınıflandırma Sonuçları.....	87
4.4. Boyut İndirgeme Yöntemleriyle Sınıflandırma Sonuçları .....	92
5. SONUÇ .....	94
KAYNAKLAR .....	96
ÖZGEÇMİŞ .....	103

## SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
DN	Doğru Negatif
DP	Doğru Pozitif
m	metre
nm	nanometre
S	Filtre Adım Sayısı (Stride)
YN	Yanlış Negatif
YP	Yanlış Pozitif
$\eta$	Öğrenme adımı
$\mu\text{m}$	mikrometre

Kısaltmalar	Açıklama
1B-ESA	Bir Boyutlu Evrişimsel Sinir Ağı
2B-ESA	İki Boyutlu Evrişimsel Sinir Ağı
3B-ESA	Üç Boyutlu Evrişimsel Sinir Ağı
Ada	Ada Boost Sınıflandırıcı
AE	Otomatik Kodlayıcı (Autoencoder)
DBN	Derin İnanç Ağı (Deep Relief Networks)
DTC	Karar Ağacı Sınıflandırıcısı (Decision Tree Classifier)
ESA	Evrişimsel Sinir Ağları (Convolutional Neural Networks)
FA	Faktör Analizi (Factor Analysis)
FE	Öznitelik Çıkarma (Feature Extraction)
GPC	Gauss Process Sınıflandırıcı
ICA	Bağımsız Bileşen Analizi (Independent Component Analysis)
kNN	K-En Yakın Komşuluk (K-nearest Neighbor)
LDA	Doğrusal Ayırtaç Analizi (Linear Discriminant Analysis)
LR	Lojistik Regresyon (Logistic Regression)
MLP	Çok Katmanlı Algılayıcı
MSS	Multispectral Scanner Systems
PCA	Temel Bileşen Analizi (Principal Component Analysis )
QDC	Quadratic Discriminant Sınıflandırıcı
RBM	Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines)
ReLU	Rectified Linear Unit
RFC	Rassal Orman Sınıflandırıcısı (Random Forest Classifier)
RFs	Karar Ormanları (Random Forests)
SAE	Yığılmış Otomatik Kodlayıcı (Stacked Autoencoder)
SVD	Tekil Değer Ayrışımı (Singular Value Decomposition)
SVM	Destek Vektör Makinası (Support Vector Machine )
TM	Thematic Mapper

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 2.1. Hiperspektral görüntülemeye temel veri küp yapısı ve verinin eşzamanlı ve uzaysal karakteri (merkez), tek bir piksel için bir spektrum seti (solda), tek bir spektral kanal için bir görüntü yığını (sağda) (Manolakis ve ark. (2003)'den değiştirilerek alınmıştır) .....	20
Şekil 2.2. Algılayıcılarda veri akışı .....	22
Şekil 2.3. Örnek bir hiperdüzlem (Haykin 2009'den değiştirilerek alınmıştır) .....	23
Şekil 2.4. (L+1) adet katmana, D adet giriş ve C adet çıkışa sahip bir algılayıcı örneği (Stutz 2014'den değiştirilerek alınmıştır) .....	25
Şekil 2.5. Sigmoid aktivasyon fonksiyonu grafiği (Karlık ve Olgac 2011) .....	27
Şekil 2.6. Tanh aktivasyon fonksiyonu grafiği (Karlık ve Olgac 2011) .....	28
Şekil 2.7. ReLU aktivasyon fonksiyonu grafiği (Xu ve ark. 2015) .....	29
Şekil 2.8. İki boyutlu evrişim işlemi .....	32
Şekil 2.9. Çok kanallı görüntülerde iki boyutlu evrişim işlemi .....	33
Şekil 2.10. Hiperspektral görüntüde üç boyutlu evrişim işlemi .....	33
Şekil 2.11. 5x5 boyutunda (a) ve 3x3 boyutunda (b) filtre örnekleri .....	34
Şekil 2.12. Tam bağlı katman (Amidi ve Amidi 2019'den değiştirilerek alınmıştır) ....	37
Şekil 2.13. Dereceli azalma (gradient descent) .....	42
Şekil 2.14. Geri yayılım algoritması .....	45
Şekil 2.15. Üç katmanlı basitleştirilmiş bir yapay sinir ağı .....	45
Şekil 2.16. Standart yapay sinir ağı (a), seyreltme uygulanan yapay sinir ağı (b) (Khalifa ve Frigui 2016) .....	53
Şekil 3.1. Salinas veri seti örnek RGB bant görüntüsü ve doğruluk verisi .....	56
Şekil 3.2. Salinas veri seti sınıfları ortalama yansıma değerleri .....	57
Şekil 3.3. Pavia University veri seti örnek RGB bant görüntüsü ve doğruluk verisi .....	58
Şekil 3.4. Pavia University veri seti sınıfları ortalama yansıma değerleri .....	58
Şekil 3.5. Bir boyutlu evrişimsel sinir ağı (1B-ESA) .....	68
Şekil 3.6. İki boyutlu evrişimsel sinir ağı (2B-ESA) .....	69
Şekil 3.7. Üç boyutlu evrişimsel sinir ağı (3B-ESA) .....	73
Şekil 4.1. 1B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,01) (a) Salinas veri seti (b) Pavia University veri seti .....	78
Şekil 4.2. Öğrenme adımının 1B-ESA sınıflandırma başarımına etkisi .....	80
Şekil 4.3. Genişletilmiş 1B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,01) (a) Salinas veri seti (b) Pavia University veri seti .....	81
Şekil 4.4. 2B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a) Salinas veri seti (b) Pavia University veri seti .....	83
Şekil 4.5 Öğrenme adımının 2B-ESA sınıflandırma başarımına etkisi .....	85
Şekil 4.6. Genişletilmiş 2B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a) Salinas veri seti (b) Pavia University veri seti .....	86
Şekil 4.7. 3B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a) Salinas veri seti (b) Pavia University veri seti .....	88
Şekil 4.8. Öğrenme adımının 3B-ESA sınıflandırma başarımına etkisi .....	90
Şekil 4.9. Genişletilmiş 3B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a) Salinas veri seti (b) Pavia University veri seti .....	91

## ÇİZELGELER DİZİNİ

### Sayfa

Çizelge 2.1. RGB, multispektral ve hiperspektral görüntülemenin karşılaştırılması (Gowen ve ark. (2007)'dan değiştirilerek alınmıştır) .....	13
Çizelge 2.2. Aktivasyon Fonksiyonları .....	26
Çizelge 2.3. Maliyet Fonksiyonları .....	40
Çizelge 3.1. Salinas veri seti sınıflarına ait örnek sayıları .....	57
Çizelge 3.2. Pavia University veri seti sınıflarına ait örnek sayıları .....	59
Çizelge 3.3. Karmaşıklık matrisi .....	60
Çizelge 3.4. Hiperspektral görüntülerinin piksel seviyesinde sınıflandırma algoritması .....	62
Çizelge 3.5. Pavia University veri seti eğitim, doğrulama ve test örneği sayıları .....	63
Çizelge 3.6. Salinas veri seti eğitim, doğrulama ve test örneği sayıları .....	64
Çizelge 3.7. 1B-ESA yapısı .....	66
Çizelge 3.8. Genişletilmiş 1B ESA yapısı .....	67
Çizelge 3.9. 2B ESA yapısı .....	70
Çizelge 3.10. Genişletilmiş 2B-ESA yapısı .....	71
Çizelge 3.11. 3B-ESA yapısı .....	72
Çizelge 3.12. Genişletilmiş 3B-ESA yapısı .....	74
Çizelge 4.1. 1B-ESA çıktı ve parametre sayısı .....	77
Çizelge 4.2. Salinas veri seti 1B-ESA sınıflandırma sonucu karmaşıklık matrisi .....	78
Çizelge 4.3. Pavia University veri seti 1B-ESA sınıflandırma sonucu karmaşıklık matrisi .....	79
Çizelge 4.4. Genişletilmiş 1B-ESA çıktı ve eğitilebilir parametre sayıları .....	81
Çizelge 4.5. 2B-ESA çıktı ve eğitilebilir parametre sayıları .....	82
Çizelge 4.6. Pavia University veri seti 2B-ESA sınıflandırma sonucu karmaşıklık matrisi .....	84
Çizelge 4.7. Salinas veri seti 2B-ESA sınıflandırma sonucu karmaşıklık matrisi .....	84
Çizelge 4.8. Genişletilmiş 2B-ESA çıktı ve eğitilebilir parametre sayıları .....	86
Çizelge 4.9. 3B-ESA çıktı ve eğitilebilir parametre sayıları .....	87
Çizelge 4.10. Salinas veri seti 3B-ESA sınıflandırma sonucu karmaşıklık matrisi .....	89
Çizelge 4.11. Pavia University veri seti 3B-ESA sınıflandırma sonucu karmaşıklık matrisi .....	89
Çizelge 4.12. Genişletilmiş 3B-ESA çıktı ve eğitilebilir parametre sayıları .....	91
Çizelge 4.13. Salinas veri seti boyut indirgeme ile ilk 50 boyutunun sınıflandırma başarımı ortalaması .....	93
Çizelge 4.14. Pavia University veri seti boyut indirgeme ile ilk 50 boyutunun sınıflandırma başarımı ortalaması .....	93

# 1. GİRİŞ

## 1.1. Genel Bakış

Uzaktan algılama sistemleri dünya yüzeyini ve atmosferi küresel, bölgesel ve yerel ölçekte görüntülemek için kullanılan güçlü araçlardır. Bu amaçla yaygın şekilde kullanılan Landsat Thematic Mapper (TM) gibi multispektral sensörler çeşitli yeryüzü gözlem uygulamalarında yüksek başarı göstermektedir. Bu sensörler yardımıyla elde edilen görüntüler toprak, su ve orman gibi arazi çeşitlerinin haritalanması ve sınıflandırılması, çevreyle ilgili modelleme, kentsel planlama, habitat analizi, çevresel risk analizi ve kentsel yayılma gibi uygulamalarda kullanılmaktadır. Fakat az sayıda alıcı kanalı içeren bu sensörler farklı arazi örtü sınıfları arasında ayırım yapabilse de aynı türün farklı alt türleri ve oluşumları arasında (örneğin; farklı orman tipleri) ayırmsallık kabiliyeti oldukça sınırlıdır. Bu problemin önüne geçebilmek için son yıllarda hiperspektral sensörler geliştirilmiştir. Bu sensörler ile hava ve uzay araçları ile oldukça geniş alanlardan yüzlerce alıcı kanal ile daha önce görülmemiş spektral, uzaysal ve zamansal çözünürlükte bilgi çıkarımı yapılabilmektedir. Elde edilen görüntüler hedeflerin spektral özellikleri hakkında geleneksel multispektral sistemlerden elde edilen verilere göre daha fazla ayrıntı içerir. Bu bilgiler sayesinde çok yüksek ayırmsallık yeteneği gerektiren ek uygulamalar geliştirilmektedir (Melgani ve Bruzzone 2004).

## 1.2. Problem

Hiperspektral görüntüleme teknolojilerinde, sensörler ile görüntülenen sahne üzerindeki her bir pikselin yüzlerce veya binlerce bantta görüntüsü alınarak spektral bir vektör oluşturur. Fakat hiperspektral sensörler tarafından üretilen bu yüksek oranda ilişkili ve yüzlerce boyutlu spektral ve uzaysal vektörler, sınıflandırma işlemlerinde birtakım zorluklara sebep olmaktadır. Spektral bant sayısı veya boyut sayısının artmasıyla sınıfların ayrılabilirliği artsa da sınıfları tanımlayan istatistiksel parametrelerin sayısı da aynı oranda artış göstermektedir. Verilerin çok sayıda öznitelik içermesi sınıflandırma işlemleri sırasında işlem yükünü ve hesaplama karmaşıklığını arttırmaktadır. Öte yandan elde edilen büyük miktardaki veride sınıflandırma başarısını olumsuz etkileyen fazlalık

bilgiler de vardır. Veri setinin daha iyi temsil edilerek daha doğru bir sınıflandırma veya kümeleme işleminin yapılabilmesi için orijinal verilerden fazlalık, yanlış ve hatalı bilgilerin ayıklanması gerekmektedir.

Hiperspektral görüntü sınıflandırılmasında birçok farklı sınıflandırma yöntemi önerilmiştir. Geleneksel piksel tabanlı hiperspektral görüntü sınıflandırma yöntemleri, farklı nesnelerin farklı spektral yansıtma değerlerine sahip olduğu varsayımına dayanmaktadır ve her bir nesneyi spektral değerlerine göre sınıflandırmaktadır. Diğer bir deyişle her bir piksel farklı bantlara ait sayısal değerlerine göre sınıflandırılmaktadır. Bu yöntemlerden destek vektör makinesi (Support Vector Machine, SVM) gibi sınıflandırıcıların performansları umut verici olsa da güvenilir eğitim verisinin toplanması oldukça pahalı ve zor bir işlemdir. Ayrıca bu algoritmaların çoğu boyutsallık laneti (curse of dimensionality) sebebiyle yüksek performans gösterememektedir (Friedman 1997). Hiperspektral görüntü sınıflandırılmasında sıklıkla görülen bir problem olan boyutsallık lanetinde, sabit bir eğitim seti varsayıldığında ve bu setin öznelikleri sınıflandırma işlemine adım adım eklendiğinde başlangıçta sınıflandırma başarımı artmaktadır. Ancak daha fazla öznelik eklendiğinde doğruluk artış oranı azalmaktadır (Hughes 1968, Pal ve Foody 2010).

Yüzlerce veya binlerce bantlık bilgiden oluşan hiperspektral görüntüler istatistiksel bütünlük içinde sınıflandırılmalıdır. İstatistiksel bütünlük ise her bir sınıf için eşit ve çok sayıda eğitim örneğinin olmasıyla sağlanabilir. Çok sayıdaki boyut bilgisi ile beraber hiperspektral görüntülerde sınıf sayısı da yüksektir. Bu nedenle hiperspektral görüntülerin sınıflandırılmasında öznelik sayısı ve eğitim örneği sayısı arasındaki dengesizlik geleneksel sınıflandırıcıların performansını düşürmektedir.

Boyutsallık lanetinin üstesinden gelmek için sadece spektral verileri kullanan geleneksel yöntemlerde, boyut indirgeme (Dimension Reduction) ve öznelik çıkarma (Feature Extraction, FE) metodları uygulanarak elde edilen spektral bilgilerle sınıflandırma işlemi tamamlanır. En uygun boyut indirgeme tekniğine karar vermek zor olsa da ilk aşamada en sık kullanılan teknikler temel bileşen analizi (Principal Component Analysis, PCA) (Fukunaga 2013), bağımsız bileşen analizi (Independent Component Analysis, ICA) (Villa ve ark. 2011), doğrusal ayırtaç analizi (Linear Discriminant Analysis, LDA)

(Liccardi ve ark. 2012) gibi doğrusal boyut indirgeme teknikleridir. Fakat spektral verilerin indirgenmesine dayanan bu yöntemler yüksek çözünürlüklü sensörler tarafından elde edilen uzaysal veriyi koruyamamaktadır. Ayrıca bu yöntemler doğrusal olmayan verilerin indirgemesinde de uygun değildir. Aynı zamanda veri güdümlü ve doğrusal olmayan boyut indirgeme algoritmaları herhangi bir modele dayanmamakta ve yüksek miktardaki verilerde oldukça uzun hesaplama süresine ihtiyaç duymaktadır (Mohan ve ark. 2007).

Uzaktan algılama görüntülerinde uzaysal özelliklerin elde edilmesi, problemin cinsine bağlı olan gri düzey oluşum matrisi, dalgacık dokusu, geometrik görüntü özellikleri, gabor doku özellikleri ve genişletilmiş morfolojik özelliklere göre amaca yönelik olarak belirlenmektedir. Diğer bir deyişle her bir parametre yapılandırması ile sadece bir nesne tespit edilebilmektedir (Zhao ve Du 2016). Bu sebeple spektral imzaların uzaysal özelliklerinin değişkenliği ile başa çıkmak için yeni yaklaşımlar ortaya çıkmıştır ve uzaysal bilgiye verilen önem artmıştır (Chen ve ark. 2014).

### **1.3. Probleme Yaklaşım**

Hiperspektral verilerdeki her türlü nesnenin tanımlanmasına olanak sağlaması açısından yapay sinir ağı modeli olan derin öğrenme tabanlı yöntemler daha etkili ve yüksek seviyeli uzaysal özniteliklerin çıkarılmasında umut verici sonuçlar ortaya koymaktadır. Yapay öznitelikler ve sığ öğrenme modellerine dayanan geleneksel sınıflandırma yöntemlerine kıyasla görüntü işlemede büyük başarı gösteren derin öğrenme teknikleri, yapay öznitelikler kullanmak yerine veriye uyarlanabilir, hiyerarşik ve dağıtık öznitelikleri ham verilerden öğrenmeyi amaçlamaktadır. Katmanlı mimariler ve doğrusal olmayan aktivasyon fonksiyonları kullanarak elde edilen bu öznitelikler geleneksel yöntemlerin oluşturduklarına göre daha gürbüzdür (Fang ve Hu 2014).

En popüler derin öğrenme metotlarından biri olan evrimsel sinir ağları (Convolutional Neural Networks, ESA), eğitilebilen parametre sayısını azaltmak için paylaşımlı ağırlıklar kullanmakta ve yerel bağlantılarla uzaysal bilgileri etkili olarak çıkarmaktadır. Ayrıca uzaysal öznitelikleri çıkarmak için sabit boyutlu resim parçaları alarak uzaysal bilgilerin değişmeden kalmasını sağlamaktadır (Yue ve ark. 2015, Liang ve Li 2016).

Bu çalışmada sınırlı sayıda eğitim verisi ve karmaşık bir yapıya sahip olan hiperspektral veri setlerine evrişimsel sinir ağı modelleri uygulanarak, geleneksel sınıflandırma yöntemlerinin düşük başarı elde etmesine sebep olan problemlerin üstesinden gelinmeye çalışılmıştır. Daha yüksek başarı elde etmek için geliştirilen bir, iki ve üç boyutlu evrişimsel sinir ağları ile sırasıyla spektral, uzaysal ve spektral-uzaysal özniteliklerden faydalanılmıştır. Evrişimsel sinir ağı sınıflandırma sonuçları; doğrusal ve doğrusal olmayan, öğreticili ve öğreticisiz gibi pek çok farklı yöntemle indirgenip geleneksel yöntemlerle sınıflandırılan sonuçlar ile farklı açılardan karşılaştırılmıştır. Yapılan çalışma ile veriler alt uzaya indirgenmeden, sınırlı sayıdaki eğitim verisiyle ve spektral-uzaysal bilgileri de korunarak yüksek başarı ile sınıflandırılmaya çalışılmıştır.

#### **1.4. Tezin Ana Hatları**

Tez çalışması beş ana bölümden oluşmaktadır. “Giriş” bölümünde uzaktan algılama ve hiperspektral görüntüleme hakkında genel bilgi verildikten sonra hiperspektral görüntülerin sınıflandırılmasında kullanılan geleneksel yöntemler ve bu yöntemlerin karşılaştığı sorunlara değinilmiştir. Bu problemlere modern bir yaklaşım olarak geliştirilen derin öğrenmeden bahsedilmiştir. Problemler ve kullanılan yöntemler ışığında tez çalışmasının amacı açıklanmıştır. “Kuramsal Temeller ve Kaynak Araştırması” bölümünde literatürde hiperspektral veriler ile yapılan derin öğrenme ve sınıflandırma çalışmalarına değinildikten sonra hiperspektral görüntülerin uzaktan algılama teknolojileri ile elde edilmesi ve yapısı incelenmiştir. Ardından çalışmada kullanılacak iki temel yaklaşımdan ilki olan yapay sinir ağı ve derin öğrenme temelleri anlatılmıştır. Evrişimsel sinir ağlarının katmanları ve ağın optimize edilmesini sağlayan parametreler açıklanmıştır. Daha sonra ikinci yöntem olan boyut indirgeme ile sınıflandırma hakkında bilgi verilmiştir. “Materyal ve Yöntem” bölümünde, veri setleri ve deney ortamı anlatılmıştır. Tezde kullanılan sınıflandırma yöntemlerinden ilki olan evrişimsel sinir ağlarının yapısı ve mimarisi açıklanmıştır. Ardından ikinci yöntem olan boyut indirgeme yöntemleri ile geliştirilen sınıflandırma yöntemi açıklanmıştır. “Bulgular ve Tartışma” bölümünde yapılan tüm deneyler anlatılarak elde edilen sonuçlar sunulmuştur. Bu bölümde başlıklar kullanılan yöntemlere göre sıralanmıştır. “Sonuçlar” bölümünde yapılan deneylerin çıktıları ve literatüre katkıları yorumlanmaktadır.

## 2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Uzaktan algılama sensörlerinin gelişmesiyle beraber hiperspektral uzaktan algılama ve bu sayede elde edilen hiperspektral resimlerin sınıflandırılması yoğun olarak çalışılan bir alan olmuştur (David 2002). Belirli spektral bant aralıklarıyla alınan yüzlerce kanaldaki hiperspektral resimlerin, sıradan üç kanallı (Red-Green-Blue, RGB) resimlerden farkı, farklı spektral bantlarda çok daha fazla detaylı bilgi sağlamasıdır. Tarımdan askeriye, hava tahmininden jeolojik keşiflere kadar pek çok kullanım alanı sunan bu resimler, detaylı bilgi sunmakla beraber çok miktarda gereksiz ve fazlalık bilgi içermesi bu resimlerin işlenmesinde hesaplama karmaşıklığını da arttırmaktadır. Boyutsallık laneti gibi problemlere de sebep olan bu durum sebebiyle, sınıflandırma aşamasında spektral uzaydaki fazlalık bilgilerin azaltılması ve temsil gücü yüksek spektral-uzaysal özniteliklerin ortaya çıkarılması gerekmektedir (Chen ve ark. 2018). Bunun yanında maliyetinden ötürü sınırlı sayıda elde edilen etiketli veriler ve spektral imzaların büyük uzaysal değişikliği hiperspektral görüntülerin sınıflandırılmasını zorlaştırmaktadır.

Hiperspektral görüntülerin hızlı bir şekilde işlenmesi için pek çok yöntem geliştirilse de bu yöntemler spektral veya uzaysal bilgilerin bir tanesini kullanıp, iki bilgiyi kombin ederek kullanmamaktadır (Cheng ve ark. 2017). Eğitimsiz tekniklerden kümeleme yöntemi bu yöntemlerden biridir. Eğitimli teknikler ise yüksek sınıflandırma başarımı sağladığı için sıklıkla tercih edilse de sınırlı sayıdaki eğitim verisi bu yöntemlerin başarımını düşürmektedir. Pratikte boyutsallık laneti olarak bilinen boyut ve eğitim seti arasındaki dengesizlik bu yöntemlerin etkinliğini azaltmaktadır (Paoletti ve ark. 2018).

Hiperspektral görüntü sınıflandırmasında yaygın şekilde radial basis fuction (RBF) çekirdekli SVM kullanılmaktadır (Mercier ve Lennon 2003). Fakat hiperspektral görüntülerin üçüncü boyutundaki (z ekseni) verilerin uzaysal komşuluklarını (x ve y ekseni) kullanmadan yapılan bu sınıflandırma tatmin edici sonuçlar vermemektedir (Chen ve ark. 2018). Öte yandan uzaysal-spektral bilgilerin kullanılarak k-en yakın komşuluk (k-nearest Neighbour, kNN), karar ormanları (Random Forests, RFs) gibi geleneksel sınıflandırıcılarla yapılan sınıflandırma işlemleri veri seti hakkında iyi derecede ön bilgi gerektirmektedir. Ayrıca bu işlemler sırasında öznitelik çıkarımı oldukça zordur ve önemli bilgilerin kaybolmasına sebep olabilmektedir (Luo ve ark. 2018).

Son yıllarda yukarıda bahsedilen sorunların üstesinden gelmek için küçük örnek seti (small sample set) uygulaması giderek ilgi çekmeye başlamıştır. Küçük veri setleri halinde çalışmak için uygulanan boyut indirgeme yöntemleri boyutsallık lanetinin etkilerini azaltmayı başarmıştır. Orijinal veriyi daha küçük boyutlu bir uzaya dönüştürmeyi sağlayan, öznelik çıkarımı olarak da bilinen bu yöntemlerden bazıları ilk etapta PCA, ICA ve manifold öğrenme olarak düşünülebilir. Fakat bu yöntemler ile boyut indirgeme yapıldığında bazı önemli bilgilerin kaybolma ihtimali bulunmaktadır. Daha da önemlisi, boyut indirgeme ile elde edilen öznelikler veri setini spektral uzayda tamamı ile temsil etmeyebilmektedir. Bu nedenle ayrımsallığı yüksek olan özneliklerin oluşturulması dikkat edilmesi gereken bir husustur (Yu ve ark. 2017).

Son yıllarda, derin öğrenme temelli yöntemler daha üst seviye ve daha etkili uzaysal özellikleri keşfetmek için ümit verici sonuçlar üretmektedir. Bilgisayarla görme alanında derin öğrenme yöntemleri, doğrusal olmayan aktivasyon fonksiyonlarını kullanarak otomatik çok katmanlı özellikli öğrenme ve araştırma araçları olarak düşük seviyeli yöntemlere göre daha sağlam özellikler sunmaktadır (Li ve ark. 2014). Alt düzey özneliklerden üst düzey öznelikler çıkararak, geleneksel örüntü tanıma algoritmalarının aksine özneliklerin hiyerarşik yapısını öğrenebilmektedir.

Derin öğrenme açısından bakıldığında, bir görüntünün bileşenleri hiyerarşiktir. Pikseller önce kenarları oluşturmak için birleştirilir; daha sonra kenarlar parçaları oluşturur ve parçalar da sonunda farklı nesnelere oluşturmak için bir araya gelir. Bu nedenle derin öğrenmenin temel teorisi, üst düzey ve daha soyut özneliklerle hiyerarşik bir şekilde derin özellikleri öğrenmektir. Derin öğrenme ile elde edilen üst düzey öznelikler oldukça karmaşık yapıları temsil etmede daha başarılıdır. Dahası, çok yüksek uzaysal ve spektral çözünürlüğe sahip büyük veri kümeleri için başarılı sınıflandırma sonuçları vermektedir (Chen ve ark. 2014, Makantasis ve ark. 2015). Literatürde derin öğrenme mimarilerinin bu avantajları kullanılarak pek çok çalışma gerçekleştirilmiştir.

Chen ve ark. (2014) tarafından gerçekleştirilen çalışmada derin öğrenme kavramı ilk kez hiperspektral görüntülerin sınıflandırılmasına dâhil edilmiştir. Yapılan çalışmada öncelikle klasik spektral bilgi tabanlı sınıflandırmayı takip eden bir yığılmış otomatik kodlayıcıların (Stacked Autoencoder, SAE) uygunluğu test edilmiştir. Derin mimari

temelli modellerden biri olan otomatik kodlayıcı (Autoencoder, AE) hiperspektral görüntülerin derin özelliklerinin denetimsiz bir şekilde öğrenilmesine odaklanmıştır. Bu kapsamda verilerin sığ ve derin özelliklerini öğrenmek için tek katmanlı AE ve çok katmanlı istiflenmiş AE yönteminden faydalanılmıştır. İkinci olarak ise uzaysal ağırlıklı bilgi tabanlı yeni bir sınıflandırma yöntemi önerilmiştir. Daha sonra en yüksek sınıflandırma doğruluğunun elde edilebileceği iki özelliği birleştirmek için yeni bir derin öğrenme çerçevesi önerilmiştir. Çerçeve; PCA, derin öğrenme mimarisi ve lojistik regresyonun (Logistic Regression, LR) bir birleşimidir. Özellikle derin bir öğrenme mimarisi olarak yığılmış otomatik kodlayıcılardan kullanışlı üst düzey özellikler elde edilmesi amaçlanmaktadır. Yaygın olarak kullanılan hiperspektral veri setleri ile yapılan deneysel sonuçlar, bu derin öğrenme temelli çerçevede oluşturulan sınıflandırıcıların rekabetçi performans sağladığını göstermektedir. Ek olarak, önerilen ortak spektral-uzaysal derin sinir ağı, derinlemesine öğrenmeye dayalı metotların hiperspektral görüntü sınıflandırması için muazzam potansiyelini gösteren gelecekteki araştırmalar için yeni bir pencere açmıştır. SAE-LR yönteminin dezavantajı eğitim süresidir ancak test süresi SVM veya k-nearest neighbor (KNN) gibi diğer yöntemlerden çok daha kısadır. SAE-LR sınıflandırıcısı veri kümelerini sınıflandırmada geleneksel spektral bilgi tabanlı yöntemlerden daha yüksek başarımlar sağlamaktadır.

2015 yılında ise Chen ve ark. (2015) SAE ve derin inanç ağını (Deep Belief Networks, DBN) temel alan spektral-uzaysal özelliklerin çıkarımı ve sınıflandırma çerçevesi önermiştir. SAE ve DBN, katman bazında bir eğitimle derin özellikleri hiyerarşik olarak çıkarabilse de görüntü yamalarından oluşan eğitim örnekleri, modellerin giriş gereksinimlerini karşılamak için tek boyutlu olarak düzleştirilmelidir. Fakat düzleştirilmiş eğitim örneklerinin uzaysal özellikleri orijinal veri ile aynı kalmamaktadır. Ayrıca önerilen yöntem doğrudan etiket bilgilerini kullanmadan eğitilmektedir.

Slavkovikj ve ark. (2015) hiperspektral görüntü sınıflandırmasında spektral ağırlıklı öznelikler ile çalışarak elde edilen sonuçları geleneksel sınıflandırma yöntemleri ile karşılaştırmaktadır. Yue ve ark. (2015) ise uzaysal ağırlıklı özellikleri çıkarmak için ilk HSI verilerinin ilk birkaç temel bileşen bandında evrimsel sinir ağı (ESA) modelini

benimsemiştir. ESA tabanlı bu iki yöntem, uzaysal ve spektral bilgiyi aynı anda tam olarak kullanamamıştır.

ESA yönteminin geleneksel SVM sınıflandırıcılarından ve geleneksel derin öğrenme ağlarından daha iyi performans göstermesi üzerine Hu ve ark. (2015) birden fazla katmandan oluşan bir ESA geliştirerek hiperspektral görüntü sınıflandırma başarımını arttırmaya çalışmışlardır. Eğitim verisinin azlığından ötürü, çalışmada yalnızca bir evrişim katmanından ve bir tam bağlı katmandan oluşan bir yapay sinir ağı mimarisi geliştirilmiştir. Uzaysal korelasyondan ziyade spektral imzalara odaklanılan çalışmada, SVM sınıflandırıcısına göre daha iyi bir sınıflandırma başarısı elde edilmiştir.

Makantasis ve ark. (2015) tarafından yapılan çalışmada geleneksel örüntü paradigmalarının aksine, yüksek düzeyde özellikleri otomatik ve hiyerarşik olarak inşa eden derinlemesine öğrenme temelli bir sınıflandırma yöntemi önerilmiştir. Sınıflandırmadan önce aynı sınıfa ait piksellerin spektral imzalarının her kanalda neredeyse aynı değerlere sahip olduğu ve varyansının çok küçük olduğu gözlemine dayanarak, eğitim ve tahmin süreçlerini hızlandırmak için randomize-PCA (R-PCA) yöntemi ile boyut azaltma işlemi uygulanmıştır. Tasarlanan sinir ağı mimarisinde piksellerin spektral ve uzaysal bilgilerini işlemek için bir ESA ve sınıflandırma görevini yürütmek için çok katmanlı algılayıcı (MLP) kullanılmıştır. Bununla birlikte çalışmada önerilen yaklaşımda, spektral ve uzaysal bilgi tek bir adımda birleştirilmiş ve aynı anda yüksek seviye spektral-uzaysal özellikler inşa eden bir çerçeve önerilmiştir. Geliştirilen sistem bir kerede spektral-uzaysal özellikler inşa ederken, aynı zamanda ESA ve MLP yöntemleri ile gerçek zamanlı tahminler gerçekleştirmektedir. Önerilen derin öğrenme yaklaşımı SVM bazlı sınıflandırıcılarla karşılaştırıldığında her veri seti için üstün performans sunmuştur.

Uzaysal ve spektral bilgiyi SAE ve ESA kullanarak ayrı ayrı elde etmeye çalışan Yue ve ark. (2016)'nın çalışmasında ise yüksek sayıda eğitim parametresi hesaplanmak zorunda kalınmış ve sınırlı sayıdaki eğitim verisi hesaba katılmamıştır. Buna rağmen uzaysal veriler düzleştirilmeden, uygun derinlikteki mimariler ile sınıflandırılmıştır. Aynı zamanda spektral özellikler Yu ve ark. (2015)'de kullanılan yöntemden üstün olarak iki boyutlu vektörlere dönüştürülmeden işlenmiştir.

Chen ve ark. (2016) tarafından yapılan çalışmada ise boyutsallık lanetiyle başa çıkmak için üç boyutlu ESA tabanlı bir öznitelik çıkarma modeli geliştirilmiştir. Önerilen yaklaşımda doğrusal olmayan, ayrımsallığı yüksek ve ayırt edici öznitelikler çıkarmak için çeşitli evrişim ve havuzlama katmanı kullanılmıştır. Ayrıca hiperspektral verilerdeki yüksek boyut ve eğitim verisinin sınırlı mevcudiyetinden kaynaklanan dengesizlik sorununu aşmak için L2 düzenlileştirmesi ve seyreltme (dropout) gibi stratejiler incelenmiştir. Daha da önemlisi, hiperspektral görüntülerin etkili şekilde spektral-uzaysal özelliklerini çıkarmak için üç boyutlu ESA tabanlı FE modeli önerilmiştir. Geliştirilen üç boyutlu ESA, sadece uzaysal ya da sadece spektral özniteliklerin çıkarılmasını sağlayan bir boyutlu ve iki boyutlu sinir ağlarına oranla üstün başarı sağlamıştır. Ayrıca veri setleri PCA, faktör analizi (FA) ve yerel doğrusal gömme (Local Linear Embedding, LLE) gibi FE yöntemleri ile farklı sayıda boyutlara indirgenmiştir. İndirgenmiş verilerin çeşitli sınıflandırıcılar ile başarımı ve önerilen yapay sinir ağının sınıflandırma sonuçları karşılaştırıldığında, sinir ağının üstün başarı sergilediği ifade edilmiştir.

Kalita ve Biswas (2018) tarafından gerçekleştirilen çalışmada ise çok yüksek boyuta ve yetersiz eğitim setine sahip hiperspektral görüntülerden hem spektral hem uzaysal bilgilerin çıkarılmasını ve aynı zamanda ayırt edici özniteliklerin elde edilmesini sağlayan bir ESA mimarisi önerilmiştir. Uzaysal alandaki evrişim işlemleri, eğitim verileri az olduğunda aşırı uyum problemine sebep olduğundan önerilen mimaride, evrişim işlemi sırasında 1x1 boyutunda filtreler kullanılarak geleneksel ESA modellerinden farklı bir yapı sunulmuştur. Uzaysal evrişimden önce uygulanan bu filtreler ile hiperspektral görüntünün spektral boyutu azaltılarak hesaplama maliyeti düşürülmüştür. Aynı zamanda daha iyi bir genelleme özelliğine sahip mimari sağlanmıştır. Bu çalışmada ayrıca ESA yöntemindeki tam bağlı katmanlar yerine küresel ortalama havuzlama (GOH) katmanı kullanılmıştır. GOH katmanında tam bağlı katmanlarda olduğu gibi optimize edilecek herhangi bir parametre bulunmadığından aşırı uyum problemi büyük oranda azaltılmıştır. Sunulan çalışma farklı çalışmaları ile karşılaştırılarak daha iyi bir sonuçlandırma başarısı elde edildiği belirtilmiştir.

Yu ve ark. (2017) tarafından önerilen çalışmada yaygın görsellerden farklı olarak, farklı elektromanyetik spektrumlarda sinyallerden oluşan hiperspektral görüntü analizini baştan sona ele alacak yeni bir ESA mimarisi geliştirilmiştir. Az sayıda eğitim örneklerinden

kaynaklanan aşırı uyum probleminin önüne geçmek için veri büyütme, seyreltme oranlarının değiştirilmesi gibi stratejiler uygulanmıştır. Hiperspektral görüntülerle daha iyi başa çıkabilmek için 1x1 boyutunda filtrelerle evrişim işlemi, ortalama havuzlama katmanı ve yüksek seyreltme oranları uygulanmıştır. Çalışmada aynı zamanda üç farklı öznitelik türü göz önünde bulundurulmuştur. Birincisi ham veriler, ikincisi hiperspektral görüntünün en önemli temel bileşenleri üzerine açma ve kapama morfolojik dönüşümleri uygulanarak elde edilen morfolojik özellikler, üçüncüsü ise üç boyutlu Gabor özellikleridir. SVM ve kNN sınıflandırıcıları ile karşılaştırılan çalışma, kullanılan veri setlerinde üstün performans göstermiştir.

Zhao ve ark. (2019) tarafından yapılan çalışmada sınırlı sayıda etiketli veri kullanılarak hiperspektral görüntüler sınıflandırması için gri seviyeli birlikte-ortaya çıkma matrisinin (GLCM) dokusal özelliklerinin ESA mimarisi ile bütünleştiği bir derin öğrenme çerçevesi önerilmiştir. Önerilen yöntemin ilk adımında PCA ile elde edilen birinci ana bileşenden GLCM dokusal özellikler çıkarılmıştır. İkinci adımda, geliştirilen bir ESA mimarisinden elde edilen derin öznitelikler ile ilk adımda elde edilen dokusal özellikler birleştirmektedir. Bu sayede ESA sadece spektral özelliklerin öğrenilmesine odaklanırken, üretilen dokusal öznitelikler softmax fonksiyonundan önce doğrudan bir özellik seti olarak kullanılmaktadır. Bu işlemler, eğitim verisinin boyut gerekliliğini azaltarak hesaplama etkinliğini arttırmaktadır. Elde edilen sonuçlara göre önerilen GLCM-ESA yaklaşımı geleneksel sınıflandırıcılara göre üstün performans göstermiştir. Ayrıca bazı gelişmiş derin öğrenme tekniklerine göre daha yüksek hesaplama etkinliği sağlamıştır.

## **2.1. Uzaktan Algılama**

Uzaktan algılama, nesnelere fiziksel temas kurmadan uzak bir noktadan verilerin toplanması ve yorumlanması işlemidir. Uzaktan algılama sistemleri ise uydu veya hava araçlarına yerleştirilen sensörler yardımıyla Dünya yüzeyini ve atmosferi büyük ve küçük ölçüde görüntülemek, haritalamak ve sınıflandırmak için kullanılan önemli sistemlerdir. Bu sistemler, sensörler yardımıyla yüzeyden yansıyan veya emilen elektromanyetik enerji algılama tekniklerinin temelini oluşturmaktadır. Sensörlerdeki gelişmelerle beraber

uzaysal, izgesel, açısar ve zamansal çözünlüğü yüksek resimler elde edilmektedir (Richards 2009).

İnsan gözleri elektromanyetik spektrumda görünür dalga boylarını algılayan bir sensör görevi görmektedir. Çevremizde yeryüzünden yansıyan fakat gözlerimiz tarafından algılayamadığımız elektromanyetik enerjiler bulunmaktadır. Maddeler üzerinden yayılan bu enerji ancak diğer uzaktan algılama araçları tarafından algılanabilir ve farklı elektromanyetik spektrum bölgelerine karşılık gelmektedir. Uzaktan algılama sistemlerinde bir nesnenin durumu, nesneden yansıyan elektromanyetik sinyalin yorumlanmasıyla elde edilmektedir.

Uzaktan algılama yönteminin asıl amacı, görüntülerden daha iyi bilgilerin çıkarılabilmesi için elektromanyetik enerjinin yüzeylerle nasıl etkileştiğini anlamaktır. Güneş tarafından aydınlatılan yüzeylerin cinsine bağı olarak geriye yansıyan elektromanyetik enerji, hava araçları ve uydular tarafından algılanarak kaydedilmektedir. Görünür ve yansıtıcı kızılötesi bölgelerde elde edilen uzaktan algılama verileri temel olarak nesnelerin zemin yüzeyindeki yansımalarına bağıdır. Fakat dünya yüzeyi elektromanyetik enerjiyi aynı anda yansıtabilir, emebilir, iletebilir ve yayabilmektedir. Tüm bunları elektromanyetik spektrumun farklı bölgelerine karşılık gelen dalga boylarında gerçekleştirmektedir. Uzaktan algılanan bir görüntüdeki her bir piksel için kaydedilen spektral imza, hedef yüzeyin özelliklerine ve atmosferin etkilerine bağı olarak benzersizdir. Uzaktan algılama verilerinin analizinde tekil piksellerin spektral imzaları arasındaki benzerlikler ve farklılıklar, manzarayı tanımlayan ya da bir sahnedeki özel ilgi alanlarını tanımlamaya yardımcı olan daha genel sınıflar kümesi oluşturmak için kullanılmaktadır.

Uzaktan algılama teknolojileri pek çok farklı alanda yaygın şekilde uygulanabilmektedir. Bu alanlardan bazıları; küresel ısınma, kuraklık, ozon tabakası, toprak erozyonu, ekin durumu, ürün tahmini, ormanlar, okyanuslar hava durumu tahmini, şehirleşme, topoğrafya, inşaat mühendisliği ve sulak alanların tespitidir.

### 2.1.1. Uzaktan algılama sistemlerinin tarihi

Uydu üzerinde algılama sistemlerinin modern çağı 1972 yılında Landsat Multispectral Scanner Systems (MSS) tarafından elde edilen yüksek çözünürlüklü resimler ile başlamıştır. Bu sensör 18 gün aralıklarla 100 nm genişliğinde ve 80 m uzaysal çözünürlüklü, görünür ve yakın kızılötesi bölgelerde çoklu spektral bant verisi (4 bant) sağlamıştır. Landsat MSS ile 1972'den 1993 yılına kadar dünya yüzeyi üzerinden alınan görüntülerle en kapsamlı uydu görüntüleri arşivi oluşturulmuştur. 1982 ve 1984 yıllarında fırlatılan Landsat 4 ve 5 uyduları ile MSS'nin gelişmiş versiyonu olan TM gözlem sensörü kullanılmıştır. Bu sayede 120 m çözünürlükte 6 adet yansıma verisi ve 1 adet termal veri olmak üzere toplam 7 spektral bantta dünya yüzeyinden bilgi toplanmaya başlanmıştır. 1991 yılında Landsat 6'nın şanssız bir şekilde düşmesinin ardından 1991 yılında geliştirilmiş TM sensörü ile Landsat 7 fırlatılmıştır. TM sensöründeki 6 spektral banda ek olarak 15 m çözünürlüğe sahip pankromatik bant eklenmiştir. 2013 yılında gönderilen Landsat 8 uydusu ise yakın-kızılötesi, kısa dalga kızılötesi ve termal kızılötesi aralıklarında görüntü almakta olup 11 banda sahiptir. Ayrıca ilk Landsat uydusunun fırlatılmasından günümüze kadar uzaktan algılama alanında ASTER, ALI, Spot, Rapideye, Quickbird ve Ikonos gibi birçok multispektral algılayıcı kullanılmıştır. Fakat çeşitli gözlem uygulamalarında kullanılabilirliğini gösteren multispektral algılayıcılar, farklı arazi örtüsü sınıflarında (ormanlık, su, tarım arazisi, ekin) başarılı olsa da aynı sınıfın farklı tip ürünlerinde (farklı çeşitlerdeki ormanlık alanlar) yeterli ayrımsallık başarısını gösterememiştir (Gowen ve ark. 2007).

Ayrımsallığın yeterince sağlanamadığı bu donanımların ardından 1980'lerde Jet Propulsion Laboratuvarında (Pasadena, California) bir grup bilim adamı eşi görülmemiş seviyede izgesel detay içeren Dünya görüntüleri elde etmeyi sağlayan bir donanım geliştirmiştir. Daha önce geliştirilen multispektral sensörlere göre bu yeni hiperspektral donanımlar ile 200 veya daha fazla bantta ve oldukça dar bant ve ardışık aralıklarla, sürekli spektral kanallarda görüntü alınabilmektedir. Ayrıca multispektral görüntüleme ile yetersiz kalan spektral bilgi, hiperspektral algılayıcılar ile elde edilebilmektedir. Bu sayede geleneksel multispektral sensörlerle belirlenemeyen detaylı yüzey analizleri yapılabilmekte ve yüksek ayrımsallık kabiliyeti gerektiren uygulamalar başarıyla

gerçekleştirilebilmektedir. RGB, multispektral ve hiperspektral görüntüleme sistemleri arasındaki farklar ve yenilikler Çizelge 2.1’de gösterilmiştir (Gowen ve ark. 2007).

**Çizelge 2.1.** RGB, multispektral ve hiperspektral görüntülemenin karşılaştırılması (Gowen ve ark. (2007)’dan değiştirilerek alınmıştır)

Öznitelik	RGB Görüntüleme	Multispektral Görüntüleme	Hiperspektral Görüntüleme
Uzaysal Bilgi	✓	✓	✓
Spektral Bilgi		Sınırlı	✓
Çok-Bileşenli Bilgi	Sınırlı	Sınırlı	✓
Küçük Bileşenlere Karşı Hassasiyet		Sınırlı	✓

### 2.1.2. Elektromanyetik spektrum

Elektromanyetik spektrum üzerinde insan gözünün algılayabildiği dalga boyları görünür bantlardır ve 0,4 - 0,7  $\mu\text{m}$  arası olarak oldukça küçük bir bölgeyi kapsamaktadır. Görünür spektrumun dışındaki dalga boyları çıplak ise gözle görülemezdir. Uzaktan algılama sistemleri görünür bantların ötesindeki elektromanyetik enerjiyi algılama olanağı sağlamaktadır. Kırmızı ötesi bölgesi ise 0,7  $\mu\text{m}$  - 100  $\mu\text{m}$  arasında uzanır ve ışıma özel filmler ile algılanabilmektedir. Daha uzun dalga boyları ile ısı olarak hissedilmektedir (Borengasser ve ark. 2007).

Elektromanyetik spektrumda en yüksek frekanslı dalga boyu bölgelerinde gama ışınları ve X ışınları (nanometre cinsinden ölçülen) bulunmaktadır. Elektromanyetik spektrumun en yüksek enerjisine ve en kısa dalga boyuna sahip (< 0,01 nm) gama ışınları nötron yıldızları, pulsarlar, süpernova patlamaları dahil olmak üzere evrendeki en sıcak nesnelere tarafından üretildiği için uzayda üretilen *gama* ışınlarının çoğunluğu Dünya atmosferi tarafından engellenmektedir. Benzer şekilde X ışınları da (0,01-10 nm) Dünya

atmosferinden geçememektedir. Bu nedenle elektromanyetik spektrumun bu bölgeleri uzaktan algılama için kullanılmamaktadır.

Ultraviyole (UV) ışınlar ise 10 – 310 nm dalga boyuna sahiptir. UV ışın kaynağı olan Güneş tarafından yayılan bu enerjinin bir kısmı atmosfer tarafından tamamen emilmektedir. UV dalgaları insan gözüne görünmez olmasına rağmen, bombus arıları gibi bazı böcekler tarafından görülebilmektedir. Bununla birlikte nesnelere daha uzun dalga boylarındaki enerjiyi benzersiz şekilde yansıttığı, ilettiği ve emdiği için uzaktan algılama sistemlerinde görünür, kızılötesi ve mikrodalga bölgeleri kullanılmaktadır. Kızılötesi bölgeleri; yakın kızılötesi (NIR) 0,7 - 1,3  $\mu\text{m}$ , kısa-dalga kızılötesi (SWIR) 1,3 - 3  $\mu\text{m}$  ve uzak veya termal kızılötesi 3 - 100  $\mu\text{m}$  olmak üzere üç ana bölgeye ayrılmıştır. Nesnelere Güneş'in bu dalga boylarındaki enerjisini benzersiz şekilde yansıttığı için uzaktan algılama sistemlerinde pek çok uygulamada kullanıma uygundur. Mikrodalga bölgesi ise uzaktan algılama sistemlerinde kullanılan en uzun spektral bölgedir. Bu spektrumun daha kısa dalga boyları, termal kızılötesi bölgesi ile benzerlik göstermektedir. Daha uzun dalga boyları ise bulutlara, sis ve yağmura nüfus ederek radar sistemleri tarafından görüntü elde edilmesini sağlamaktadır (Borengasser ve ark. 2007).

### **2.1.3. Uzaktan algılamada çözünürlük**

Bir sensörün en önemli özelliği spektral çözünürlüğüdür. Bir sistemin spektral çözünürlüğü, sensörlerin çözebileceği maksimum spektral zirveleri belirlemektedir.

#### **2.1.3.1. Spektral çözünürlük**

Bir görüntüdeki farklı sınıflara ait detaylar, farklı dalga boylarında ve geniş dalga boyu aralıkları üzerindeki yanıtları karşılaştırılarak ayırt edilebilmektedir. Fakat aynı sınıfın farklı türleri (örneğin; farklı kayalar türleri) geniş dalga boyu aralıkları ile ayırt edilemez. Bu tip ayrımların yapılabilmesi için daha dar dalga boylarında çalışmalar gerçekleştirilmelidir. Sensörlerin ayrımsallık gücüyle ilgili olan spektral çözünürlük, bir sensörün daha dar dalga boyu aralıkları ile ölçüm yapabilme yeteneğini temsil etmektedir (Borengasser ve ark. 2007).

Pek çok uzaktan algılama sistemi multispektraldir ve çok sayıda bantta görüntü elde edilmesini sağlamaktadır. Özellikle yörüngedeki uzaktan sistemlerinde ise maliyetten ötürü tek bantta görüntü alınmaktadır. Multispektral bir veri kümesi, pikselin her katman için bir dijital sayı ile ilişkili olduğu bir dizi istiflenmiş katmanın oluşturduğu düşünülebilir.

Elektromanyetik spektrumda dar aralıklarla çok sayıda sıkıştırılmış bant ölçümü yapan sistemler yüksek spektral çözünürlüğe sahip olarak kabul edilmektedir. Multispektral ölçümler için Landsat TM, Landsat MSS'den daha iyi bir spektral çözünürlüğe sahiptir (Borengasser ve ark. 2007).

Havadan gözlem yapan pek çok uzaktan algılama sistemleri 1-2  $\mu\text{m}$  (1000 - 2000 nm) spektral çözünürlükte ve yaklaşık 4 - 6 bant arası görüntü alabilirken, havadan gözlem yapılan hiperspektral uzaktan algılama sistemleri ise çok yüksek spektral çözünürlükte 200 bant üzerinde görüntü alabilmektedir. NASA tarafından göreve başlatılan AVIRIS bu sistemlerin en bilinenidir. 224 bantta 0,4 - 2,5  $\mu\text{m}$  aralığında alınan görüntüler, tek başına 10 nm aralığını kapsamaktadır (Borengasser ve ark. 2007).

### **2.1.3.2. Uzaysal çözünürlük**

Uzaysal çözünürlük, sistemin görüntülediği nesnelerin ayrıntılarını kaydetme yeteneğini belirleyen çözünürlüktür. Bir görüntü pikselinin temsil ettiği sahne alanı uzaysal çözünürlüğü ifade etmektedir. Uzaysal çözünürlük arttıkça, daha fazla görüntü detayı elde edilmektedir.

Dünya gözlem sensörlerinin uzaysal çözünürlüğü oldukça geniştir. Yüksek uzaysal çözünürlüklü algılayıcılar 0,5 m'den 4 m'ye kadar çıksa da, yerel ve bölgesel algılayıcıların piksel boyutu 10 m'den 50 m'ye kadar değişebilmektedir. Küresel sensörlerin piksel boyutu 200 m'den 1 km'ye çıkarken, meteorolojik uyduların ise yarımkürenin tamamını görüntüleyebilmek için 5 km'ye kadar çıkabilmektedir (Chuvieco 2009).

### **2.1.3.3. Temporal çözünürlük**

Sensörlerin gözlem sıklığını (aynı noktadan tekrar geçme sıklığı) temsil eden bu çözünürlük, sensörlerin yörüngesel özelliklerine (yükseklik, hız, eğim) bağlıdır. Atmosferik şartlara oldukça bağlı olan bu çözünürlük, bulutlu günlerde ve tropikal yağışlı bölgelerde sensörlerin düşük kalitede görüntü almasına sebep olmaktadır. Modern sensörler bu problemin üstesinden gelmek için farklı açılarda ilgilenilen bölge üzerinden görüntü alabilmektedir.

Temporal çözünürlük, kullanılan algılayıcının amacına göre 1 saatten 20 güne kadar değişiklik göstermektedir. Meteorolojik ölçümlerde kullanılan algılayıcıların bilgileri 15 - 30 dakikada bir güncellenmektedir. Kutup bölgelerinde bu oran 12 saatte birdir. Genel olarak yüksek mekânsal çözünürlüğe sahip algılayıcılar daha az temporal çözünürlüğe sahiptir (Borengasser ve ark. 2007).

### **2.1.3.4. Radyometrik çözünürlük**

Radyometrik çözünürlük bir uzaktan algılama sisteminin en beyaz ve en siyah renk seviyesi arasındaki gri seviyelerin ölçüsüdür. Bit cinsinden ölçülen radyometrik çözünürlükte, sekiz bitlik bir sistemde siyah pikseller 0 ile beyaz pikseller ise 255 ile ifade edilmektedir. Birçok uzaktan algılama sistemi 6 bitlik ya da daha fazla radyometrik çözünürlüğe sahip olsa da insan gözü 30 gri seviyeden fazla rengi algılayamamaktadır (Borengasser ve ark. 2007).

## **2.2. Hiperspektral Uzaktan Algılama**

Uzaktan algılanan veriler, bitki örtüsünün sınıflandırılması ve haritalanması için geniş ve uzaysal ölçekler üzerinde haritalama, yaygın ve zaman alan yoğun araştırmalar gerektiren geleneksel sınıflandırma yöntemlerinin yerine kullanılmaktadır. 1960'lı yılların başından bu yana, bitki örtüsünün uzaktan sınıflandırılması için multispektral hava araçları ve uydular ile uzaktan algılama teknolojileri ortak bir kaynak olarak kullanılmıştır.

Multispektral uzaktan algılama teknolojileri, tek bir gözlemede elektromanyetik spektrumun görünebilir ve yakın kızılötesi bölgesinden 3 ila 6 spektral bant arasında veri toplamaktadır. Bu bantlar arazi yüzeyindeki ince ayrıntıları tespit edemeyen ve spektral yansıma açısından çok az farklılıklar gösteren nesnelere ayrılmasına izin vermeyen daha az ama daha geniş spektral bantlardır. Dünyadan yansıyan ve yayılan enerjinin bu kaba spektral kategorizasyonu, multispektral sensörlerin birincil sınırlayıcı faktörüdür (Lee ve Landgrebe 1993).

Bilinen spektral imzaları tanımlama ve ilişkilendirme süreci, uzaktan algılama biliminin çekirdeğini oluşturmaktadır. Tek bir pikselin temsil ettiği spektral bilginin ne olduğunu anlamak, aynı spektrum imzasına sahip tüm pikselleri anlamak için temel sağlamaktadır. Spektral imzaların doğru bir şekilde sınıflandırılması, etkili bir görüntü yorumlaması için şarttır. Bu sayede bir fotoğraf zengin bir spektral bilgi zenginliğine dönüştürülebilir. Öte yandan pikseller içinde mevcut olan bilgilerin miktarı ve kalitesi verilerin elde edilmesini sağlayan sensörün özelliklerine tamamen bağlıdır. Orta ila düşük çözünürlüğe sahip sensörler, bölgesel ve büyük ölçekli değerlendirme için yeterli veri sağlamaktadır. Ancak büyük pikseller pek çok bağımsız değişkenin karışımından oluşan spektral imzalara sebep olmaktadır. Bu durum detaylı bir sınıflandırma işlemi yapılmasını engellemektedir. Son yıllarda hava araçları ve uydular üzerine yerleştirilmiş hiperspektral sensörlerin gelişimi ile multispektral sensörlerin bahsedilen bu sınırlamalar ortadan kalkmıştır (Vorovencii 2009).

Hiperspektral uzaktan algılama 1980'lerin başlarından itibaren ortaya çıkan ve uzaktan algılama alanında çığır açan bir teknolojidir. Hiperspektral uzaktan algılama bir görüntünün her bir pikseli için eşzamanlı olarak detaylı spektral ve uzaysal bilgi sağlayan teknolojilerdir. Bu teknoloji görüntüleme ve spektroskopik işlemlerinin tek bir sistemde bir araya gelmesi nedeniyle "görüntüleme spektroskopisi" olarak da bilinmektedir (Goetz ve ark. 1985). Geleneksel spektroskopilerden farklı olarak tek bir hedef noktasından değil, Dünya yüzeyi üzerinden veri toplamaktadır. Oldukça yüksek derecede spektral, uzaysal ve radyometrik çözünürlük sağlayacak şekilde dizayn edilmiştir. Ayrıca hiperspektral sensörler 10 ile 20 nm aralıklarla bir dizi dar ve bitişik oldukça dar bant aralıklarıyla, insan gözünün görebildiği kırmızı, yeşil ve mavi bantlardan farklı olarak yüzlerce hatta binlerce spektral kanalda veri elde edilmesini sağlar. Görünür (VIS), yakın

kızılötesi (NIR), kısa-dalga kızılötesi (SWIR), orta-dalga kızılötesi (MWIR), uzun-dalga kızılötesi (LWIR), ve ultraviolet (UV) bölgelerde detaylı görüntü sağladığı ve benzer spektral özelliklere sahip nesnelere ayırt etme başarısı sayesinde uzaktan algılama alanında çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Bu alanlardan bazıları jeoloji, çevrebilim, jeomorfoloji, pedoloji atmosfer bilimi ve adli bilimlerdir. Hiperspektral sensörlerin kullanımı günümüzde hala nispeten maliyetlidir ve verileri işlemek için profesyonel insan gücü gerektirmektedir (Ben-Dor ve ark. 2013).

### **2.2.1. Hiperspektral algılayıcılar**

Çok sayıda hiperspektral algılayıcı kullanılmasına rağmen, hiperspektral uzaktan algılama alanında kullanılan en önemli algılayıcı Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)'dir. NASA tarafından 1989 yılında hizmete sunulan bu algılayıcı ile Kuzey Amerika ve Avrupa üzerinden yüzlerce görüntü alınmıştır (Green ve ark. 1988).

Geleneksel algılayıcı sistemlerinden farklı olarak hiperspektral sensörlerde bir görüntü merceği ile sahnedeki yansıyan veya yayılan enerji toplanmaktadır. Daha sonra yönlendirici bir lens, radyasyonu ayrı spektral bantlara ayıran bir kırınım ızgarası yoluyla paralel olarak yansıtılmaktadır. Her bir spektral banttaki enerji bir dizi silikon ve indiyum antimonit algılayıcı tarafından tespit edilmektedir.

Tez çalışmasında kullanılan veri setlerinden Salinas veri setinin elde edilmesini sağlayan 400 - 2500 nm (0,4 - 2,45 µm) spektral bölgesinde çalışan AVIRIS sensörü, 10 nm genişliğinde 224 spektral bant bilgisi sağlamaktadır. İkinci veri seti Pavia University'nin oluşturulduğu Reflective Optics System Imaging Spectrometer (ROSIS) sensörü (Holzwarth ve ark. 2003) ise 430 – 860 nm arasındaki spektral aralığı kapsamaktadır. Bant sayısı 115 ve bant genişliği 4,0 nm'ye eşittir.

### **2.2.2. Hiperspektral görüntülerin yapısı**

“Hiper” ve “Spektral” kelimelerinden oluşan “hiperspektral” yüzlerce veya binlerce banttaki oluşan görüntü anlamını taşımaktadır. Gri tonlamalı görüntüler ışığı elektromanyetik spektrumunda tek bantta yansıtırken, renkli görüntüler kırmızı, yeşil ve

mavi bantlarda yansır. Hiperspektral görüntüler ise pek çok bantta farklı çözünürlükte bilgi içermektedir.

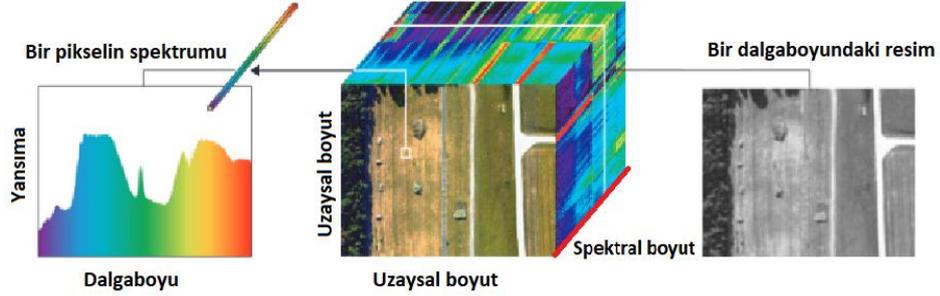
Geleneksel görüntüleme teknolojileri, bir dijital kamera aracılığıyla nesnelere uzaysal ve zamansal bilgiyi elde etmektedir. Hiperspektral görüntüleme sistemleri geleneksel spektroskopik tekniklere ve görüntülemelere kıyasla spektroskopik ve uzaysal bilgileri entegre etmek için tasarlanmıştır. Spektroskopi, nesnelere moleküllerinden ortaya çıkan ışık yoğunluğunu farklı dalga boylarında tanımlayıp açıklayarak, nesnelere ait bir parmak izi (spektral imza) oluşturmayı sağlamaktadır. Görüntüler iki boyutlu olarak kabul edildiğinden, hiperspektral görüntülere yeni bir spektrum bilgisi eklenerek, görüntüler üç boyutlu bir veri küpü olarak temsil edilmektedir.

Hiperspektral görüntüleme için temel prensip, herhangi bir materyal tarafından yansıyan, emilen veya yayılan ve farklı dalga boylarında çeşitlilik gösteren bu parlaklığı çok sayıda bitişik spektral dalga boyutlarında her bir piksel alanı içinde ölçmektir. Hiperspektral görüntüleme, spektroskopi teknikleri gibi yansıma, iletim ve floresan modlarında gerçekleştirilebilse de çoğunlukla yansıtma modunda kullanılmaktadır (Sun 2010). Uydular veya hava araçlarındaki algılayıcılar, spektrumun farklı bölümlerinde yüzey malzemelerinden yansıyan enerjiyi tespit etmektedir. Bu ölçümlerden sonra oluşturulan hiperspektral veri, her bir pikselde bulunan malzemeleri tanımlamak için yüksek çözünürlüklü bir spektrum içermektedir (Manolakis ve ark. 2003)

Hiperspektral algılayıcılar, incelenen bir hedefin her bir uzaysal konumu için yüzlerce bitişik dalga bandında görüntüsünü alarak üç boyutlu, hiperküp adı verilen veri yapılarının elde edilmesini sağlamaktadır (Lu ve Chen 1998). Hiperküpler, görüntülenen nesnelere biyokimyasal bileşenlerinin incelenmesine olanak tanımaktadır. Benzer spektral özelliklere sahip nesnelere, benzer kimyasal bileşenlere sahiptir (Gowen ve ark. 2007)

Hiperspektral görüntülerde aynı uzaysal lokasyondaki pikseller çıkarılıp spektral değerleri dalga boylarına göre çizildiğinde, yeryüzünde o piksele karşılık gelen materyallerin ortalama spektrumu çıkarılmış olur. Aynı spektral banttaki tüm pikseller ise

görüntüdeki yansımaların uzaysal dağılımını ilgili spektral dalga boyunda temsil eden gri tonlamalı bir görüntü sağlamaktadır (Şekil 2.1) (Manolakis ve ark. 2003).



**Şekil 2.1.** Hiperspektral görüntüleme temel veri küp yapısı ve verinin eşzamanlı ve uzaysal karakteri (merkez), tek bir piksel için bir spektrum seti (solda), tek bir spektral kanal için bir görüntü yığını (sağda) (Manolakis ve ark. (2003)'dan değiştirilerek alınmıştır)

Bu görüntülerde gözlemlenen spektral parlaklık verisi veya yansıtma verileri,  $K$ 'nın spektral bant sayısını temsil ettiği bir  $K$  boyutlu Öklid uzayında saçılan noktalar olarak gösterilebilir. Her spektral bant alanının bir eksenine dikey şekilde atandığında her bir piksel vektör olarak  $x = [x_1, x_2, \dots, x_K]^T$  şeklinde temsil edilmektedir. Bu vektör her bir spektral banttaki parlaklık veya yansıtma değerlerini içeren, kartezyen koordinatları  $x_i$  olan bir  $K$  boyutlu noktaya karşılık gelmektedir (Manolakis ve ark. 2003).

## 2.1. Bant sayısı

Hiperspektral görüntüleme sistemlerinde ana parametrelerden biri de bant sayısıdır. Multispektral görüntüleme sistemlerinde bant sayısı genellikle 10'dan az iken, hiperspektral sistemlerde bu sayı yüzlerce hatta binlerce olabilir.

## 2.2. Spektral aralık

Spektral aralık, hiperspektral görüntüleme sistemi tarafından elektromanyetik spektrumda kapsanan dalga boylarını temsil etmektedir. Spektral görüntüleme sistemleri, uygulamanın gerekliliğine göre ultraviyole, görünür, yakın kızılötesi ya da kızılötesi dalga boylarını kapsamaktadır.

### 2.3. Yapay sinir ağıları

YSA insan beyninin biyolojisini ve nöronlar arasındaki bağlantılardan esinlenilerek ortaya çıkmıştır. Ancak nöronların birbirine bağlandığı biyolojik bir beynin aksine YSA; ayrı katmanlara, bağlantılara ve veri yayılma yöntemlerine sahiptir. Bu sistemler açık bir şekilde programlanmış olmak yerine, kendi kendine öğrenme yeteneğine sahiptir. Geleneksel bilgisayar programlarında çözümün veya tespitin zor olduğu uygulamalarda mükemmel performans göstermektedir (Copeland 2006).

Genel olarak YSA, uzaktan algılanan görüntülerden çeşitli tarla ve mahsul ürünlerini tahmin etmede kullanılabilir. YSA'nın karmaşık spektral bilgiyi, örnek dağılımı için herhangi bir kısıtlama olmaksızın hedef niteliklerle ilişkilendirebilmesi, karmaşık ve doğrusal olmayan ilişkileri tanımada ideal bir yaklaşımdır. Yapılan ilk çalışmalarda YSA'lar çoğunlukla verileri sınıflandırmak için kullanılmasına rağmen, yöntem sürekli değişkenleri tahmin etmek için de büyük bir potansiyel göstermiştir (Atkinson ve Tatnall 1997).

Örüntü tanıma konusunda son yıllarda oldukça ilgi çeken YSA sınıflandırıcılarının istatistiksel yöntemlerle karşılaştırıldığında bazı önemli avantajları vardır. İstatistiksel sınıflandırma teknikleri tipik olarak model dağılımı hakkında önceden bilgi gerektirmesine rağmen, sinir ağı sınıflandırıcıları herhangi bir dağılım bilgisi olmadan iyi çalışmaktadır (Danaher ve ark. 1997). Bu kapsamda Lee ve ark. (1990) sinir ağlarının ve istatistiksel sınıflandırıcıların performansını karşılaştırmış ve sinir ağlarının daha küçük bir eğitim verisi seti kullanarak eşit performans sağlayabileceğini göstermiştir.

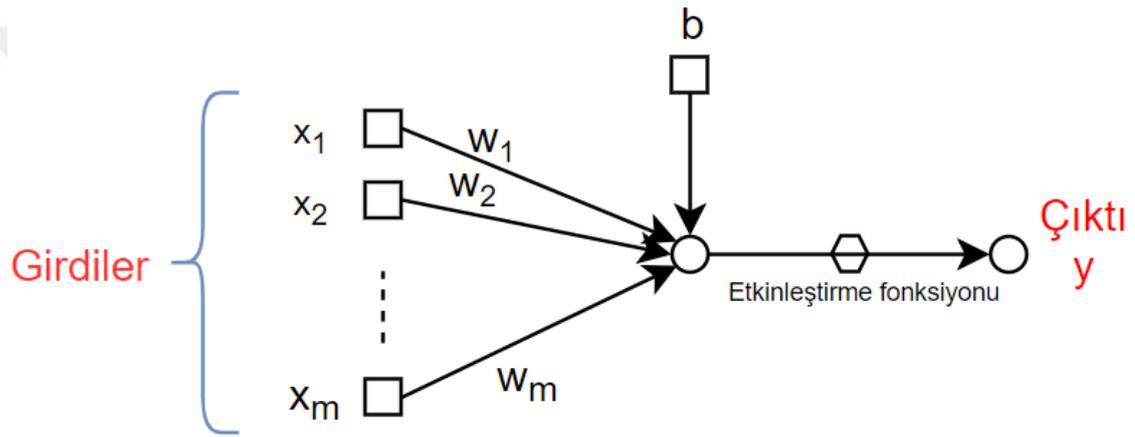
Bu bölümde tez kapsamında hiperspektral görüntülerin sınıflandırılmasında kullanılan derin yapay sinir ağı modellerinin gelişimi ve modellerinin anlatımı yapılmıştır.

#### 2.3.1. Algılayıcı (Perceptron)

Doğrusal olarak ayrılabilen modellerin sınıflandırılmasında kullanılan bir sinir ağının en basit şekli olan algılayıcı, ayarlanabilir sinaptik ağırlıklar ve tek bir nöronun oluşmaktadır. Tek bir nöronun etrafına inşa edilen algılayıcı, yalnızca iki sınıflı örüntü

problemlerinde sınıflandırma yapmak ile sınırlıdır. Algılayıcının çıktı katmanı birden fazla nöron içerecek şekilde genişletilerek ikiden fazla sınıfla sınıflandırma yapılabilir.

1958 yılında algılayıcıyı denetimli öğrenme olarak ilk kez öneren Rosenblatt'a göre, sinir modelinin toplama düğümü, kendi sinapslarına uygulanan girdilerin doğrusal bir kombinasyonunu hesaplamaktadır ve aynı zamanda dışarıdan uygulanan bir bias değeri içermektedir. Elde edilen toplam doğrusal olmayan bir etkinleşme fonksiyonundan geçirilerek, etkinleşme fonksiyonunun girişi pozitif ise +1'e ve negatif ise -1'e eşit bir çıkış üretilmektedir (Şekil 2.2).



Şekil 2.2. Algılayıcılarda veri akışı

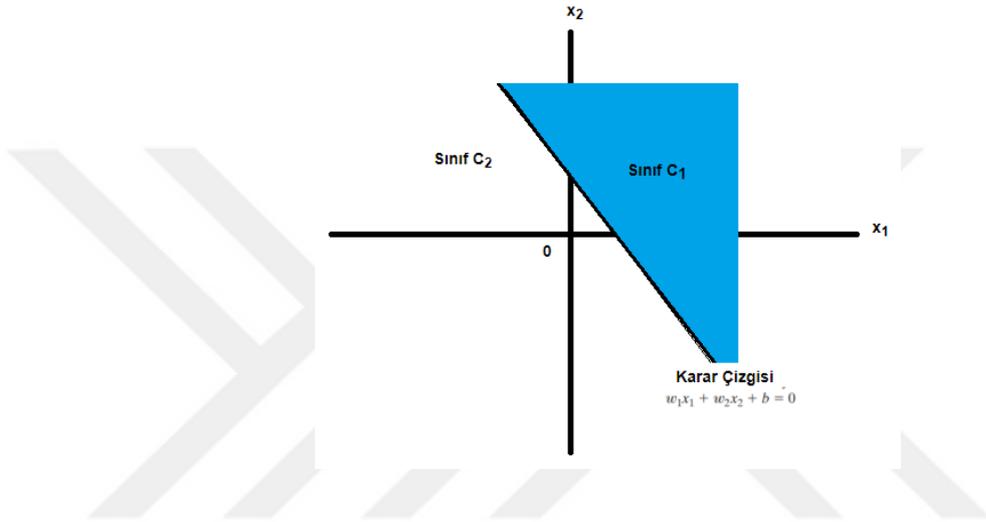
Örnek bir algılayıcıya ait ağırlıklar  $w_1, w_2, \dots, w_n$  şeklinde gösterilsin. Buna karşılık olarak, algılayıcıya uygulanan girişler  $x_1, x_2, \dots, x_n$  ile temsil edilsin. Dışarıdan uygulanan bias değeri de  $b$  ile temsil edildiğinde nöronun etkinleşme fonksiyonuna girdisi olan  $y$  denklem (2.1) ile ifade edilmektedir.

$$y = f \left( \sum_{i=1}^m w_i x_i + b \right) \quad (2.1)$$

Algılayıcının temel amacı, dışarıdan uygulanan uyarıcı kümesini iki sınıfa doğru olarak sınıflandırmaktır. Bir algılayıcının en basit haliyle karar düzlemiyle ayrılmış iki karar bölgesi vardır. Bu karar düzlemi denklem (2.2) ile tanımlanmaktadır (Haykin 2009).

$$\sum_{i=1}^n w_i x_i + b = 0 \quad (2.2)$$

Şekil 2.3'te  $x_1$  ve  $x_2$  olarak adlandırılan iki adet girdi değişkeninden oluşan örnek bir karar düzlemi gösterilmiştir. Karar çizgisinin üstünde kalan  $(x_1, x_2)$  noktası  $C_1$  sınıfına, sınır çizgisinin altında kalan nokta ise  $C_2$  sınıfına atanmaktadır. Bias değişkeni  $b$  ise karar sınırını orijinden uzağa ötelemek için kullanılır (Haykin 2009).



Şekil 2.3. Örnek bir hiperdüzlem (Haykin 2009'den değiştirilerek alınmıştır)

### 2.3.2. Çok katmanlı algılayıcılar (Multilayer perceptron)

Çok katmanlı algılayıcılar (MLP) hızlı çalışması, uygulama kolaylıkları ve daha az sayıda eğitim seti gereksinimleri nedeniyle en sık kullanılan ileri besleme sinir ağlarıdır. En temel haliyle, basit bir nöron veya düğüm sisteminden oluşur. Bir katmanın bir nöronunun çıktısının bir sonraki katmanın bir nöronunun girişi haline geldiği birkaç gizli nöron katmanından oluşan bir yapıdır. MLP kullanılarak gizli katman sayısının artırılması karmaşık problemlerin çözümü kolaylaşmıştır.

MLP mimarisi değişkendir ancak genel olarak birkaç nöron katmanından oluşmaktadır. Giriş katmanı hiçbir hesaplama işlemi yapmaz, yalnızca giriş vektörünü ağa iletmek için kullanılmaktadır (Gardner ve Dorling 1998). Gizli katman, giriş bilgisini çıkış katmanına işleyip iletmektedir. Gizli katmandaki yetersiz veya aşırı sayıda nöronlu bir sinir ağı

modeli, kötü genelleme ve aşırı-uyum sorunlarına neden olmaktadır. Gizli katmanlardaki nöron sayısını belirlemek için analitik bir yöntem yoktur (Orhan ve ark. 2011). Çıkış katmanında ise üzerinde çalışılan sorunların türüne göre regresyon ya da sınıflandırma yapılmaktadır. Tek katmanlı algılayıcılar pratikte fayda sağlamadığı için hiperspektral görüntülerin incelenmesinde çok katmanlı algılayıcılar oldukça uygundur.

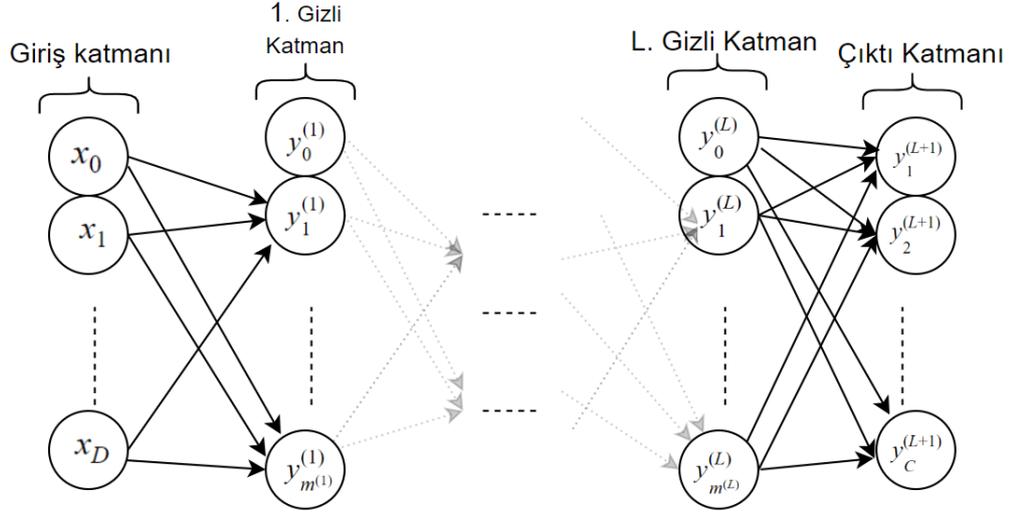
MLP mimarisinde bir katmanın her bir nöronu bir sonraki katmanın tüm birimlerine bağlıdır fakat aynı katmanın nöronlarıyla hiçbir bağlantısı yoktur. Bir diğer ifadeyle bir düğümün çıktısı, bağlantı ağırlığı ile ölçeklendirilir ve bir sonraki katmandaki düğümlere bir giriş olması için ileri beslenmektedir. Bağlantılara atanan ağırlık değerleri, nöronların sinir ağındaki etkisini ve önemini belirtmektedir. Ağı performansı ve sınıflandırma başarımını etkilediği için bu ağırlıklar dikkatle seçilmelidir. Ağırlık atama işlemi yapıldıktan sonra, ağıdaki her bir girdi ilgili ağırlık değerleriyle çarpılarak bir aktivasyon fonksiyonundan geçirilmektedir. Aktivasyon fonksiyonu nöronun şiddetini sınırlayan ve yapay sinir ağına doğrusal ve doğrusal olmayan bir yapı kazandıran işlevleri temsil etmektedir.

Şekil 2.4'te gösterilen  $(L+1)$  katmanlı bir algılayıcıda  $D$  adet giriş,  $C$  adet çıkış nöronu ve  $L$  adet gizli katman bulunmaktadır. Katman  $l$ 'deki birim  $i$ 'nin çıktısı denklem (2.3)'deki gibi hesaplanmaktadır (Stutz 2014).

$$z_i^{(l)} = \sum_{k=1}^{m^{(l-1)}} w_{i,k}^{(l)} y_k^{(l-1)} + w_{i,0}^{(l)} \quad (2.3)$$

Her bir nöronun çıktısı, girdilerin ağırlıklı toplamlarını kullanan bir aktivasyon fonksiyonu  $f$  ile denklem (2.4) kullanılarak elde edilmektedir (Stutz 2014).

$$y_i^{(l)} = f(z_i^{(l)}) \quad (2.4)$$



**Şekil 2.4.**  $(L+1)$  adet katmana,  $D$  adet giriş ve  $C$  adet çıkışa sahip bir algılayıcı örneği (Stutz 2014'den değiştirilerek alınmıştır)

Denklem (2.4)'te  $w_{i,k}^{(l)}$  ağırlığı  $(l-1)$  katmanındaki  $k$  nöronundan  $i$  nöronuna olan bağlantının değerini temsil etmektedir.  $w_{i,0}^{(l)}$  değeri ise bias adı verilen dış bir girdiği ifade etmektedir.  $m^{(l)}$  değeri ise  $D = m^{(0)}$  ve  $C = m^{(L+1)}$  olmak üzere katman  $l$ 'deki nöron sayısını temsil etmektedir. Her bir katmandaki çıktı değeri  $y_i^{(l)}$  ise denklem (2.5) veya (2.6) ile hesaplanmaktadır (Stutz 2014).

$$z_i^{(l)} = \sum_{k=0}^{m^{(l-1)}} w_{i,k}^{(l)} y_k^{(l-1)} \quad (2.5)$$

$$z^{(l)} = w^{(l)} y^{(l-1)} \quad (2.6)$$

Çok katmanlı algılayıcılar, eğitim yoluyla öğrenme yeteneğine sahiptir. Bir dizi girdi ve ilgili çıktı vektörlerinden oluşan bir dizi eğitim verisi ile çok katmanlı algılayıcı tekrar tekrar çalıştırılmakta ve ağıdaki ağırlıklar istenen giriş-çıkış haritalaması gerçekleşene kadar ayarlanmaktadır. Eğitim sırasında, belirli bir giriş vektörü için algılayıcının çıktısı istenen çıktıya eşit olmayabilir. İstenilen ve gerçek çıktı arasındaki fark olarak bir hata sinyali tanımlanır. Böylece eğitim aşamasında toplam hata minimize edilmeye çalışılarak ağıdaki ağırlıkların nasıl ayarlanması gerektiği belirlenmektedir.

### 2.3.3. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları seçilen fonksiyon çeşidine göre nöronların davranışlarını belirleyen en önemli işlemlerden biridir. Aktivasyon fonksiyonunun türüne göre belirli bir eşik değerinin altında kalan nöronlar aktif hale getirilmemekte ve kullanılmamaktadır.

Öte yandan yapay sinir ağına doğrusal veya doğrusal olmayan bir yapı kazandırmak için de aktivasyon fonksiyonları kullanılmaktadır. Doğrusal olmayan aktivasyon fonksiyonlarının seçimi ile yapay sinir ağı daha karmaşık problemleri temsil edebilecek yetenekler kazanmaktadır.

Derin öğrenme bağlamında aktivasyon fonksiyonunun temel amacı ise girdi uzayındaki temsili, çıktı uzayındaki farklı bir temsildir. Her durumda girdi ve ağırlıklar arasındaki benzerlik fonksiyonu yapay sinir ağındaki korelasyon ya da evrişim fonksiyonu tarafından sağlanmaktadır. Bunu daha sonra hesaplanan benzerlik ölçümünde bir eşikleme yapan aktivasyon işlemi takip etmektedir. En genel anlamda aktivasyon işlemi ile bir seçim ve projeksiyon işlemi gerçekleştirilmektedir. Bu işlemler yapılmadan ağ aynı uzayda kalacak ve katmanlar arasında daha yüksek soyutlama seviyeleri oluşmayacaktır.

Tipik olarak, belirli bir sınır aralığında sınırlandırılmış bir aktivasyon fonksiyonu seçildiğinde, gradyan bazlı optimizasyon yöntemleri düzenli olarak daha kararlı olma eğilimindedir.

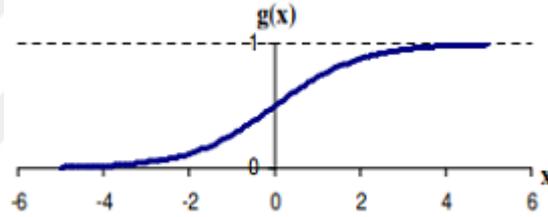
**Çizelge 2.2.** Aktivasyon Fonksiyonları

İsim	Fonksiyon
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$
Tanh	$\tanh(x) = 2\sigma(2x) - 1$
ReLU	$f(x) = \max(0, x)$
Leaky ReLU	$f(x) = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases}$
ELU	$f(x) = \begin{cases} x, & \text{if } x > 0 \\ \alpha(e^x - 1), & \text{if } x \leq 0 \end{cases}$
SELU	$\text{selu}(x) = \lambda \begin{cases} x, & x > 0 \\ \alpha e^x - a, & x \leq 0 \end{cases}$
PReLU	$f(x) = \begin{cases} x, & \text{if } x > 0 \\ ax, & \text{if } x \leq 0 \end{cases}$
Softmax	$f(x) = \frac{e^{z_j}}{\sum_k e^{z_k}}$

Yıllar boyunca pek çok aktivasyon fonksiyonu önerilse de Sigmoid, Tanh, ReLU, Softmax gibi fonksiyonların kullanımı daha yaygındır. YSA'nın karmaşık problemler üzerinde etkili performans gösterebilmesi için geliştirilen aktivasyon fonksiyonları Çizelge 2.2'de gösterilmiştir.

Geliştirilen aktivasyon fonksiyonlarından Sigmoid fonksiyonu ileri beslemeli YSA için en yaygın olarak kullanılan yöntemdir. Karakteristik bir "S" şekilli eğriye sahip lojistik fonksiyonun özel bir halidir.

Çizelge 2.2'deki Sigmoid fonksiyonu denkleminde  $e$ , Euler sayısını;  $x_0$  ise Sigmoid'in orta noktasının  $x$  eksenindeki değeridir.  $L$ , eğrinin maksimum değeridir ve  $k$  değeri eğrinin dikliğidir.  $L=1$ ,  $k=1$  ve  $x_0=0$  alındığında, Şekil 2.5'teki Sigmoid fonksiyonu elde edilmektedir (Karlık ve Olgac 2011).



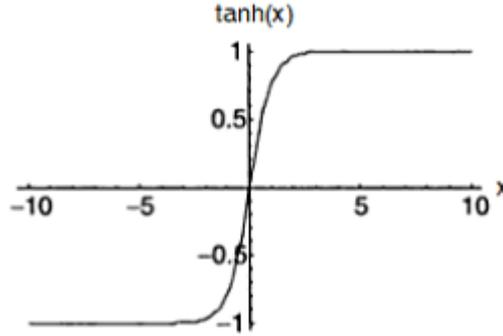
Şekil 2.5. Sigmoid aktivasyon fonksiyonu grafiği (Karlık ve Olgac 2011)

Sigmoid fonksiyonu çıktıların sadece pozitif olması gereken durumlarda kullanılmakta ve çıkış değerlerini 0 ve 1 arasına sınırlandırmaktadır. Büyük negatif sayıların 0 ve büyük pozitif sayıların 1 olmasını sağlamaktadır.

Sigmoid fonksiyonda yerel gradyan çok küçük değere sahip olduğunda fonksiyon gradyan etkisini neredeyse sıfıra yaklaştırarak "öldürmekte" ve nöronlar arasındaki veri akışı neredeyse durmaktadır. Saturasyon olarak betimlenen bu durumun önüne geçebilmek için ağırlıkların ilk değeri çok önemlidir. Ağırlıkların başlangıç değerleri çok büyük seçildiğinde birçok nöron saturasyona uğramakta ve öğrenme zorlaşmaktadır.

Sigmoid fonksiyonu yaygın olarak kullanılmasına rağmen hiperbolik tanjant (Tanh) veya rectified linear unit (ReLU) fonksiyonlarının kullanımı daha uygundur (Glorot ve ark.

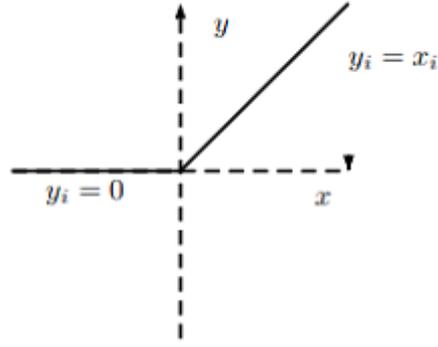
2011). Hiperbolik tanjant fonksiyonu en önemli aktivasyon fonksiyonlarından biridir ve Şekil 2.6'da gösterilmiştir.



**Şekil 2.6.** Tanh aktivasyon fonksiyonu grafiği (Karlık ve Olgac 2011)

Tanh fonksiyonu veriyi -1 ve 1 arasına sınırlar ve orijin etrafında simetrik değerlere sahiptir. Sigmoid ve Tanh işlevi, türevlerini çok basit ve verimli bir şekilde hesaplamaktadır. Bu durum MLP'de gradyan optimizasyonu sırasında kullanılmasının nedenlerinden biridir. Fakat 2011 yılında ReLU fonksiyonunun derin sinir ağlarının eğitimini daha da iyileştirdiği tespit edilmiştir. Sigmoid ve tanh yaygın olarak kullanılan aktivasyon fonksiyonları olsa da, Glorot ve ark. (2011) 'nın bir çalışmasına göre ReLU, karmaşık ve yüksek boyutlu verilerde derin sinir ağlarının daha hızlı ve daha etkili bir şekilde öğrenilmesini sağlamaktadır. En basit anlamda,  $x < 0$  olduğunda 0,  $x = 0$  olduğunda tersine doğrusal bir işlev çıkarmaktadır (Şekil 2.7).

Genelde bir sinir ağının son katmanında bulunan Softmax fonksiyonu ise çoklu sınıflandırmalı sinir ağları için kullanılmaktadır. Softmax fonksiyonu  $K$  boyutlu ve gerçek değerlerden oluşan  $z$  vektörünü, yine  $K$  boyutlu  $[0-1]$  arasındaki  $\sigma(z)$  vektörüne sıkıştırılmaktadır. Sigmoid fonksiyonundan farklı olarak her bir çıktıyı toplamları 1 olacak şekilde olasılıklara bölmektedir. Olasılık teorisi açısından, Softmax fonksiyonunun çıktısı, kategorik bir dağılımı, yani  $K$  farklı olası sonuçlara göre olasılık dağılımını temsil etmek için kullanılabilir (Liu ve ark. 2016).



Şekil 2.7. ReLU aktivasyon fonksiyonu grafiği (Xu ve ark. 2015)

## 2.4. Derin Öğrenme

Yapılan çalışmalarla nörobilimde görsel primat sisteminin farklı seviyelerdeki işlemlerle çalıştığı ve bu tür bir öğrenme sisteminin nesne tanımada çok iyi performans gösterdiği belirlenmiştir. Görüntü sınıflandırmasında ve hedef algılamasında yüksek performanslar sağlayan bu sistemler iki veya daha fazla katmanı içeren öğrenme tabanlı yöntemlere dayanmaktadır (Chen ve ark. 2016). Bu bilgiler ışığında 80'li ve 90'lı yıllarda yoğun olarak çalışılan YSA modelleri ile karmaşık problemlerin çözümünde çoklu gizli katmanların kullanılmasına yönelik çalışmalar başlamıştır.

FE ve birçok geleneksel sınıflandırma yöntemlerinin çoğu “derin” bir konsepte dayanmamaktadır. Geleneksel yöntemlerden doğrusal SVM ve LR gibi sınıflandırıcılar tek katmanlı sınıflandırıcılar olarak tanımlanabilir iken karar ağacı veya çekirdek SVM'lerinin iki katmana sahip olduğuna inanılmaktadır (Chen ve ark. 2014). Fakat bu yöntemler karmaşık problemlerin çözümünde yine de yetersiz kalabilmektedir.

YSA alanının bir uygulaması olan derin öğrenme, soyut katmanlar analizi ve hiyerarşik yöntemler anlamına gelmektedir. Çeşitli işlem süreçlerinde sonuçları iyileştirmek ve işlem sürelerini optimize etmek için kullanılmaktadır. Uzun yıllar boyunca yapay zekâ topluluklarını en meşgul eden problemlerin çözümünde büyük ilerlemeler kaydetmiştir. Yüksek boyutlu verilerde karmaşık yapıları keşfetmede son derece iyi performans gösteren derin öğrenme teknikleri bilim, işletme ve devletin birçok alanı için geçerli bir yöntem olarak popülaritesini arttırmıştır. Gen tanımlaması, konuşma tanıma kayıtlarına ek olarak, beyin devrelerini yeniden inşa eden potansiyel ilaç moleküllerinin aktivitesini

tahmin etmede diğer makine öğrenmesi tekniklerinden daha iyi başarımlar elde edilmesini sağlamıştır. Ayrıca doğal dil işleme tekniklerinde konu sınıflandırması ve duygu analizi gibi konularda da kullanılmaktadır. Yine bu alanda, resim yazısı üretimi ve el yazısı üretimi için derin öğrenme yöntemleri uygulanmıştır (Vargas ve ark. 2017).

Derin öğrenmenin yakın gelecekte çok daha fazla alanda uygulanabileceği öngörülmektedir. Makine öğrenmesinde nispeten yeni bir kavram olan derin öğrenme görüntü işleme alanında dikkat çeken sonuçlar vererek pek çok öncü çalışmanın da oluşmasını sağlamıştır. Derin öğrenmenin temel teorisi; hiyerarşik olarak temsil edilen özneliklerin veriye daha uygun ve daha güçlü temsil yeteneği kazanmasıdır. Pratikte YSA, ESA veya kısıtlı boltzman makineleri (Restricted Boltzmann Machines, RBM) içeren hiyerarşik temsillerde derin öğrenme prosedürleri yaygın olarak kullanılmaktadır. Görüntü işleme uygulamaları için ise RBM ve ESA yaygın olarak tercih edilmektedir.

Derin öğrenme alanında ilk büyük atılım olan derin inanç ağları (DİN), RBM'ler tarafından denetimsiz bir şekilde bir katmanı bir seferde eğitmektedir (Freund ve Haussler 1992). Daha sonraları önerilen AE tabanlı algoritmalar ise yerel temsillerin orta seviyelerini de eğitmektedir (Zhang ve ark. 2016). Uzaktan algılama alanında hiperspektral görüntü sınıflandırma problemleri için ilk kez derin öğrenme temelli bir yöntem 2014 yılında önerilmiştir (Natrajan ve ark. 2019). Yapılan çalışmada sınıflandırma için yığılmış otomatik kodlayıcılar ile hiperspektral görüntünün hiyerarşik ve güçlü öznelikleri çıkarılmaya çalışılmıştır. Daha sonra seyrek kısıtlamaya dayalı olarak geliştirilmiş bir AE önerilmiştir (Tao ve ark. 2015). 2015 yılında ise DBN ağına sahip başka bir derin model geliştirilmiştir (Chen ve ark. 2015). Ancak yukarıda bahsedilen modeller farklı katmanların tam bağımlı olmasından ve eğitim setinin eksikliğinden dolayı birçok farklı parametrenin eğitilmesini gerektirmektedirler. Ayrıca SAE ve DBN uzaysal bilgileri verimli bir şekilde ortaya çıkaramamıştır (Chen ve ark. 2016). Daha sonraları derin öğrenme tabanlı yöntemlerden özellikle ESA göz önünde bulundurularak pek çok çalışma gerçekleştirilmiştir. Hu ve ark. (2015)' da beş katmanlı bir ESA yapısı kullanarak hiperspektral görüntülerin spektral özelliklerinin elde edilmesinde umut verici bir sınıflandırma performansı elde etmiştir (Chen ve ark. 2017). Bu çalışmalar neticesinde hiperspektral görüntü sınıflandırılmasında ESA giderek ilgi çekici bir çalışma alanı haline gelmiştir.

Bölümün devamı, çalışmada kullanılan evrişimsel sinir ağlarının temelleri ile ilgili kuramsal bilgiler içermektedir.

#### **2.4.1. Evrişimsel sinir ağları (ESA)**

ESA hayvanların görsel korteksindeki nöronların organizasyonundan ilham alınarak tasarlanmış çok katmanlı bir sinir ağıdır ve görsel problemlerin çözümünde oldukça iyi performans göstermektedir. Hiperspektral görüntüler için sınıflandırma işlemi kenarlar, damlalar, köşeler ve dokudan ziyade spektral bilgilere dayanmaktadır. ESA, her bir sınıf için bu spektral imzaların temsilini öğrenmeye ve onu diğer tüm sınıflardan benzersiz bir şekilde ayırmaya çalışmaktadır (Morchhale 2016).

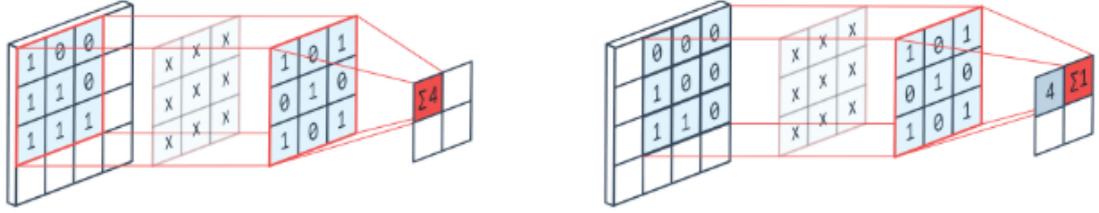
Derin öğrenme yöntemlerinin temeli YSA çeşitlerinden MLP yöntemine dayansa da; derin sinir ağlarının çeşitli uygulamaları arasında ESA ise görüntü işleme, yüz tanıma vb. işlemlerde çığır açmıştır. ESA mimarilerinin, hiperspektral görüntü sınıflandırılmasında ilk olarak kullanıldığı çalışmalardan sonra Hu ve ark. (2015) her bir spektral imzayı ayırt etmek için evrişimli katmanlar ve maksimum havuzlama katmanı önermiştir (Jin ve ark. 2018).

Genel olarak bir ESA yapısı evrişim katmanı, havuzlama katmanı ve tam bağlı katmanın çeşitli kombinasyonlarından oluşmaktadır. Bir veya daha fazla evrişim ve havuzlama katmanından oluşarak tam bağlı bir sinir ağı ile son bulmaktadır (Hu ve ark. 2015). Evrişim katmanında ağırlık paylaşım tekniği ile tüm veriye aynı ağırlıktaki evrişim filtresi uygulanarak parametre sayısı azaltılmaktadır. Daha sonra doğrusal olmayan bir fonksiyon ve havuzlama katmanı uygulanarak daha yüksek düzeyli öznitelikler elde edilmektedir. Evrişim ve havuzlama katmanının ardından tam bağlı katman uygulanmaktadır (Ha ve ark. 2016).

Kullanılan filtrelerin boyutlarına göre evrişimsel sinir ağları bir, iki veya üç boyutlu olabilmektedir. Bir boyutlu evrişimsel sinir ağı (1B-ESA), hiperspektral görüntüyü piksel düzeyinde sınıflandırma için çeşitli çalışmalarda başarıyla kullanılmıştır (Yu ve ark. 2016, Yu ve ark. 2017). Spektral özniteliklerin çıkarılması için kullanılan bir boyutlu YSA'da hiperspektral görüntü pikselinin spektral bir vektörü giriş verisi olarak

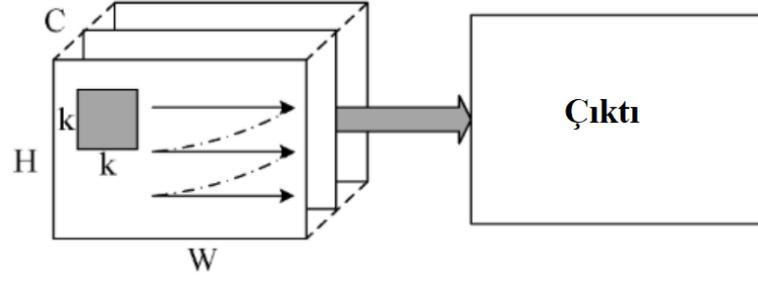
alınmaktadır (Jin ve ark. 2018). İki boyutlu evrişimsel sinir ağları (2B-ESA) ise bilgisayarlı görü, görüntü işleme, görüntü sınıflandırması, nesne algılama ve tek bir görüntüden derinlik tahmini gibi uygulamalarda oldukça başarılı sonuçlar vermektedir. İki boyutlu evrişimsel sinir ağlarının en önemli özelliği doğrudan ham girdi verisi üzerinden öznitelik çıkarımı yapabilmesidir. Bununla birlikte, iki boyutlu evrişim işlemini doğrudan hiperspektral veriye uygulamak, sinir ağına girdisi olan iki boyutlu verinin her birine bir eğitilebilir bir filtrenin uygulanmasını gerektirmektedir. Spektral boyuttaki yüzlerce kanal, çok sayıda filtre ve parametre gerektirmektedir. Bu durum hesaplama yükünü arttırdığı gibi aşırı-uyum problemine de sebep olmaktadır.

Piksellerin yerel uzaysal özniteliklerinin çıkarımını sağlayan 2B-ESA'da iki boyutlu evrişim işlemi, bir boyutlu evrişim işleminin genişletilmesi şeklinde düşünülebilir. Geleneksel bir 2B-ESA'da, önceki katmandan öznitelikleri çıkarmak için Şekil 2.8'de örnek olarak gösterilen iki boyutlu evrişim işlemi uygulanmaktadır.



**Şekil 2.8.** İki boyutlu evrişim işlemi

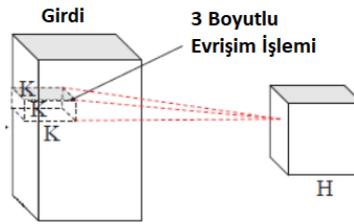
Geleneksel iki boyutlu evrişim uygulamalarında görüntüler tek kanaldan oluşmaktadır. Fakat yapılan çalışmada hiperspektral görüntülerin spektral kanal sayısı oldukça fazladır. Çok kanallı görüntülerde iki boyutlu evrişim işlemi aşamasında evrişim katmanında giriş görüntüsünün her bir kanalına iki boyutlu evrişim işlemi uygulanarak elde edilen çıkış görüntüsünün bir kanalında birleştirilmektedir (Şekil 2.9).



**Şekil 2.9.** Çok kanallı görüntülerde iki boyutlu evrişim işlemi

Hiperspektral görüntü sınıflandırması için iki boyutlu evrişim işlemi, girdi verilerini uzaysal boyutta, üç boyutlu evrişim işlemi ise girdi verilerini hem uzaysal boyutta hem de spektral boyutta aynı anda düzenlemektedir. Üç boyutlu evrişim işlemi için, giriş verisi iki boyutlu veya üç boyutlu olsa da çıktı iki boyutludur. Hiperspektral görüntüye iki boyutlu evrişim işlemleri uygulandığında büyük miktarda spektral bilgi kaybolmaktadır. Üç boyutlu filtreler ise girdilerin spektral bilgisini koruyarak bir çıkış hacmi oluşturur. Zengin spektral bilgi içeren hiperspektral görüntü için spektral bilginin korunması oldukça önemlidir.

Şekil 2.10'da gösterilen üç boyutlu bir komşuluk penceresine uygulanan üç boyutlu evrişim işlemi adım adım yukarıdan aşağıya, sağdan sola ve içten dışa olarak gerçekleştirilmektedir. Her adımda bir evrişimli skalar üretilir ve özellik haritasının ilgili pozisyonuna yerleştirilir (Şekil 2.10'da kırmızı çizgilerle gösterilmiştir). Bu işlem bir özellik haritası olarak daha küçük bir üç boyutlu küp üretmektedir (Yang ve ark. 2018).



**Şekil 2.10.** Hiperspektral görüntüde üç boyutlu evrişim işlemi

### 2.4.1.1. Evrişim katmanı

ESA mimarisinin temelini oluşturan evrişim katmanı temel olarak dönüşüm işlemi yapmaktadır. Bu dönüşüm işlemi bir filtrenin tüm görüntü üzerinde gezdirilmesi ile gerçekleşmektedir. Bu sebeple filtreler evrişimsel mimarinin en önemli bileşenlerindedir. Farklı boyutlarda olabilen bu filtreler, bir önceki katmandan gelen görüntülere doğrusal bir matematik işlemi olan evrişim işlemi uygulanarak çıktı verisini ve özellik haritasını oluşturur. Öznitelik haritası ile her bir filtreye özgü olan özellikler keşfedilmektedir. Evrişimsel sınır ağının eğitimi sırasında bu filtrelerin katsayıları güncellenerek verinin hangi bölgelerinin daha önemli olduğu tespit edilmektedir (İnik ve Ülker 2017).

Evrişim katmanında kullanılan filtreler genel olarak 3x3, 5x5 ve 7x7 boyutlarında tercih edilmektedir. 3x3'lük ve 5x5'lik filtre örnekleri Şekil 2.11'de yer almaktadır.

1	1	1	0	0
0	0	1	1	1
1	0	1	0	1
0	0	1	1	1
1	1	0	0	0

(a)

1	0	1
0	1	0
1	0	1

(b)

Şekil 2.11. 5x5 boyutunda (a) ve 3x3 boyutunda (b) filtre örnekleri

Evrişim katmanında kullanılan filtreler yalnızca belirli özellikleri algılamak için eğitilmiş çeşitli ağırlık değerlerinden oluşan bir değer matrisidir. Bu filtreler algılanması istenen özelliğin bulunup bulunmadığını kontrol etmek için resmin her bir parçası üzerinde hareket etmektedir. Filtre, görüntünün üzerinde daha önceden belirlenen filtre adım sayısı (stride,  $S$ ) kadar görüntü üzerinde yer değiştirir. Her konumda filtre ile görüntünün filtre ile üst üste geldiği pikseller çarpılıp toplanarak bir değer elde edilir ve bu değer yeni bir matrise yazılır. Bu çıktı değerlerinin oluşturduğu matrise öznitelik haritası denir. Bu

işlemi matematiksel olarak temsil etmek için  $n_1 \times n_2$  boyutlarında  $I = \{1, \dots, n_1\} \times \{1, \dots, n_2\} \rightarrow W \subseteq \mathbb{R}, (i, j) I_{i,j}$  şeklinde temsil edilen bir  $I$  resmi düşünelim.  $K \in \mathbb{R}^{2h_1 + 1 \times 2h_2 + 1}$  şeklinde verilen bir  $K$  filtresi ile resim  $I$ 'nın evrişim işlemi aşağıdaki şekilde hesaplanmaktadır.

$$(I * K)_{r,s} := \sum_{u=-h_1}^{h_1} \sum_{v=-h_2}^{h_2} K_{U,V} I_{r+u, s+v} \quad (2.7)$$

Ayrıca  $K$  filtresi aşağıdaki matrisle temsil edilmektedir.

$$K = \begin{pmatrix} K_{-h_1, -h_2} & \dots & K_{-h_1, -h_2} \\ \dots & K_{0,0} & \dots \\ K_{h_1, -h_2} & \dots & K_{h_1, h_2} \end{pmatrix} \quad (2.8)$$

Katman  $l$ 'nin evrişim katmanı olduğu düşünüldüğünde  $l$  katmanının girdisi bir önceki katmandan her biri  $m_2^{(l-1)}$  ve  $m_3^{(l-1)}$  boyutlarındaki  $m_1^{(l-1)}$  adet öznitelik haritasıdır. Bu durumda  $l$  katmanının çıktısı  $m_2^{(l)} \times m_3^{(l)}$  boyutlarında  $m_1^{(l)}$  adet öznitelik haritası içermektedir. Katman  $l$ 'deki  $Y_i^{(l)}$  olarak temsil edilen öznitelik haritası  $i$  aşağıdaki denklem (2.9) ile hesaplanmaktadır.

$$Y_i^{(l)} = B_i^{(l)} + \sum_{j=1}^{m_1^{(l-1)}} K_{i,j}^{(l)} * Y_j^{(l-1)} \quad (2.9)$$

Denklem (2.9)'da  $B_i^{(l)}$  değişkeni bias matrisini,  $K_{i,j}^{(l)}$  ise  $(l-1)$  katmanındaki öznitelik haritası  $j$  ve  $l$  katmanındaki öznitelik haritası  $i$ 'ye bağlantısı olan  $2h_1^{(l)} + 1 \times 2h_2^{(l)} + 1$  boyutundaki filtreyi temsil etmektedir. Evrişim katmanında yapılan işlemler çok katmanlı algılayıcılar açısından yeniden düzenlenebilmektedir. Katman  $l$ 'deki her bir öznitelik haritası  $Y_i^{(l)}$ , iki boyutlu bir dizide düzenlenmiş şekilde  $m_2^{(l)} \cdot m_3^{(l)}$  boyutunda nöron içermektedir.  $(r,s)$  pozisyonundaki nöronun çıktısı ise denklem (2.10) ile

hesaplanmaktadır. Sınır ağındaki eğitilebilir ağırlıklar  $K_{i,j}^{(l)}$  filtrelerinde ve bias matrisi  $B_i^{(l)}$ , de bulunmaktadır.

$$\begin{aligned} (Y_i^{(l)})_{r,s} &= (B_i^{(l)})_{r,s} + \sum_{j=1}^{m_1^{(l-1)}} (K_{i,j}^{(l)} * Y_j^{(l-1)})_{r,s} \\ &= (B_i^{(l)})_{r,s} + \sum_{j=1}^{m_1^{(l-1)}} \sum_{u=-h_1^{(l)}}^{h_1^{(l)}} \sum_{v=-h_2^{(l)}}^{h_2^{(l)}} (K_{i,j}^{(l)})_{u,v} (Y_j^{(l-1)})_{r+u,s+v} \end{aligned} \quad (2.10)$$

Gürültü ve bozukluk etkilerini azaltmayı sağlayan filtre adım sayısı  $S$  ise filtre uygulanmadan önce yatay ve düşey yönde belirtilen sayıda pikselin işleme alınmadan atlanmasını sağlar.  $S$  değeri ile beraber çıktı öznetelik haritasının boyutu denklem (2.11)'deki gibi hesaplanmaktadır (Stutz 2014).

$$m_2^{(l)} = \frac{m_2^{(l-1)} - 2h_1^{(l)}}{s_1^{(l)} + 1} \text{ ve } m_3^{(l)} = \frac{m_3^{(l-1)} - 2h_2^{(l)}}{s_2^{(l)} + 1} \quad (2.11)$$

#### 2.4.1.2. Havuzlama katmanı

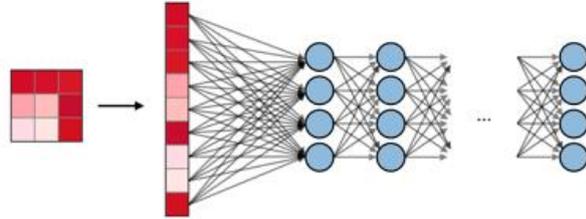
Havuzlama katmanı, görüntünün çok büyük olduğu durumlarda parametre sayısını ve genel olarak verinin boyutunu azaltırken önemli bilgileri korumak için kullanılan katmandır.

Evrişim katmanından sonraki aşamada uygulanan havuzlama katmanında, evrişim katmanına benzer olarak çeşitli filtreler kullanılmaktadır. Evrişim işleminde olduğu gibi daha önceden seçilen filtre adımı ve seçilen işleme göre filtre alanı ve görüntü piksellerinin üst üste geldiği bölge içindeki değerlerinin ortalaması veya maksimum değeri alınarak bir değer ortaya çıkarılmaktadır. Görüntünün en üst sol köşesinden filtre adım parametresine göre sağa kaydırılarak işlemler tekrarlanmaktadır. Tekrar en sol kısma gelinerek filtre adımı değerine göre aşağıya doğru kaydırılarak aynı işlemler uygulanmaktadır. Bu işlemler görüntünün en alt sağ köşesine kadar devam etmektedir. Elde edilen çıktı değerleri ile boyutu indirgenmiş bir öznetelik haritası elde edilmektedir. Maksimum, minimum ve ortalama gibi havuzlama katmanı işlevleri bulunmaktadır.

### 2.4.1.3. Tam bağı katman

Yapay sinir ağı olarak çalışan bu katman üretilen öznitelik haritalarını girdi olarak alarak sınıflandırma işlemi yapılmasını sağlar. Tam bağı bir katmandaki tüm nöronlar bir önceki katmandaki nöronların tümüne bağlıdır. Evrişim ve havuzlama katmanlarından gelen bilgiler sonucu oluşan bu çıktı, giriş görüntüsünün üst düzey özelliklerini temsil etmektedir. Tam bağı katmanın amacı, giriş görüntüsünü eğitim veri setine göre sınıflandırmak için bu özellikleri kullanmaktır. Tam bağı katmanın çıktısı eğitimde kullanılan sınıf sayısına eşittir. Öznitelik haritasından görüntülerin hangi sınıfa ait olduğu olasılıksal olarak belirtmek için softmax fonksiyonu kullanılmaktadır.

Şekil 2.12’de temsil edildiği gibi, tam bağı katmanda giriş bilgisi tek boyutlu bir vektöre çevrilerek çıkış olasılıklarını tahmin etmek için bir nöron ağı üzerinden geçirilir. Düzleştirilmiş veri, ileri beslemeli bir sinir ağına iletilir ve eğitimin her iterasyonunda geri yayılma uygulanır. Bu işlemlerin belirli sayıda tekrarlanmasından sonra elde edilen model basit ve zayıf düzeydeki öznitelikleri ayırt edebilecek duruma gelmektedir.



Şekil 2.12. Tam bağı katman (Amidi ve Amidi 2019’den değiştirilerek alınmıştır)

Katman  $l$ 'nin tam bağı bir katman olduğunu düşünülürken  $(l-1)$  katmanının tam bağı bir katman olması durumunda denklem (2.5) veya (2.6) kullanılmaktadır. Aksi halde katman  $l$ ,  $m_2^{(l-1)} \times m_3^{(l-1)}$  boyutunda bir  $m_1^{(l-1)}$  öznitelik haritasını girdi olarak almaktadır. Katman  $l$ 'deki düğüm  $i$  ise aşağıdaki şekilde hesaplanmaktadır (Stutz 2014).

$$y_i^{(l)} = f(z_i^{(l)}) \text{ ile } z_i^{(l)} = \sum_{r=1}^{m_1^{(l-1)}} \sum_{s=1}^{m_3^{(l-1)}} w_{i,j,r,s}^{(l)} \left( Y_j^{(l-1)} \right)_{r,s} \quad (2.12)$$

Denklem (2.12)'de  $w_{i,j,r,s}^{(l)}$  ağırlığı katman  $(l-1)$ 'deki öznitelik haritası  $j$  ve katman  $l$ 'deki öznitelik haritası  $i$  arasındaki  $(r,s)$  pozisyonundaki nöronuna bağlı ağırlığı temsil etmektedir (Stutz 2014).

Evrişimsel katmanlar uygulamada, bir özellik hiyerarşisini öğrenmek için kullanılmaktadır. Bir ya da daha fazla tam olarak bağlı katmanlar ise hesaplanan özelliklere dayalı sınıflandırma amacıyla kullanılır. Bir sınıflandırma işleminde ikiden fazla sınıf varsa, softmax fonksiyonunu tam bağlı çıktı katmanı olarak kullanmak bir standarttır. Softmax fonksiyonu,  $N$  boyutlu gerçek sayı vektörünü  $(0,1)$  aralığında ve toplamı 1 olan gerçek sayı vektörüne dönüştürür.  $e^{a_i}$  değeri  $i$  çıktısının aktivasyon değerini ifade etmek üzere; softmax fonksiyonu matematiksel olarak denklem (2.13) ile ifade edilmektedir (Hinton ve ark. 2012).

$$p_i = \frac{e^{a_i}}{\sum_{k=1}^N e^{a_k}} \quad (2.13)$$

Bir olasılık dağılımını çıkararak softmax fonksiyonu sinir ağlarında son katman olarak kullanılır. Bunun için türev veya gradyanı hesaplanması ve geri yayılma sırasında önceki katmana geri dönülmesi gerekmektedir (Denklem 2.14).

$$\frac{\partial p_i}{\partial a_j} = \frac{\partial \frac{e^{a_i}}{\sum_{k=1}^N e^{a_k}}}{\partial a_j} \quad (2.14)$$

#### 2.4.2. Evrişimsel sinir ağı eğitimi

Yüksek boyutlu verilerle çalışıldığında derin öğrenme yaklaşımları hesaplama açısından maliyetli duruma gelmektedir. Bu yüksek maliyetler temel olarak veri soyutlamalarını öğrenmek ve özniteliklerin düşük seviyelerden en yüksek seviyedeki öznitelik temsiline dönüştürmek için gerekli olan yavaş öğrenme sürecinden kaynaklanmaktadır. Yüksek boyutlu veriler, ham veri hacmine büyük ölçüde katkıda bulursa da bu verilerden

öğrenme giderek karmaşıklaşmaktadır. ESA'da ise gizli katman ünitelerindeki nöronların önceki katmandaki tüm düğümlere değil, daha sınırlandırılmış bir alana bağlanması gerekmektedir. Ayrıca havuzlama katmanlarının kullanımı ile daha yüksek katmanlarda görüntünün çözünürlüğü azalmaktadır. Fakat bu durum daha zor ve karmaşık problemlere sebep olmaktadır.

Derin ve geniş yapılara dayanan derin öğrenme modellerinin eğitiminde çok sayıda parametre optimize edilmelidir. Bu modellerin kurulması ve eğitilmesi zor, maliyeti oldukça yüksektir. Aynı zamanda bu modeller fazla sayıda etiketlenmiş veriye ihtiyaç duyulmaktadır. Fakat hiperspektral veriler geniş spektrumlu etiketli veri açısından fakirdir.

Günümüzde derin öğrenme kullanımındaki temel özellik çok çeşitli karmaşık uygulamalarla başa çıkabilmesidir. Fakat bu verilerin işlenmesinde ucuz ve etkili model oluşturma görevlerin karmaşıklaşmasına sebep olmaktadır. Bu sebeple derin mimarilerin hesaplama maliyetlerinin doğru sonuçlar ve gerekli eğitim bilgileri açısından optimize edilmesi önemli bir ihtiyaçtır.

#### **2.4.2.1. Maliyet fonksiyonu**

Ağın ürettiği sonuç ile gerçek değer arasındaki farkın değerlendirilmesinde maliyet fonksiyonları kullanılmaktadır. Sinir ağındaki parametreleri optimize etmeyi sağlayan maliyet fonksiyonu, ağ için bir parametre değeri kümesini, bu parametrenin ağın yapmayı amaçladığı görevi ne kadar iyi yaptığını gösteren bir skalar değer ile eşleştirir.

Yaygın olarak kullanılan maliyet fonksiyonları genellikle bir ağın çıkışı ile bazı hedef veya istenen çıktılar arasındaki kare veya mutlak hatayı ölçer. Diğer kayıp fonksiyonları, sınıflandırma modelleri için özel olarak tasarlanmıştır. Çizelge 2.3'de özetlendiği gibi farklı türden problemler için farklı maliyet fonksiyonları kullanılmaktadır. Bu fonksiyonlar aynı problem için farklı hatalar vereceğinden modelin performansı üzerinde maliyet fonksiyonu seçiminin etkisi büyüktür. En yaygın kullanılan kayıp fonksiyonlarından biri, gerçek değer ile öngörülen değer arasındaki farkın karesini hesaplayan ortalama kare hatasıdır. Yapay sinir ağının çıktısı  $y(x_n)$  ve istenen hedef çıktı

$t_n$  olmak üzere bir diğer yaygın olarak kullanılan maliyet fonksiyonu kareler toplamı ( $E$ ) hatası denklem (2.15) ile ifade edilmektedir.

$$E(w) = \sum_{n=1}^N E_n(w) = \sum_{n=1}^N \sum_{k=1}^C (y_k(x_n, w) - t_{n,k})^2 \quad (2.15)$$

Maliyet fonksiyonunu hesaplamak için kullanılan matematiksel fonksiyon her zaman denklem (2.15)'de belirtilen ifade olmak zorunda değildir. Çeşitli maliyet fonksiyonu hesaplama yöntemleri Çizelge 2.3'te belirtilmiştir

Derin sinir ağlarında en yaygın olarak kullanılan maliyet fonksiyonu çapraz entropi maliyet fonksiyonudur. Çapraz entropi, modelin çıktı dağılımının hesaplanan değeri ile orijinal dağılımın gerçekte ne olduğu arasındaki mesafeyi göstermektedir. Çapraz entropi matematiksel olarak denklem (2.16) ile ifade edilmektedir.

$$H(y, p) = - \sum y_i \log(p_i) \quad (2.16)$$

Çıkış katmanında softmax fonksiyonunun kullanıldığı sinir ağlarında daha gürbüz ve hızlı sonuçlar alınmasını sağlayan çapraz entropi fonksiyonu, tahmin edilen her olasılık değerini gerçek sınıf değerleriyle karşılaştırmaktadır. Tahmin ve gerçek değer arasındaki mesafeye göre logaritmik olarak artan ceza puanı uygulanmaktadır (Sabuncu ve Zhang 2018).

**Çizelge 2.3.** Maliyet Fonksiyonları

Maliyet Fonksiyonu	Denklem
İkinci Dereceden Maliyet Fonksiyonu	$L = \frac{1}{N} \sum_{i=1}^N (x_i - \widehat{x}_i)^2$
Çapraz Entropi Maliyet Fonksiyonu	$L = \frac{1}{N} \sum_{i=1}^N \widehat{x}_i \ln(x_i) + (1 - \widehat{x}_i) \ln(1 - x_i)$
Üsteli Maliyet Fonksiyonu	$L = \frac{1}{N} \tau \exp \frac{1}{\tau} \sum_{i=1}^N (x_i - \widehat{x}_i)^2$

### 2.4.2.2. Dereceli azalma (Gradient descent)

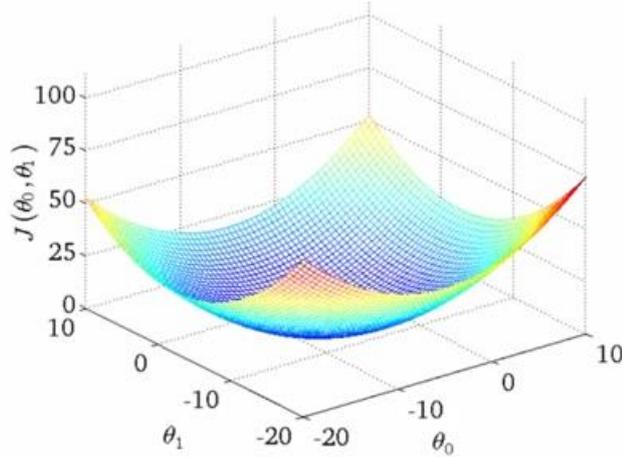
Dereceli azalma (gradient descent) yöntemi bir sinir ağını optimize etmede kullanılan en popüler optimizasyon algoritmasıdır. Sinir ağı modellerinde maliyet fonksiyonunu en aza indirgeyecek yönde ağırlık güncellemelerini ve model parametrelerinin ayarlamasını sağlamaktadır. Dereceli azalma,  $\theta \in \mathbb{R}_d$  parametreleri tarafından parametrelendirilen  $J(\theta)$  nesnel fonksiyonunu, hedef fonksiyonun gradyanının ters yönündeki parametrelerle güncelleyerek en aza indirgemenin bir yoludur. Öğrenme adımı  $\eta$  (yerel) bir asgariye ulaşmak için attığımız adımların boyutunu belirlemektedir. Minimum noktasına ulaşabilmek için bu adımın büyüklüğü dikkatli seçilmelidir. Öğrenme adımının çok büyük seçilmesi durumunda minimum noktasına ulaşılmadan hata fonksiyonu üzerinde “vadi” adı verilen sırtlara sıçrama ihtimali bulunmaktadır. Adımın küçük seçilmesi durumunda ise eğitimin süresi oldukça uzayabilir ve parametreler yerel minimum noktalarına sıkışabilir. Dereceli azalma işlemi matematiksel olarak denklem (2.17) ile ifade edilmektedir (Ruder 2016).

$$\theta = \theta - \eta \cdot \nabla J(\theta) \quad (2.17)$$

Derin öğrenmede YSA parametrelerinin güncellemesi geri yayılım işlemi ile yapılmaktadır. Bu süreçte ilk olarak girdi sinyalleri ve sinyallere karşılık gelen ağırlıkların çarpımı hesaplanmaktadır. Ardından bu toplam bilgiye, giriş sinyalini çıkış sinyaline çeviren ve karmaşık doğrusal olmayan fonksiyonları modellemek için bir aktivasyon işlemi uygulanmaktadır. Daha sonra dereceli azalma yöntemi kullanılarak ağırlıkların güncellenmesi gerçekleştirilmektedir. Bu işlem sırasında hata oranının ağırlıklara göre gradyanı alınır. “Chain Rule” olarak adlandırılan geriye doğru türev alma işlemi ile gradyan hesaplaması yapılmakta ve bu gradyanın zıttı yönünde ağırlıklar güncellenerek hata oranı en aza indirilmeye çalışılmaktadır (Wengert 1964).

Sinir ağı hata fonksiyonunun Şekil 2.13’deki gibi olduğu farz edildiğinde  $x$  ve  $y$  eksenleri ağırlık değerlerini,  $z$  eksenini ise bu ağırlıklara bağlı olarak hesaplanan maliyet fonksiyonunu temsil etmektedir. Amaç, maliyet fonksiyonunu minimum yapan ağırlık

değerlerini bulmaktır. Başlangıç olarak, rastgele ağırlık değerleri seçilmektedir. Seçilen ağırlıklara göre başlangıç noktasından maliyet fonksiyonunun değerinde en hızlı düşüşe sebep olacak yönde ilerleme yapılmalıdır.



**Şekil 2.13.** Dereceli azalma (gradient descent)

Gradyanın yönü, hangi yönün en dik yükselişe sahip olduğunu söylerken büyüklüğü ise yükseliş veya inişin ne kadar dik olduğunu belirtmektedir. İlerlenilmesi gereken yön elde edilen gradyanın tam tersi yönde seçilmelidir. Gradyan fonksiyonu en dik çıkışa sahip olan yönü verdiği için karşıdaki yön en dik iniş yönüdür ve bu yön boyunca iniş yapılarak minimum noktası bulunur. İlerlenecek yöne karar verildikten sonra, ilerleme  $\eta$  değerine karar verilmelidir.

Gradyan ve öğrenme hızına karar verildiğinde bir adım ilerledikten sonra gradyan bu pozisyonda yeniden hesaplanır. Bu adımlar tekrarlanarak yüzeyin düz olduğu minimum noktasında gradyan değerinin neredeyse sıfır olması beklenmektedir (Ruder 2016).

YSA'da ağız öğrenme başarısı maliyet fonksiyonunu minimuma indirgeyecek parametrelerin elde edilmesi ile ölçülmektedir. Başarımı belirleyen bu parametrelerin daha hızlı güncellenmesi için dereceli azalma yönteminin optimizasyonu ile ilgili pek çok yöntem önerilmiştir. Bu optimizasyon yöntemleri genel olarak parametrelerin daha hızlı güncellenmesi amacıyla geliştirilmiştir. Fakat aynı zamanda bu yöntemler, dereceli azalma yönteminin dezavantajlarından biri olan sabit öğrenme katsayısı sorununun da

önüne geçmeyi amaçlamıştır. Bu yöntemler ile sabit bir öğrenme adımı yerine, öğrenme katsayısı her adımda güncellenmektedir ya da hiç kullanılmamaktadır.

### **Momentum**

Bu yöntem, gradyanların üssel ağırlık ortalaması dikkate alınarak, gradyan iniş algoritmasını hızlandırmak için kullanılır. Momentum yöntemi ile geçmiş parametreler güncellenirken geçmiş gradyanlar da hesaba katılır. Bu sayede minimal noktaya daha hızlı bir şekilde yaklaşılmaktadır (Yazan ve Talu 2017).

### **Adagrad**

Dereceli azalma yöntemindeki sabit öğrenme katsayısı probleminin çözümü için önerilmiş bir yöntemdir. Geçmiş gradyan bilgilerinin karesini tutan, parametre sayısı ile aynı boyutta bir matris ile  $\eta$  her adımda güncellenmektedir (Yazan ve Talu 2017).

### **Adadelta**

Adagrad yönteminde geçmiş gradyan bilgilerini tutan matris büyüdükçe öğrenme adımı sıfıra yaklaşmaktadır. Bu durumun önüne geçmek için geliştirilen Adadelta yöntemi ile öğrenme katsayısının yok olmasının önüne geçilmektedir. Aynı zamanda başlangıçta öğrenme adımı parametresine olan ihtiyaç da giderilmiştir (Yazan ve Talu 2017).

### **RMSProp**

RMSProp iyileştiricisi Geoff Hinton tarafından önerilmiş bir yöntemdir. Momentumlu dereceli azalma algoritmasına benzemektedir. Dikey yönde salınımları kısıtlayarak algoritmaların yatay doğrultuda daha hızlı ve daha büyük adımlarla minimum noktasına yaklaşmasını sağlamaktadır. (Yazan ve Talu 2017).

### **Adam**

Her iterasyonda  $\eta$  değerini güncelleyen bu yöntem, Adagrad ve RMSProp yöntemlerinin avantajlarını bir araya getirmiştir. RMSProp yönteminden farkı ise parametre

güncellemesini gradyan üzerinde bir momentum kullanarak değil, gradyanın ilk ve ikinci moment ortalamasını kullanarak hesaplamasıdır (Yazan ve Talu 2017).

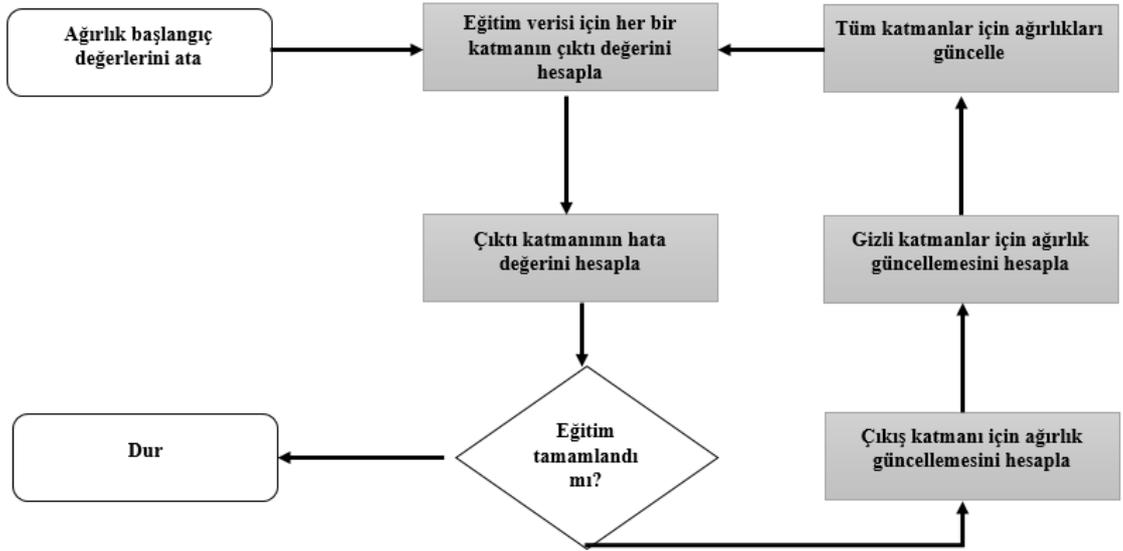
### 2.4.2.3. Geri yayılım algoritması (Backpropagation)

Geri yayılım algoritması hedeflenen çıktı ve her çıktı biriminin çıktıları arasındaki fark olan maliyet fonksiyonunu hesaplayarak, her çıkış ünitesindeki hatayı en aza indirmeyi hedefleyen algoritmadır. Hata beklenen seviye kadar indirgenene kadar ileri ve geri besleme adımları uygulanmaya devam etmektedir. Her döngüde maliyet fonksiyonunun gradyanı hesaplandığından maliyet fonksiyonun devam ettirebilir ve türevlenebilir olması önemlidir. Ağın bağlantı ağırlıklarında yapılan değişiklikler ile en az hata oranına ulaşmak amaçlanmaktadır (Kurt 2018).

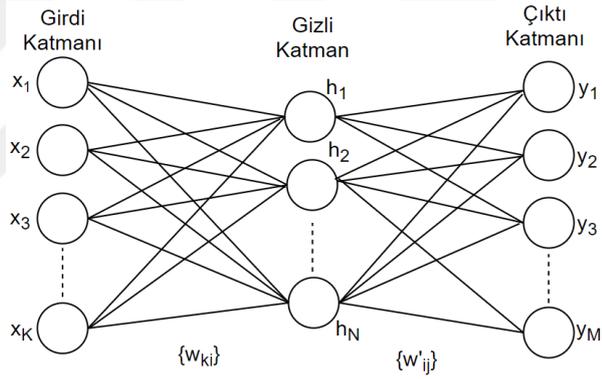
Geri yayılım algoritması iki aşamada gerçekleşmektedir. İlk aşamada girdiler çıkış değerini hesaplamak için ağ üzerinden katmanlar boyunca iletilmektedir. İstenen çıkış değeri, ağın çıkış değeri ile karşılaştırılarak her çıkış birimi için hata değeri hesaplanmaktadır. Bu adım esnasında, her gizli katmandaki hata oranı da hesaplanmaktadır. Benzer şekilde bir önceki katmanın hata oranı da hesaplanarak ağırlıklar optimize edilmektedir. İkinci aşamada ise uygun ağırlık değişimlerini hesaplamak için ağ üzerinden hata sinyalinin her birime iletiği bir geri yayılım işlemi uygulanmaktadır. Şekil 2.14’de geri yayılım algoritması ile bir yapay sinir ağının eğitimi adım adım ifade edilmiştir (Hossain ve ark. 2013).

Tipik bir yapay sinir ağının giriş, gizli ve çıkış katmanları olmak üzere üç çeşit katmandan oluştuğu belirtilmişti. Şekil 2.15, üç katmanlı basitleştirilmiş bir yapay sinir ağını temsil etmektedir. Bu ağ üzerinden eğitim ve ağırlık güncellemeleri matematiksel olarak anlatılmıştır.

Bir yapay sinir ağının eğitimi sırasında asıl amaç, test verisi  $y(x_k)$  ve sinir ağının çıktısı arasındaki hata oranının geri besleme algoritması minimize edilmesidir. Bu işlem genel olarak en küçük kareler hatasını en aza indirmek için  $w_{ij}$  ve  $w_{jk}$  ağırlıklarının ayarlanması ile gerçekleştirilir.



Şekil 2.14. Geri yayılım algoritması



Şekil 2.15. Üç katmanlı basitleştirilmiş bir yapay sinir ağı

Girdilerin ağırlıklandırılmasından ve bu ağırlıkların toplanmasından sonra sonuç verisi belirlenen doğrusal olmayan aktivasyon fonksiyonlarından geçirilmektedir. Şekil 2.15'deki örnek sinir ağında giriş katmanı  $x = \{x_1, \dots, x_K\}$  girdi vektörünü gizli katman ise  $N$  adet nörondan oluşan  $h = \{h_1, \dots, h_N\}$  vektörünü içermektedir. Çıktı katmanı ise her bir element için  $y = \{y_1, \dots, y_M\}$  şeklinde çıkış vektöründen oluşmaktadır. Girdi katmanındaki her bir element gizli katman  $i$  ve giriş katmanı  $k$  arasındaki bağlantının ağırlığını temsil eden  $w_{ki}$  ağırlığı ile ağırlıklanmıştır. Aynı şekilde gizli katman  $i$  ve çıkış katmanı  $j$  arasındaki ağırlık ise  $w'_{ij}$  ile temsil edilmektedir.

Giriş katmanından ağırlıklandırılmış verileri alan  $h_i$  gizli katman çıktısı denklem (2.18) ile üretilmektedir.

$$h_i = f(u_i) = f\left(\sum_{k=1}^K w_{ki} x_k\right) \quad (2.18)$$

Benzer şekilde gizli katmandan gelen bilgileri girdi olarak alan  $y_j$  çıktı katmanı çıktısı ise denklem (2.19) ile hesaplanmaktadır.

$$y_j = f(u'_j) = f\left(\sum_{i=1}^N w'_{ij} h_i\right) \quad (2.19)$$

Çıktı katmanındaki çıkış verilerinin ve gerçek çıktı bilgilerinin arasındaki maliyet değeri ise denklem (2.20) ile hesaplanmaktadır.

$$E = \frac{1}{2} \sum_{j=1}^M (y_j - t_j)^2 \quad (2.20)$$

Sinir ağının çıktısı arasındaki hatayı minimuma indirmek için giriş katmanından gizli katmana olan bağlantının ağırlığı  $w_{ki}$  ve gizli katmandan çıkış katmanına olan bağlantı ağırlığı  $w'_{ij}$ 'nin güncellenmesi gerekmektedir. Ağırlıkları optimize etmek için kullanılan yöntem ise dereceli azalma yöntemidir. Bu bağlamda hesaplanmak istenen değer maliyet fonksiyonunun ağırlık değişiminden ne kadar etkilendiğini ve çıktı ağırlıklarının güncelleme adımını bulmak için maliyet fonksiyonunun ağırlık değerine göre türevi bulunmalıdır. YSA mimarisinde gradyan tüm parametreler üzerinden tek seferde hesaplanmayacağı için geri yayılım algoritması uygulanmaktadır. Bunu sağlamak için  $E$  hata oranının  $w_{ki}$  ve  $w'_{ij}$  ağırlıklarına göre türevi hesaplanmalıdır. Öncelikle gizli katman ve çıktı katmanı arasındaki gradienti bulabilmek için zincir kuralına göre  $\partial E / w'_{ij}$  değeri elde edilmelidir. Bu işlem denklem (2.21) ile belirtilmiştir.

$$\frac{\partial E}{\partial w'_{ij}} = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial u'_j} \cdot \frac{\partial u'_j}{\partial w'_{ij}} \quad (2.21)$$

Giriş ve gizli katmanlar arasındaki  $w_{ki}$  ağırlığının ve maliyet fonksiyonunun gradyanına dönecek olursak; bu güncelleme de zincir kuralı kullanarak denklem (2.22) ile ifade edilir.

$$\frac{\partial E}{\partial w_{ki}} = \sum_{j=1}^M \left( \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial u_j'} \cdot \frac{\partial u_j'}{\partial h_i} \right) \cdot \frac{\partial h_i}{\partial u_i} \cdot \frac{\partial u_i}{\partial w_{ki}} \quad (2.22)$$

Çıkış nöronu  $j$  için son çıkış hatası  $y_j - t_j$  değerinin hesaplanmasıyla başlayan süreç, bu hatanın ağ boyunca ağırlıkları güncellemek için geriye doğru yayılmasını ifade etmektedir.

#### 2.4.2.4. Evrişimsel sinir ağlarında parametreler

ESA yöntemi birçok karmaşık makine öğrenme görevinde yaygın olarak kullanılmaktadır. Bununla birlikte, doğruluk ve performansı doğrudan etkileyen hiper parametrelerin optimizasyonu ESA mimarilerinin geliştirilmesinde önemli bir konudur. Tasarlanan modelin yüksek başarımlar sağladığı birbirinden farklı hiper parametre grupları olabilmektedir. Fakat en uygun parametre grubunun tespit edilmesi genelde tasarımcının sezgisine, daha önceki çalışmalardan elde edilen tecrübeler, farklı alanlardaki problemlerde kullanılan yöntemlere ve güncel yöntemlere bağlı olarak değişebilmektedir. Evrişimli sinir ağlarında evrişimli tabakalarının sayısı, tam bağlı katmanların ve nöronların sayısı, bırakma uygulama olasılığı, öğrenme adımı gibi bir dizi hiper parametrenin uygun şekilde belirlenmesi gerekmektedir. Aynı zamanda filtre derinliği ve boyutları, adım sayısı ve sıfır dolgusu gibi parametrelerin seçimi de oldukça önemlidir.

Filtre sayısı, filtre boyutu ve ağ mimarisi gibi parametreler, eğitim sürecinden önce ağ tasarlayan kişi tarafından belirlenmektedir.

ESA, eğitim esnasında filtre değerlerini geri yayılım işlemi ile güncelleyerek kendi kendine öğrenmektedir. Kullanılan filtre sayısı arttıkça, görüntü özellikleri daha iyi ortaya çıkarılıp, görüntünün sınıflandırılmasında daha iyi sonuçlar elde edilebilir. ESA uygulamalarında genel olarak 3x3, 5x5 ve 7x7 boyutunda filtreler kullanılmaktadır. Büyük boyutlu filtreler, evrişim işlemi sonucunda oluşacak resmin küçülmesine neden

olmaktadır. Aynı zamanda büyük boyutta filtre kullanımı hesaplama karmaşıklığını arttırmaktadır. Bu nedenle, uygulamalarda küçük boyutlu filtreler tercih edilmektedir.

Öte yandan öğreticili öğrenme tekniklerinde ağın genişliği ve derinliği de önemli bir rol oynamaktadır. Ağın genişliği, gizli katmanlardaki düğümlerin sayısını ifade ederken, ağın derinliği ise ağdaki gizli katmanların sayısını temsil etmektedir. Daha çok gizli katman kullanımı düzenlileştirme tekniklerinin kullanımı ile doğruluğu arttırırken, daha az sayıda katman yetersiz öğrenmeye sebep olabilir. Fakat gizli katman sayısı çok fazla arttırıldığında geri beslemenin etkisi ilk katmanlara doğru kaybolduğundan başarımlar artmamaktadır.

Görüntüler üzerinde evrişim işlemini gerçekleştiren filtreler belirlenen filtre adım sayısına ( $S$ ) göre hareket etmektedir. Bu değer, evrişim veya havuzlama işlemlerinden sonra filtrenin hareket ettiği piksel sayısını belirtmektedir. Adım sayısının iki veya daha fazla olması, çıktı boyutunun girdiden daha düşük olmasına neden olmaktadır. Aynı zamanda küçük basamak sayıları tüm uzaysal aşağı örnekleme için havuzlama katmanına bırakılmasına izin vermektedir. Sıfır ekleme işlemi ise, girdi sınırlarının her bir tarafına istenen sayıda sıfır ekleme işlemini belirtmektedir. Bu sayede girdinin köşelerindeki elemanlara da filtreleme işlemi yapılması sağlanmaktadır. Ekleme işlemi yapılmadığında filtre ve girdinin boyutları uymuyorsa son evrişim işlemi yapılmamaktadır. Öte yandan, sıfır ekleme işlemi yapılmadan uzaysal boyutları sabit tutmak performansı arttırsa da, sadece geçerli evrişim işlemleri gerçekleştirildiğinde, her bir evrişimden sonra veri hacmi küçük bir miktar azalır ve sınırlardaki bilgiler çok hızlı bir şekilde kaybolmaktadır.

Bahsedilen hiper parametreler belirlendikten sonra her bir katmanda, katmanın türüne göre eğitilebilir parametreler oluşmaktadır. Eğitilebilir parametrelerin geri besleme ile güncellenmesi sayesinde YSA, veri setinin yapısını öğrenerek test işlemine hazır hale gelmektedir. Örneğin; bir yapay sinir ağında  $W_1 \times H_1 \times D_1$  boyutlarında bir girdi verisinin olduğunu düşünölsün. Filtre sayısı  $K$ , filtrelerin uzaysal boyutu  $F$ , adım sayısı  $S$  ve sıfır ekleme miktarı  $P$  olmak üzere; bu sinir ağında evrişim işlemi gerçekleştikten sonra  $W_2 \times H_2 \times D_2$  boyutunda çıktı oluşmaktadır. Bu boyutlar aşağıdaki şekilde hesaplanmaktadır.

$$W_2 = (W_1 - F + 2P) / S + 1 \quad (2.23)$$

$$H_2 = (H_1 - F + 2P) / S + 1 \quad (2.24)$$

$$D_2 = K \quad (2.25)$$

YSA mimarilerinde parametre paylaşımı yapıldığı için her bir filtre için  $F \times F \times D_1$  adet olmak üzere, toplam  $(F \times F \times D_1) \times K$  adet ağırlık ve  $K$  adet bias değeri oluşmaktadır. Havuzlama katmanında ise aynı girdi verisi için oluşan çıktının boyutları aşağıdaki şekilde hesaplanmaktadır.

$$W_2 = (W_1 - F) / S + 1 \quad (2.26)$$

$$H_2 = (H_1 - F) / S + 1 \quad (2.27)$$

$$D_2 = D_1 \quad (2.28)$$

Havuzlama katmanında filtre boyutuna göre yalnızca minimum, maksimum veya ortalama değer hesabı yapıldığı için parametre bulunmamaktadır.

Birbirine bağlı tam bağlı katmanlarda ise eğitilebilir parametre hesabı aşağıdaki şekilde hesaplanmaktadır.

Bir FC Katmanına bağlı olan bir FC Katmanının ağırlık sayısı :  $W_{ff}$

Bir FC Katmanına bağlı olan bir FC Katmanının bias sayısı :  $B_{ff}$

Bir FC Katmanına bağlı olan bir FC Katmanının parametre sayısı :  $P_{ff}$

FC Katmanındaki nöron sayısı :  $F$

Bir önceki FC Katmanındaki nöron sayısı :  $F_{-1}$

$$W_{ff} = F_{-1} \times F \quad (2.29)$$

$$B_{ff} = F \quad (2.30)$$

$$P_{ff} = W_{ff} + B_{ff} \quad (2.31)$$

Yukarıdaki eşitlikte bir önceki tam bağlı katmandan mevcut tam bağlı katmana olan bağlantıların toplam sayısı  $F_{-1} \times F$  kadardır. Toplam *bias* değeri nöronların sayısı  $F$  ile aynıdır.

ESA mimarilerinin eğitiminde veri setinde bulunan tüm verileri aynı anda işleyerek öğrenme zaman ve hesaplama açısından maliyetli olduğu için ağı her seferinde tek bir örnekle optimize etmek yerine, bir dizi örnek üzerinden ortalama hata tespiti yapmak daha etkili bir yöntemdir. Bu doğrultuda model eğitilirken belli sayıda paketler eğitimde yer almaktadır. Her bir paket eğitildikten sonra modelin başarımı test edilip geri yayılım ile ağırlıklar güncellenmektedir. Daha sonra yeni eğitim paketi ile eğitim ve güncelleme devam etmektedir. Bu eğitim adımlarının her birine epok adı verilmektedir. Epok değerinin büyüklüğü problemin türüne göre değişiklik göstermektedir.

Sinir ağında işlenecek paket büyüklüğü, sistemin güncellenme aşamasını etkileyen kritik bir parametredir. Paket boyutu arttıkça her bir epok için kullanılacak eğitim örneği de artmaktadır. İlk epoklarda başarımlar düşük olsa da, epok sayısı arttıkça başarımlar da artmaktadır. Bununla birlikte epok değeri büyüdükçe bir noktadan sonra başarımlar daha fazla artmamaktadır. Epok değerini belirlerken doğrulama verisinin başarımı eğitim verisinin başarımının düşmesine rağmen artana kadar (aşırı-uyum) epok değeri artırılabilir.

Sinir ağının eğitimi sürecinde farklı parametrelerin durumunu belirlediği için ağırlıkların başlangıç değerleri oldukça önemlidir. Ağırlık değerlerinin başlangıçta sıfır olarak atanması, tüm nöronların aynı çıktı değeri hesaplamasına ve bu nedenle geri yayılım işleminde eğitim değerlerinin aynı çıkmasına sebep olacağından tüm ağırlıkların aynı değerlerle güncellenmesine sebep olmaktadır. Başlangıç olarak çok küçük değerler kullanılırsa geri yayılım işlemi sırasında küçük eğitim değerleri hesaplandığı için “kaybolan eğitim” adı verilen problem oluşacaktır (Hochreiter 1991). Öte yandan başlangıç değerleri tam olarak sıfır olmasa da küçük değerlere sahip olmalıdır. Bu sayede nöronlarda farklı güncelleme değerleri üretilerek, ağırlıkların birbirlerinden farklı şekillerde ağı uyum göstermesi sağlanmaktadır.

Literatüre pek çok ağırlık başlangıç değeri belirleme yöntemleri önerilmiştir (Kurt 2018). Bu tez çalışmasında ise Xavier (Glorot ve Bengio 2010) ve He ve ark. (2015) tarafından önerilen ve kaybolan eğitim problemini, karmaşık bir başlatma tekniğiyle çözerek tüm ağın

aynı oranda eğitilmesini sağlayan Xavier Başlatıcı yöntemi tercih edilmiştir (Koturwar ve Merchant 2017).

Bir diğer hiper parametre olan öğrenme adımı ( $\eta$ ), optimizasyon algoritmasındaki ağırlığın ne kadar güncelleneceğini kontrol etmektedir.  $\eta$  çok büyük seçildiğinde global minimum noktasının etrafından dolaşılıp bu değere ulaşılamayabilir. Çok küçük bir değer seçildiğinde, yakınsama çok küçük adımlarla yapılacağı için arama süresi oldukça artacaktır. SGD, Adam, Adagrad, AdaDelta veya RMSProp gibi optimizasyon algoritması seçimine bağlı olarak sabit öğrenme adımını, kademeli olarak azalan öğrenme adımını, momentum tabanlı yöntemleri veya uyarlanabilir öğrenme oranları kullanılabilir (Mei ve ark. 2017).

#### **2.4.2.5. Düzenleştirme**

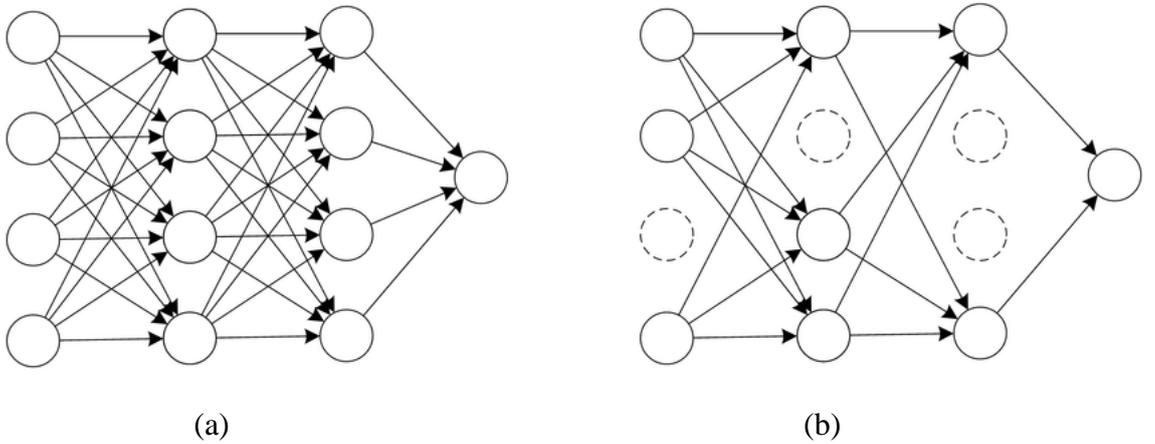
YSA mimarilerinin eğitiminde maliyet fonksiyonu en aza indirilerek, eğitim verilerine göre veriyi en iyi temsil edecek model oluşturulmaya çalışılır. Fakat eğitim verisinin az olduğu durumlarda eğitilen model sadece mevcut eğitim setini temsil edecek şekilde tasarlanmakta ve yeni verilerin sınıflandırılmasında tahmin yeteneği düşük olmaktadır. Mevcut eğitim setini ezberleyen modelin test verileri üzerinde düşük başarı verdiği durumlar aşırı uyum (overfitting) olarak adlandırılmaktadır. Öte yandan aşırı-uyum probleminin tersi az-uyum (underfitting) probleminde ise sinir ağı modeli verinin çeşitliliğini yakalayamamaktadır (Piotrowski ve Napiorkowski 2013, van der Aalst ve ark. 2010). Bu nedenle elde edilen sınıflandırıcı, eğitim verilerini uygun şekilde haritalayamamakta ve test verilerini doğru şekilde tahmin edememektedir. Bu durum veri kümesinin karmaşıklığına oranla daha basit bir model kullanmaktan kaynaklanmaktadır. Aşırı-uyum ve az-uyum problemlerinin önüne geçebilmek için pek çok yöntem kullanılmaktadır (Jabbar ve Khan 2015). Derin öğrenme uygulamalarında özellikle aşırı uyum problemini engellemek için bazı değişiklikler yapılmaktadır. Bu değişiklikler kapsamında eğitim verisinin sayısı artırılabilir ya da karmaşık model basitleştirilebilir. Bunun yanında gereğinden fazla tekrar ile modelin eğitim verisini ezberlemesi engellenebilir. Bir diğer yöntem ise erken durdurma (early stopping) işlemi ile sinir ağı yeterli tekrar sayısına ulaştığında eğitimi durdurmaktır. Bunların yanında aşırı uyum

problemine yönelik çeşitli düzenleme teknikleri önerilmiştir. Bu yöntemlerin içerisinde yaygın olarak L1, L2 ve seyreltme (dropout) teknikleri kullanılmaktadır.

L1 tekniği maliyet tüm ağırlıkların ortalamasını, düzenleme sabiti ile çarparak maliyet fonksiyonuna bu terimi eklemektedir. Bu sayede maliyet fonksiyonunun ağırlıklarına ceza terimi uygulayarak özellikle büyük ağırlık değerlerini sıfıra yakınsamaktadır (Yiğit 2017).

L1 tekniğinde ise ceza terimi değeri hesaplanırken tüm ağırlıkların kareleri alınarak ortalamaları hesaplanmakta ve elde edilen değer düzenleme sabiti ile çarpılarak sonuç ikiye bölünmektedir. Elde edilen değer maliyet fonksiyonuna eklenerek ağırlıkların küçültülmesi amaçlanmaktadır. L1 ve L2 fonksiyonlarında ortak olarak ağırlık küçültme işlemi yapılsa da yöntem olarak farklı tekniklerdir (Yiğit 2017).

Aşırı uyumu önlemek için kullanılan bir diğer yöntem olan seyreltme ise bazı nöronların eğitim esnasında rastgele silinerek ileri besleme ve geri yayımda kullanılmasını önlemektedir. Farklı eğitim iterasyonlarında farklı nöronların etkin olmasını sağlayarak yapay sinir ağının yapısını değiştirir. Böylece her bir sinir hücresinin farklı özellikleri temsil etmesini sağlayarak ağı daha etkili bir biçimde çalışmasını sağlamaktadır. Eğitim seti ile yapay sinir ağı arasındaki adaptasyonu sınırlayarak ağırlıkların bu verilere aşırı uyum sağlamasını engellemektedir. Silme işlemi katmanlarda 0 ve 1 arasında seçilen olasılık değerine göre gerçekleştirilir (Luo ve ark. 2017). Şekil 2.16'da seyreltme uygulanmamış ve uygulanmış standart bir yapay sinir ağı gösterimi sunulmuştur.



**Şekil 2.16.** Standart yapay sinir ağı (a), seyreltme uygulanan yapay sinir ağı (b)  
(Khalifa ve Frigui 2016)

## 2.5. Boyut İndirgeme

Boyut indirgeme en genel tanımıyla; veriyi çok boyutlu bir uzaydan, alt boyutlu bir uzaya dönüştürme işlemidir. Boyut indirgeme işlemleri sayesinde karmaşık verilerin temsili kolaylaşıp, hesaplama ve işlem maliyeti azaltılmaktadır. Bunun yanında fazlalık ve gürültü verilerin atılmasını sağlayarak veri setinin daha gürbüz özniteliklerden oluşmasını sağlamaktadır. Hiperspektral görüntülerin sınıflandırılması aşamasında da boyut indirgeme yöntemleri gerekli bir ön adımdır.

Geleneksel sınıflandırma yöntemleri, hiperspektral görüntülerdeki her bir pikselin spektral bantlardaki yansıtma değerlerine göre piksel bazında sınıflandırılması yaklaşımını temel almaktadır. Bu uygulamalar genellikle, her pikselin sınıfının çok sayıda eğitici örnek ile tanımlanmasını gerektirmektedir. Bununla birlikte, bu tür spektral / uzaysal çözünürlük açısından zengin görüntüler ile uğraşırken yüksek yorumlama başarısı elde etmek zordur. Spesifik olarak, yüksek çözünürlüklü görüntülerle sağlanan zengin bilgiler, sınıf içi değişimleri artırabilir ve hem spektral hem de uzaysal alanlarda sınıflar arası değişimleri azaltabilir ve daha düşük yorumlama doğruluğuna yol açabilmektedir. Aynı zamanda boyutsallık laneti olarak da bilinen Hughes olgusu, özelliklerin sayısı ve mevcut eğitim örnekleri dengesiz olduğunda ortaya çıkmaktadır ve geleneksel sınıflandırıcıların tamamen başarısız olmasına neden olmaktadır (Lee ve Landgrebe 1993).

Bu duruma çözüm olarak daha çok sayıda eğitim verisi temin edilmelidir. Bir diğer çözüm ise hiperspektral görüntülerden en ilgili öznitelikleri çıkararak, verinin boyutunu azaltmaktır. İlk çözümde, hiperspektral görüntülerin boyut sayısı arttıkça çok değişkenli istatistiklerin tahminlerini yapabilmek için eğitim verilerinin büyüklüğünün katlanarak artması gerekmektedir. Bu nedenle ikinci çözüme uygun olarak sınıfların ayrımsallığını sağlayan orijinal bilgiyi kaybetmeden boyut azaltma yöntemleri uygulanmaktadır.

Boyut indirgeme yöntemleri, verileri yüksek boyutlu bir uzaydan daha küçük bir uzaya taşıyan, böylece boyutsallık lanetini azaltan bir ön işlem adımdır. Sınıflandırma ile ilgili

olarak, hiperspektral bir görüntünün, ilgili nesne bilgisini kaybetmeden anlamlı bir alana dönüştürülmesi son zamanlarda önemli bir araştırma konusu haline gelmiştir. Tüm spektral bantları kullanmak yerine, boyutsallık azaltma teknikleri veri işleme ve sınıfa özgü alt alanı bulmak için etkili yöntemlerdir. İdeal olarak azaltılmış görüntü, verimli görüntü modellemesi için minimum değişken sayısına karşılık gelmelidir. İşlenecek olan veriler herhangi bir veri kaybı olmadan daha az öznelikle ifade edildiğinde, verilerin görselleştirmesi ve yorumlanması daha kolay olmaktadır. Aynı zamanda fazlalık ve sınıflandırma başarısını düşüren özneliklerin atılmasıyla sınıflandırma başarımları artabilmektedir. Aynı zamanda boyut azaltma teknikleri uygulandığında hiperspektral verilerin analizi sırasındaki işlem zamanı ve hesaplama yükü azalmaktadır. Ayrıca boyut indirgeme yöntemleri ile depolama ve bellek alanı kullanımından da tasarruf edilmektedir.

Boyut indirgeme işlemi, FE ve öznelik seçimi (feature selection) olmak üzere iki yöntemle yapılmaktadır. Bu tez çalışmasında öznelik çıkarımı yöntemi kullanılarak boyut indirgeme yapılmıştır.

### 2.5.1. Öznelik çıkarma

FE veri seti üzerinde belirli fonksiyonlar kullanılıp dönüşüm yapılarak, analizlerde kullanılacak daha etkin ve yararlı özneliklerin elde edilmesini amaçlar. Özellik çıkarma işlemi,  $d$  boyutlu giriş alanından  $m$  boyutlu çıkış alanına (harita alanı) eşleme işlemi yapan  $\psi$  fonksiyonu şeklinde formüle edilebilir (Denklem 2.32). Bu çıkarım bazı optimize edilmesi gereken dönüşüm kriterlerine bağlıdır.

$$\psi : R^d \rightarrow R^m, m \leq d \quad (2.32)$$

Öznelik çıkarımı için literatürde çok sayıda yaklaşım mevcuttur. Bu yaklaşımlar,  $\psi$  eşleştirme fonksiyonunun öğrenme şekline ve optimizasyon kriterlerine göre değişmektedir. Haritalama işlevleri doğrusal veya doğrusal olmayan, aynı zamanda denetimli ve denetimsiz yöntemlerle yapılabilir. Bu iki faktörün birleşimi dört şekilde öznelik çıkarımı yöntemi ile sonuçlanır. Bu yöntemler *i*) denetlenmeyen doğrusal, *ii*) denetlenen doğrusal, *iii*) denetlenmeyen doğrusal olmayan ve *iv*) denetlenmeyen doğrusal

olmayan yaklaşımlardır. Genel olarak doğrusal yöntemler daha az hesaplama işlemi gerektirdiğinden analitik çözümlerde doğrusal yöntemler tercih edilmektedir. Öte yandan, doğrusal olmayan yöntemler doğrusal yöntemlerden daha güçlüdür. Bununla birlikte, analitik bir çözüm çoğu zaman mevcut olmadığından ve hesaplama işlemi gerektiren problemlerde sayısal bir optimizasyon yöntemi kullanılmalıdır. Fakat kullanılan optimizasyon yöntemleri yerel minimum noktalarına takılabilmektedir. Ayrıca, denetlenen yöntemlerin kategori bilgisinin mevcut olduğu durumlarda denetlenmeyen yöntemlerden daha iyi performans gösterdiği de doğrudur. Tüm bu sebeplerden ötürü belirli bir problem için uygun bir öznitelik çıkarım yöntemi belirlemek oldukça zordur. Uygulanacak yöntemin belirlenmesi için veri seti hakkında ön bilgi (doğrusal veya doğrusal olmayan) ve yapılacak işlemin amacı (sınıflandırma veya görselleştirme) hakkında bilgiler gerekmektedir. En etkili yöntemi seçmek için yöntemler ve veri seti hakkında bilgiye sahip olmak oldukça önemlidir (Jimenez-Rodriguez ve ark. 2007).

### **3. MATERYAL VE YÖNTEM**

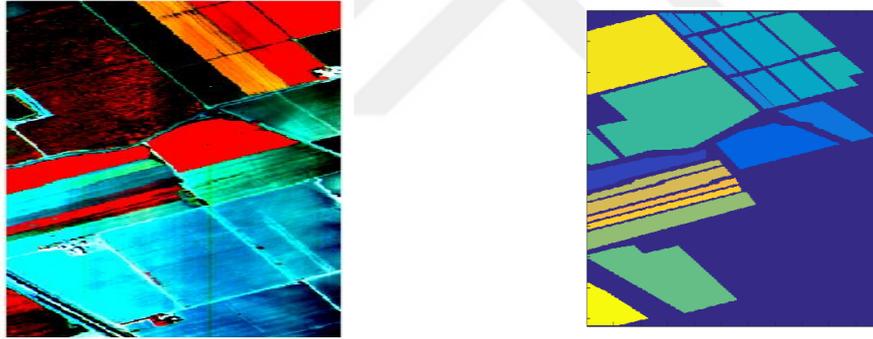
#### **3.1. Materyal**

Bu bölümde tez çalışmasında kullanılan hiperspektral veri setlerinden ve deney kurulumundan bahsedilmiştir. Ayrıca sınıflandırma işlemlerinde kullanılan performans ölçütleri açıklanmıştır.

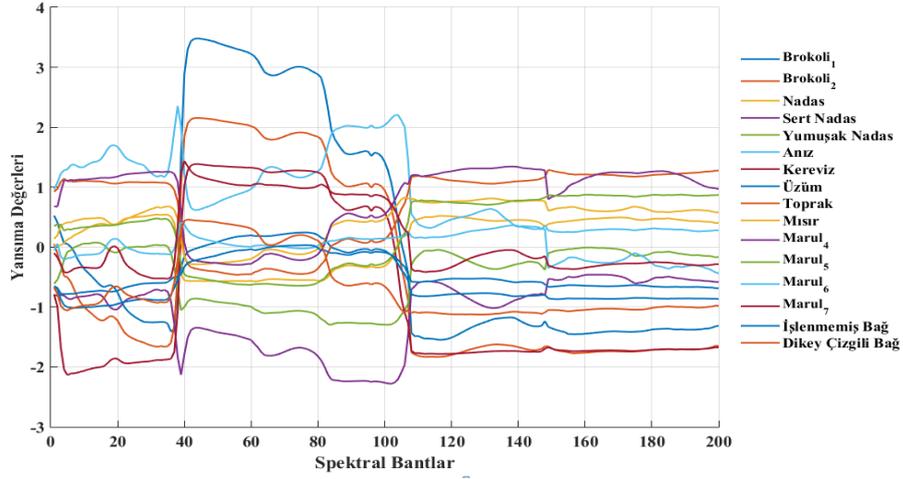
### 3.1.1. Veri setleri

Tez çalışmasında yaygın olarak tercih edilen ve kullanımı ücretsiz olan Salinas ve Pavia University hiperspektral veri setleri kullanılmıştır.

Salinas veri seti, AVIRIS sensörü ile Salinas Valley, California'da ve yüksek uzaysal çözünürlükle (3,7 m/piksel) karakterize edilmiştir. Veri seti 224 banttan oluşmaktadır. Kapsadığı alan ise 512 x 217 adet örnek içermektedir. Veri setinden su absorpsiyonuna uğrayan 20 bant atılmıştır. [108-112] ve [154-167] bantlarının atılmasından sonra veri setinde 204 bant kalmaktadır. Sebzeleri, çıplak toprakları ve bağ alanlarını içeren bu veri setinde 16 adet sınıf bulunmaktadır (Ghamisi ve ark. 2014). Veri setine ait RGB görüntüsü ve zemin gerçekliği Şekil 3.1'de, veri setindeki sınıflara ait ortalama yansımaya değerleri ise Şekil 3.2'de gösterilmiştir. Yansımaya değerlerinden görüldüğü üzere 40-100 bantları arasında sınıflar arası ayrımsallık yüksektir.



Şekil 3.1. Salinas veri seti örnek RGB bant görüntüsü ve doğruluk verisi



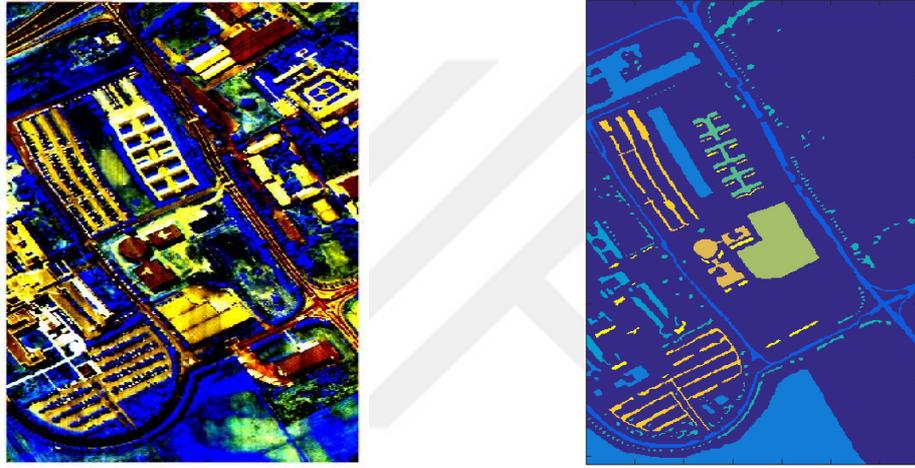
**Şekil 3.2.** Salinas veri seti sınıfları ortalama yansıma değerleri

Salinas veri setinde her bir sınıfa ait örnek sayıları Çizelge 3.1’te gösterilmiştir.

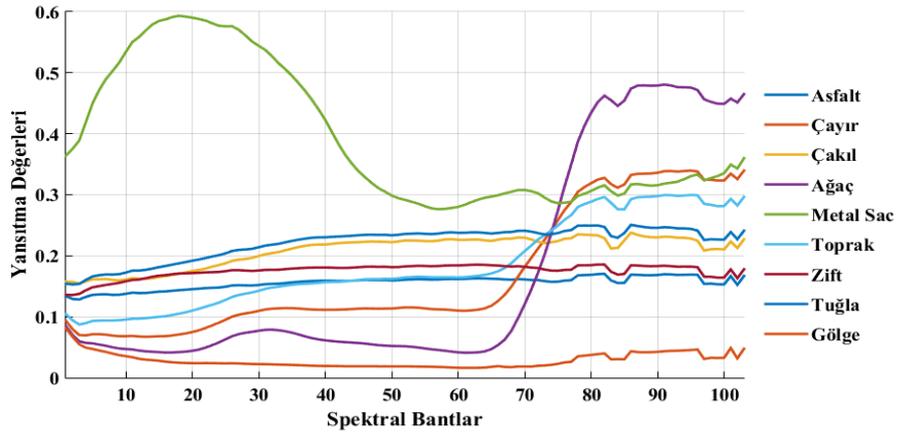
**Çizelge 3.1.** Salinas veri seti sınıflarına ait örnek sayıları

#	Sınıf	Örnek Sayısı
1	Brokoli_1	2009
2	Brokoli_2	3726
3	Nadas	1976
4	Sert Nadas	1394
5	Yumuşak Nadas	2678
6	Anız	3959
7	Kereviz	3579
8	Üzüm	11271
9	Toprak	6203
10	Mısır	3278
11	Marul_4	1068
12	Marul_5	1927
13	Marul_6	916
14	Marul_7	1070
15	İşlenmemiş Bağ	7268
16	Dikey Çizgili Bağ	1807

ROSIS sensörü tarafından İtalya'nın kuzeyindeki Pavia bölgesinden alınan görüntülerle oluşturulan Pavia University veri setinin spektral bant sayısı 103'tür.  $610 \times 610$  boyutundaki veri setinde, bilgi içermeyen pikseller atılarak  $610 \times 340$  boyutlarında görüntü elde edilmiştir. Veri setinde geometrik çözünürlük 1,3 m'dir (Huang ve Zhang 2009). Pavia University veri setine ait bir RGB görüntüsü ve zemin gerçekliği de Şekil 3.3'de sunulmuştur. Ayrıca, veri setindeki her bir sınıfa ait ortalama yansımaya değerleri de Şekil 3.4'de gösterilmiştir. Yansımaya değerlerinden görüldüğü üzere sınıflar arası ayrımsallık 10-65 ve 80-100 bantları arasında yüksektir.



Şekil 3.3. Pavia University veri seti örnek RGB bant görüntüsü ve doğruluk verisi



Şekil 3.4. Pavia University veri seti sınıfları ortalama yansımaya değerleri

Veri seti 9 adet sınıftan oluşmaktadır ve her sınıf için örnek sayıları Çizelge 3.2’de gösterilmiştir.

**Çizelge 3.2.** Pavia University veri seti sınıflarına ait örnek sayıları

#	Sınıf	Örnek Sayısı
1	Asfalt	6631
2	Çayır	18 649
3	Çakıl	2099
4	Ağaç	3064
5	Metal Sac	1345
6	Toprak	5029
7	Zift	1330
8	Tuğla	3682
9	Gölge	947

### 3.1.2. Deney kurulumu

Sınıflandırma ve YSA eğitim ve test işlemleri, Python programlama dilinin 3.6.2 sürümü kullanılmıştır. Önerilen yapay sinir ağı modelleri; Tensorflow ya da Theano kütüphaneleri üzerinde çalışan Python ile yazılmış yüksek seviye bir API olan Keras 2.1.6 sürümünde programlanmıştır. Ham verilerin okunması, hazırlanması ve ön işlemlerde MATLAB R2015a kullanılmıştır. Deneylerin yürütüldüğü bilgisayar ortamında; Intel Core i7 7700HQ işlemci (2.8 GHz Turbo ile 3.8 GHz işlemci hızı), 16 GB DDR4 sistem ve belleği NVIDIA GeForce GTX 1050 grafik işlemcisi bulunmaktadır.

### 3.1.3. Performans ölçütleri

Eğitilen modellerde test aşamasında doğruluk değerinin yanında karmaşıklık matrisi kullanılarak kesinlik (precision), anma değeri (recall) ve F1 skor değerleri de hesaplanmıştır. Çizelge 3.3’te iki sınıfa ait karmaşıklık matrisi yer almaktadır.

**Çizelge 3.3.** Karmaşıklık matrisi

		Tahmin Değerleri	
		Pozitif	Negatif
Gerçek Değerler	Pozitif	DP (Doğru Pozitif)	(YN) Yanlış Negatif
	Negatif	YP (Yanlış Pozitif)	DN (Doğru Negatif)

Karmaşıklık matrisine göre DP ve DN değerleri doğru olarak sınıflandırılan verileri temsil etmektedir. Sınıflandırmada asıl amaç bu değerlerin en yüksek değerde olmasıdır. DP değeri, Pozitif sınıfta yer alan bir örneğin yine Pozitif sınıfta tahmin edilmesi, YP değeri Pozitif sınıfa ait bir örneğin Negatif sınıfta tahmin edilmesi, YN değeri Negatif sınıfa ait bir örneğin Pozitif sınıfa ait olarak tahmin edilmesini ve DN değeri ise Negatif sınıfa ait bir örneğin yine Negatif sınıfta tahmin edilme durumunu temsil etmektedir. Karmaşıklık matrisi üzerinden hesaplanan doğruluk değeri, en sezgisel performans ölçütüdür ve doğru olarak tahmin edilen örneklerin toplam örneklere olan oranıdır. 0, 1 veya 0 ve 1 arasında değer elde edilmesini sağlamaktadır.

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.1)$$

Kesinlik değeri, doğru tahmin edilen pozitif örneklerin, toplam pozitif örnek sayısına oranıdır. Pozitif olarak tahmin edilen örneklerin ne kadar başarılı tahmin edildiğini göstermektedir (Denklem 3.2).

$$Kesinlik = \frac{DP}{DP + YP} \quad (3.2)$$

Anma değeri, pozitif sınıftan olan örneklerin ne kadar başarılı tahmin edildiğini gösteren durumdur (Denklem 3.3).

$$Anma = \frac{DP}{DP + YN} \quad (3.3)$$

F1 skoru ise kesinlik ve anma değerlerinin harmonik ortalamasıdır (Denklem 3.4). Bu nedenle, bu ölçüt hem yanlış pozitifleri hem de yanlış negatifleri hesaba katmaktadır. Özellikle düzensiz sınıf dağılımlarında genellikle doğruluktan daha kullanışlıdır. Sınıflandırıcının ne kadar iyi performans gösterdiğinin bir ölçüsüdür ve sınıflandırıcıları karşılaştırmakta sıklıkla kullanılır.

$$F1 Skoru = \frac{2 * Kesinlik * Anma}{Kesinlik + Anma} \quad (3.4)$$

## 3.2. Yöntem

Bu bölümde tez çalışmasındaki iki sınıflandırma yaklaşımı teorik olarak açıklanmıştır. İlk yöntem olan evrişimsel sinir ağları ile sınıflandırmadaki algoritmik yaklaşım sunulmuştur. Geliştirilen sinir ağlarına veri setlerinin giriş verisi olarak düzenlenmesi, filtre boyutlarına göre evrişim işlemleri, eğitilebilir parametre sayıları hesabı ve ağların ürettikleri veri boyutu hakkında örnek ağlar üzerinden hesaplamalar verilmiştir. İkinci yöntem olan boyut indirgeme ile sınıflandırma algoritmasında ise tezde kullanılan K-katlamalı çapraz geçiş yaklaşımı açıklanmıştır.

### 3.2.1. Evrişimsel sinir ağı ile sınıflandırma

Uzaktan algılama görüntülerinin içeriği göz önüne alındığında, büyük miktarda veriyi verimli bir şekilde yüksek doğrulukla işlemek ve aynı zamanda hesaplama maliyeti arasındaki dengeyi koruyan mimariyi bulmak oldukça önemlidir. Yapılan çalışmalar düşük maliyetli veri işlemeyi hedeflese de farklı zorluklar ortaya çıkmaktadır. Fakat asıl zorluk, derin mimariyi sadece hiperspektral görüntünün uzaysal boyutunu değil aynı zamanda zengin spektral içeriğini de dikkate alacak şekilde tasarlamaktır. ESA mimarilerinin içerdiği katman çeşitliliği sayesinde, bu ağlar verimli bir sınıflandırma ve işleme için etkin araçlar sunarlar.

**Çizelge 3.4.** Hiperspektral görüntülerinin piksel seviyesinde sınıflandırma algoritması

**Algoritma 1:**  $n_1$  adet spektral bant içeren bir veri setinde her bir piksel belirlenen bir sayıda ( $n$ ) komşuluğu alınarak  $n \times n \times n_1$  boyutundaki voksel ile ifade edilir. Bir boyutlu evrişim işleminde ise her bir piksel  $1 \times n_1$  boyutundaki piksel vektörü ile ifade edilir.

**Girdi: S:** Her bir paketteki örnek sayısı olmak üzere;

*epok:* Sinir ağını eğitmek için kullanılacak maksimum adım sayısı

$X_{egitim}$  : Girdi olarak verilen eğitim vokselleri

$X_{test}$  : Girdi olarak verilen test vokselleri

$X_{dogrulama}$  : Doğrulama için kullanılacak vokseller

**Çıktı: mAccuracy:** *test* veri setinin ortalama başarımı

**Eğitim :**  $X_{train}$  setindeki her bir vokselin başarımı

**for** *it in range epok do*

- 1)  $X_{egitim}$  veri setinden rastgele şekilde seçilen  $S$  adet voksel mevcut epokta daha önce değerlendirilmemiştir.
- 2)  $X_{dogrulama}$  veri setinden rastgele şekilde seçilen  $S$  adet voksel mevcut epokta daha önce değerlendirilmemiştir.
- 3)  $S$  adet voksel ile ileri besleme gerçekleştirilerek ortalama doğrulama ve eğitim kayıp hesabı
- 4) Ortalama kayıp değerine göre geri besleme ile ağırlıklarının güncellenmesi

**end**

**Test :**  $X_{test}$  veri setindeki her bir vokselin başarımı

**for** *it in range epok do*

- 1)  $X_{test}$  veri setinden seçilen  $S$  adet voksel daha önce mevcut epokta kullanılmamıştır
- 2) Paketteki örneklere ileri besleme uygula
- 3) Geri dön ve elde edilen doğruluk değerlerini topla

**end**

*mAccuracy* değerini hesapla

Yapılan tez çalışmasının evrişimsel sinir ağı ile sınıflandırma aşamasında, bir, iki veya üç boyutlu filtre kullanımına göre farklı avantajlar sağlayan evrişimsel sinir ağı modelleri kullanılmıştır. Spektral, uzaysal ya da her iki uzaydaki bilgilerin işlenmesini sağlayan bu sinir ağlarının sınıflandırma performansları karşılaştırılmıştır.

Çizelge 3.4’de bir, iki ve üç boyutlu evrişimsel sinir ağları ile sınıflandırma işlemi genel hatlarıyla özetlenmiştir.  $n_1$  adet spektral bant içeren hiperspektral bir veri seti için sınıflandırma işlemi hiperspektral görüntülerdeki piksellerin yapay sinir ağına girdi olacak şekilde düzenlenmesi ile başlamaktadır. Bir boyutlu evrişimli sinir ağında, her bir pikselin spektral bilgileri alınarak  $1 \times n_1$  boyutunda ifade edilmesi sağlanmıştır. İki ve üç boyutlu evrişimli ağlarda ise piksellerin komşulukları alınarak üç boyutlu vokseller (bir pikselin üç boyutlu karşılığı) şeklinde temsili sağlanmıştır.

Çizelge 3.5 ve Çizelge 3.6’da Pavia University ve Salinas veri setlerinde her bir sınıfta kullanılan eğitim, test ve doğrulama verilerinin sayıları gösterilmiştir.

**Çizelge 3.5** Pavia University veri seti eğitim, doğrulama ve test örneği sayıları

#Sınıf	Eğitim	Doğrulama	Test
1	3713	929	1989
2	10444	2611	5594
3	1176	294	629
4	1716	429	919
5	754	188	403
6	2817	704	1508
7	745	186	399
8	2062	516	1104
9	530	133	284

Örnekler sinir ağlarına uygun girdi şekline getirildikten sonra her bir sınıftaki toplam piksellerin %70’i eğitim, %30’u test pikseli olarak ayrılmıştır. Eğitim verilerinin %20’si de doğrulama verisi olarak ayrılarak modelin eğitim süreci her bir epokta izlenmiştir.

Test aşamasında belirlenen paket boyutunda test verilerinden alınan bilgiler üzerinde eğitilen sinir ağı test edilmektedir. Bu iki süreç epok değeri kadar tekrar edilerek final sonucu elde edilmektedir.

**Çizelge 3.6** Salinas veri seti eğitim, doğrulama ve test örneği sayıları

#Sınıf	Eğitim	Doğrulama	Test
1	1126	281	602
2	2087	522	1117
3	1107	277	592
4	781	195	418
5	1500	375	803
6	2218	554	1187
7	2005	501	1073
8	6312	1578	3381
9	3474	869	1860
10	1836	459	983
11	598	150	320
12	1079	270	578
13	514	128	274
14	599	150	321
15	4070	1018	2180
16	1012	253	542

### 3.2.1.1. Bir boyutlu evrişimsel sinir ağı (1B-ESA)

Spektral özniteliklerin çıkarımını sağlayan 1B-ESA ile  $i$  katmanındaki öznitelik  $j$  haritasında  $x$  pozisyonundaki  $v_{ij}^x$  nöronunun değeri denklem (3.5) ile hesaplanmaktadır.

$$v_{ij}^x = g \left( b_{ij} + \sum_m \sum_{p=0}^{P_i-1} w_{ijm}^p v_{(i-1)m}^{x+p} \right) \quad (3.5)$$

Denklem (3.5)'de  $m$  değeri bir önceki katman olan katman  $(i-1)$ 'den geçerli katmana bağlanan öznitelik haritasını temsil etmektedir.  $w_{ijm}^p$  ise  $p$  pozisyonundaki öznitelik haritası  $m$ 'ye bağlı ağırlık değerini ifade etmektedir.  $P_i$  değeri, kernelin spektral boyuttaki genişliğini belirtirken,  $b_{ij}$  ise  $i$  katmanındaki öznitelik haritası  $j$ 'nin bias değeridir.

Geleneksel evrişim sinir ağları giriş verisi olarak iki boyutlu görüntü kullanılmaktadır. Kullanılan evrişimli çekirdek ve havuzlama işlemi de iki boyutlu olarak yapılmaktadır. Tek boyutlu evrişimsel sinir ağlarında ise girdi olarak tek boyutlu bir vektör oluşturulur. Her piksel için birden fazla hiperspektral bant bilgisi ile ilgilenilir. Bu ağlarda evrişim filtreleri örnek olarak  $3 \times 1$ ,  $5 \times 1$ 'lik tek boyutlu yapılarıdır. Sistem girdisi ise her piksel için hiperspektral bantlardaki değerlerini içeren tek boyutlu bir piksel vektörüdür.  $(n \times 1)$  boyutunda  $k$  adet evrişim filtresi veriye uygulandıktan sonra,  $k$  adet öznitelik haritası elde edilmektedir. Her öznitelik haritası, bu özellikleri uygulama gereksinimlerine daha uygun hale getirmek için geri yayılma aşamasında güncellenebilen farklı bant bilgilerine sahiptir.

Geliştirilen 1B-ESA, iki adet evrişim katmanı ve bir tanesi çıkış katmanı olmak üzere iki adet tam bağlı katman içermektedir. Girdi boyutları 103 adet spektral banda sahip Pavia University veri seti için  $1 \times 103$ , 204 adet spektral banda sahip Salinas veri seti için  $1 \times 204$  vektörü şeklindedir.

Çizelge 3.7'de katmanlara ait filtre boyutları ve öznitelik haritaları gösterilmiştir. Hiperspektral veri setlerinin 1B-ESA sınıflandırması için geliştirilen mimaride; iki adet evrişim katmanı, iki adet havuzlama katmanı ve biri çıkış katmanı olmak üzere iki adet tam bağlı katman bulunmaktadır. Her bir evrişim katmanı ReLU aktivasyon fonksiyonu içermektedir. Birinci evrişim katmanı (C1)'de  $1 \times 3$  boyutunda 64 adet filtre bulunmaktadır. C1 katmanının ardından  $1 \times 2$  boyutunda filtre içeren maksimum havuzlama katmanı (H1) uygulanmıştır. İkinci evrişim katmanı C2,  $1 \times 3$  boyutunda 128 adet filtre içermektedir. Bu katmandan sonra  $1 \times 2$  boyutunda filtrelerle maksimum havuzlama (H2) işlemi gerçekleştirilmiştir. Evrişim ve havuzlama işleminden sonra tek boyutlu bir vektöre düzleştirilen veriler, 150 adet nöron içeren tam bağlı katmana (F1) iletilmiştir. Bu katmanda aşırı uyumu önlemek için 0,5 oranında seyreltme işlemi

uygulanmıştır. Seyreltilen veri çıkış katmanına (F2) gönderilmiştir. Bu katman ağıın çıkışlarını softmax fonksiyonu ile hesaplamaktadır.

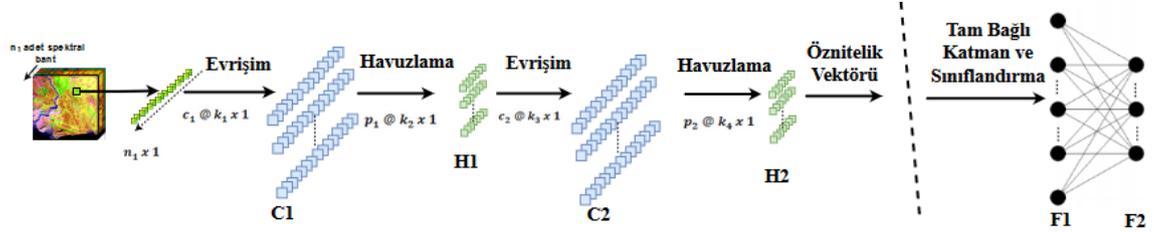
Sinir ağında işlenen paket boyutu 100, filtre adım sayısı (S), 2 olarak belirlenmiştir. Ağırlıkların ilk değerlerini atamak için Xavier başlatıcı kullanılmıştır. Maliyet fonksiyonu olarak çapraz entropi fonksiyonu (Denklem 2.16) kullanılmıştır. Ağ, Adam optimize edici tarafından çapraz entropi kaybı fonksiyonunu en aza indirerek eğitilmiştir.

**Çizelge 3.7.** 1B-ESA yapısı

Veri Seti	Pencere Boyutu	C1 Aktivasyon	H1	C2 Aktivasyon	H2	F1 Aktivasyon	F2 Aktivasyon
Pavia University	1x103	1x3 ReLU	1x2	1x3 ReLU	1x2	Tam Bağlı ReLU	1x9 Softmax
Salinas	1x204	1x3 ReLU	1x2	1x3 ReLU	1x2	Tam Bağlı ReLU	1x16 Softmax
Öznitelik Haritası		64		128		150	

Şekil 3.5'te 1B-ESA mimarisinin katmanlarının bir görseli sunulmuştur.  $n_1$  adet hiperspektral banda sahip bir veri seti için giriş bilgisinin boyutu ( $n_1 \times 1$ )' dir. Birinci evrişimsel katman olan C1'de  $c_1$  adet  $k_1 \times 1$  boyutunda filtre bulunduğu oluşun çıktı verisinin boyutu  $n_2 = (n_1 - k_1) / S + 1$  olmaktadır. Ayrıca giriş katmanı ve evrişim katmanı arasında  $c_1 \times (k_1 + 1)$  adet eğitilebilir parametre oluşmaktadır. Havuzlama katmanı olan H<sub>1</sub> katmanında ise ( $k_2 \times 1$ ) boyutunda filtre olduğunu varsayıldığında  $n_3 = ((n_2 - k_2) / S) + 1$  olmak üzere; bu katmanda ( $n_3, c_1$ ) boyutunda çıktı oluşacaktır. Havuzlama katmanında eğitilebilir parametre oluşmamaktadır.  $k_3 \times 1$  boyutunda  $c_2$  adet filtre içeren C2 evrişim katmanında ise  $n_4 = (n_3 - k_3) / S + 1$  olmak üzere  $c_2 \times (k_3 \times 1)$  adet eğitilebilir parametre oluşmaktadır. Havuzlama katmanı H2'de ise ( $k_4 \times 1$ ) boyutunda filtre olması durumunda  $n_5 = (n_4 - k_4) / S + 1$  olmak üzere ( $n_5, c_2$ ) boyutunda çıktı elde edilmektedir.  $n_6$  adet nöron içeren tam bağlı katman F1

ve havuzlama katmanı (H2) arasında ise  $((c_2 \times n_5)/S + 1) \times n_6$  adet eğitilebilir parametre hesaplanmaktadır.  $n_7$  adet nöron içeren çıktı katmanı (F2) ve F1 katmanı arasında  $(n_6 + 1) \times n_7$  adet eğitilebilir parametre oluşmaktadır.



Şekil 3.5. Bir boyutlu evrişimsel sinir ağı (1B-ESA)

Detaylı analiz için öğrenme adımının sınıflandırma başarımına etkisi de incelenmiştir. Bu amaçla öğrenme adımı değiştirilerek 1B-ESA mimarisi ile sınıflandırma yapılmıştır ve sonuçlar analiz edilmiştir.

Ayrıca katman ve sinir ağı derinliğinin sınıflandırmaya etkisini gözlemlemek için 1B-ESA'ya 1x5 boyutunda 256 adet filtre içeren C3 evrişim katmanı, 1x2 boyutunda filtrelerle maksimum havuzlama yapan H3 havuzlama katmanı ve 300 adet nöron içeren tam bağlı katman eklenmiştir. Genişletilmiş 1B-ESA mimarisinin katmanlarındaki filtre ve öznetelik haritası sayıları Çizelge 3.8'de gösterilmiştir.

Çizelge 3.8. Genişletilmiş 1B-ESA yapısı

Veri Seti	Pencere Boyutu	C1 Aktivasyon	H1	C2 Aktivasyon	H2	C3 Aktivasyon	H3	F1 Aktivasyon	F2 Aktivasyon	F3 Aktivasyon
Pavia University	1x103	1x3 ReLU	1x2	1x3 ReLU	1x2	1x3 ReLU	1x2	Tam Bağlı ReLU	Tam Bağlı ReLU	1x9 Softmax
Salinas	1x204	1x3 ReLU	1x2	1x3 ReLU	1x2	1x3 ReLU	1x2	Tam Bağlı ReLU	Tam Bağlı ReLU	1x16 Softmax
Öznetelik Haritası		64		128		256		150	300	

### 3.2.1.2. İki boyutlu evrişimsel sinir ağı (2B-ESA)

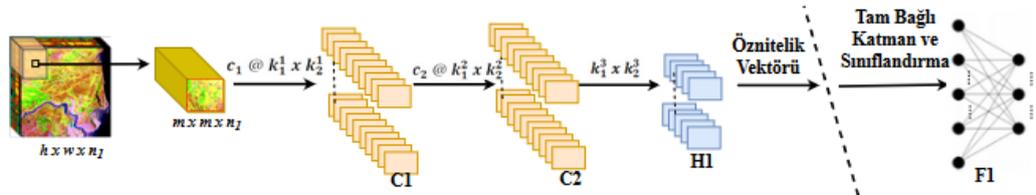
Matematiksel ifadeyle 2B-ESA'da görüntünün her bir pikseli için, komşu pikseller ile filtre matrisinin karşılık gelen elemanları arasında bir hesaplama işlemi yapılarak bu pikselin öznitelik değeri atanmaktadır.  $i$  katmanındaki öznitelik haritası  $j$ 'de,  $(x,y)$  pozisyonundaki nöronun değeri ise denklem (3.6) ile hesaplanmaktadır.

$$v_{ij}^{xy} = g \left( b_{ij} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} w_{ijm}^{pq} v_{(i-1)m}^{(x+p)(y+q)} \right) \quad (3.6)$$

Yukarıdaki denklemde  $i$  geçerli katmanı,  $j$  öznitelik haritasının sayısını temsil etmek üzere,  $v_{ij}^{xy}$  katman  $i$  ve öznitelik haritası  $j$ 'deki  $(x,y)$  pozisyonundaki çıkış değerini belirtmektedir.  $g(\cdot)$  aktivasyon fonksiyonudur.  $m$  değeri ise bir önceki katman olan katman  $(i-1)$ 'den geçerli katmana bağlanan öznitelik haritasının indeksini ve sonuç olarak  $w_{ijm}^{pq}$  değeri ise öznitelik haritası  $j$ 'ye bağlı olan  $(p,q)$  pozisyonundaki filtreyi temsil etmektedir.  $P_i$  ve  $Q_i$  değerleri ise uzaysal evrişim filtresinin yükseklik ve genişliğini belirtmektedir.

Şekil 3.6'da tez çalışmasında geliştirilen 2B-ESA mimarisi gösterilmiştir. Bir hiperspektral görüntü,  $h$  yükseklik,  $w$  genişlik ve  $n_1$  spektral bant sayısını temsil etmek üzere,  $h \times w \times n_1$  boyutlarından oluşan üç boyutlu voksel adı verilen bir yapı ile ifade edilmektedir. Evrişimli sinir ağlarına uyumlu hale getirmek için hiperspektral görüntü, her biri belirli bir piksel spektral ve uzaysal bilgiler içeren yamalar halinde ifade edilecek şekilde düzenlenir.  $(x,y)$  konumundaki bir piksel  $(p_{x,y})$ , merkezde olmak üzere ilişkili olduğu komşuluk bilgileri alınarak belirli bir pencere boyutuna göre komşuluk penceresiyle temsil edilmektedir. Bu sayede uzaysal olarak bitişik piksellerin çoğu zaman aynı etiketlere sahip olması nedeniyle, önerilen modelin "uzaysal tutarlılığı" dikkate alması amaçlanır.  $l_{x,y}$ ,  $(x,y)$  konumundaki pikselin etiket bilgisi olmak üzere  $w_{x,y}$  ifadesinin,  $p_{x,y}$  pikselinin komşuluk penceresini ifade ettiğini düşünüldüğünde veri seti  $x = 1, 2, \dots, w$  ve  $y = 1, 2, \dots, h$  için  $D = \{(w_{x,y}, l_{x,y})\}$  formunda ifade edilmektedir.

Süreç komşuluklar şeklinde düzenlenen piksellerin eğitim ve test seti olarak ayrılması ile başlamaktadır. Daha sonra  $c_1$  adet  $k_1^1 \times k_2^1$  boyutundaki filtreden ilk evrişim katmanı C1'e,  $m \times m \times n_1$  boyutundaki veriler girdi olarak verilmektedir. Bu durumda  $k_1^1 \times k_2^1$  boyutlarında  $c_1$  adet filtre içeren C1 katmanında  $((m + k_1^1 - 1)/S, (m + k_2^1 - 1)/S)$  boyutlarında  $c_1$  adet çıktı oluşmaktadır. Bu katmandaki hesaplanabilir parametre sayısı ise  $((k_1^1 * k_2^1) + S) * c_1$  olmaktadır.  $k_1^2 \times k_2^2$  boyutlarında  $c_2$  adet filtre içeren C2 katmanında ise;  $n_2 = (m + k_1^1 - 1)/S$  ve  $n_3 = (m + k_2^1 - 1)/S$  olmak üzere  $((n_2 + k_1^2 - 1)/S, (n_3 + k_2^2 - 1)/S)$  boyutunda  $c_2$  adet çıktı oluşmaktadır. C2 katmanında  $((k_1^2 * k_2^2) + S) * c_2$  adet eğitilebilir katman oluşmaktadır.  $k_1^3 \times k_2^3$  boyutlarında filtre içeren havuzlama katmanı H1'de;  $n_4 = (n_2 + k_1^2 - 1)/S$  ve  $n_5 = (n_3 + k_2^2 - 1)/S * c_2$  olmak üzere  $(n_4 + k_1^3 - 1)/S, (n_5 + k_2^3 - 1)/S$  boyutlarında  $c_2$  adet çıktı oluşmaktadır. H1 katmanında oluşan eğitilebilir parametre oluşmamaktadır.  $f_1$  adet nöron içeren tam bağlı katman F1'de eğitilebilir parametre sayısı  $((n_4 - k_1^3 + 1)/S * (n_5 - k_2^3 + 1)/S * c_2) * f_1 + 1$  adet parametre oluşmaktadır. Tam bağlı katmanın (F1) ardından çıkış katmanında (F2) Softmax fonksiyonu ile piksellerin sınıflara ait olma olasılıkları hesaplanmaktadır (Chen ve ark. 2016, Li ve ark. 2017). F2 katmanında ise veri setlerine ait sınıf sayıları O olmak üzere; hesaplanan parametre sayısı  $O * f_1$  olarak hesaplanmaktadır.



Şekil 3.6. İki boyutlu evrişimsel sinir ağı (2B-ESA)

Veri setlerinde her bir piksel 7 adet komşuluğuyla temsil edilmiştir. Bu durumda her bir pikselin boyutu 7x7 şeklinde komşuluk penceresiyle temsil edilmektedir.

Çizelge 3.9 ise tez çalışması kapsamında geliştirilen 2B-ESA'ya ait katman ve filtre bilgilerini içermektedir. Görüldüğü üzere hiperspektral veri setlerinin 2B-ESA sınıflandırması için geliştirilen mimaride; iki adet evrişim katmanı, bir adet havuzlama katmanı ve biri çıkış katmanı olmak üzere iki adet tam bağlı katman bulunmaktadır. Her

bir evrişim katmanı ReLU aktivasyon fonksiyonu içermektedir. Birinci evrişim katmanı (C1), 3x3 boyutunda 50 adet filtre içermektedir. C1 katmanından sonra 3x3 boyutunda 100 adet filtre içeren C2 evrişim katmanı gelmektedir. Evrişim katmanlarından sonra 2x2 boyutunda filtre içeren maksimum havuzlama katmanı (H1) uygulanmıştır. Evrişim ve havuzlama işleminden sonra tek boyutlu bir vektöre düzleştirilen veriler, 200 adet öznitelik haritası içeren tam bağlı katmana (F1) iletilmiştir. Bu katmanda aşırı-uyumu önlemek için 0,5 oranında seyreltme işlemi uygulanmıştır. Seyreltilen veri, çıkış katmanına (F2) gönderilmiştir. Bu katman için çıkışlarını softmax fonksiyonu ile hesaplamaktadır.

**Çizelge 3.9.** 2B-ESA yapısı

Veri Seti	Pencere Boyutu	C1 Aktivasyon	C2 Aktivasyon	H1	F1 Aktivasyon	F2 Aktivasyon
Pavia University	7x7x103	3x3 ReLU	3x3 ReLU	2x2	Tam Bağlı ReLU	1x9 Softmax
Salinas	7x7x204	3x3 ReLU	3x3 ReLU	2x2	Tam Bağlı ReLU	1x16 Softmax
Öznitelik Haritası		50	100		200	

Sinir ağında işlenen paket boyutu 100, öğrenme adımı ( $\eta$ ), 0,001 olarak belirlenmiştir. Filtrelerin adım sayısı (S) iki boyutlu filtreler için (1,1) olarak belirlenmiştir. Ağırlıkların ilk değerlerini atamak için Xavier başlatıcı kullanılmıştır. Maliyet fonksiyonu olarak çapraz entropi fonksiyonu (Denklem 2.16) kullanılmıştır. Çalışmada çapraz entropi, ESA maliyetini belirlemek, hedef ve öngörülen etiketlerden sapmayı ölçmek için kullanılmıştır. Ağ, Adam optimize edici tarafından çapraz entropi kaybı fonksiyonunu en aza indirerek eğitilmiştir.

Detaylı analiz için öğrenme adımının sınıflandırma başarımına etkisi de incelenmiştir. Bu amaçla öğrenme adımı değiştirilerek 2B-ESA mimarisi ile sınıflandırma yapılmıştır ve sonuçlar incelenmiştir.

Katman ve sinir ağı derinliğinin sınıflandırmaya etkisini gözlemlemek için 2B-ESA mimarisi genişletilmiştir. Genişletilmiş 2B-ESA mimarisinde C1 ve C2 katmanlarının öznitelik haritası sayısı 100 ve 150'ye çıkarılmıştır ve 3x3 boyutunda 200 filtre içeren C3 katmanı eklenmiştir. C3 katmanından sonra ikinci havuzlama katmanı H2 eklenmiştir. F1 katmanının öznitelik haritası sayısı ise 300'e çıkarılmıştır. Genişletilmiş 2B-ESA mimarisinin katmanlarındaki filtre ve öznitelik haritası sayısı Çizelge 3.10'da gösterilmiştir.

**Çizelge 3.10.** Genişletilmiş 2B-ESA yapısı

Veri Seti	Pencere Boyutu	C1 Aktivasyon	C2 Aktivasyon	H1	C3 Aktivasyon	H2	F1 Aktivasyon	F2 Aktivasyon
Pavia University	7x7x103	3x3 ReLU	3x3 ReLU	2x2	3x3 ReLU	2x2	Tam Bağlı ReLU	1x9 Softmax
Salinas	7x7x204	3x3 ReLU	3x3 ReLU	2x2	3x3 ReLU	2x2	Tam Bağlı ReLU	1x16 Softmax
Öznitelik Haritası		100	150		200		300	

### 3.2.1.3. Üç boyutlu evrişimsel sinir ağı (3B-ESA)

3B-ESA, uzaysal-spektral tabanlı öznitelikleri kullanılarak sınıflandırma işleminin yapılmasını sağlayan yapay sinir ağı modelidir. Üç boyutlu evrişim işleminde 1 katmanında öznitelik haritası j'deki (x,y,z) konumundaki çıkış değeri denklem (3.7) ile hesaplanmaktadır.

$$v_{lj}^{xyz} = f \left( \sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} \sum_{r=0}^{R_l-1} k_{ljm}^{hwr} v_{(l-1)m}^{(x+h)(y+w)(z+r)} + b_{lj} \right) \quad (3.7)$$

Yukarıdaki eşitlikte  $R_1$  değeri üç boyutlu filtrenin spektral boyutunu temsil etmek üzere,  $j$  değeri bu katmandaki filtre numarasını ve  $k_{l_{j,m}}^{hwr}$  ise bir önceki katmandan öznitelik kübü  $m$ 'ye bağlı olan  $(h,w,r)$  konumundaki filtreyi belirtmektedir.

Veri setlerinde her bir piksel 7 adet komşuluğuyla temsil edilmiştir. Bu durumda her bir pikselin boyutu  $7 \times 7$  şeklinde komşuluk penceresiyle temsil edilmektedir.

Hiperspektral veri setlerinin 3B-ESA sınıflandırması için geliştirilen ilk mimarinin katmanlarındaki filtre ve öznitelik sayısı Çizelge 3.11'de gösterilmiştir. 3B-ESA mimarisinde iki adet evrişim katmanı bulunmaktadır. Her bir evrişim katmanı ReLU aktivasyon fonksiyonu içermektedir. Birinci evrişim katmanı (C1),  $3 \times 3 \times 3$  boyutunda 32 adet filtre içermektedir. C1 katmanının sonra  $3 \times 3 \times 3$  boyutunda 48 adet filtre içeren C2 evrişim katmanı gelmektedir. Tam bağlı katmanlara iletilmeden önce verilere  $2 \times 2 \times 2$  filtrelerle sahip H1 katmanı ile havuzlama işlemi ve 0,5 oranında seyreltme uygulanmıştır. Evrişim işleminden sonra tek boyutlu bir vektöre düzleştirilen veriler, 128 adet öznitelik haritası içeren tam bağlı katmana (F1) iletilmiştir. Bu katmanda 0,5 oranında seyreltme işlemi uygulanmıştır. Seyreltilen veri çıkış katmanına (F2) gönderilmiştir. Bu katman ağı çıkışlarını softmax fonksiyonu ile hesaplamaktadır.

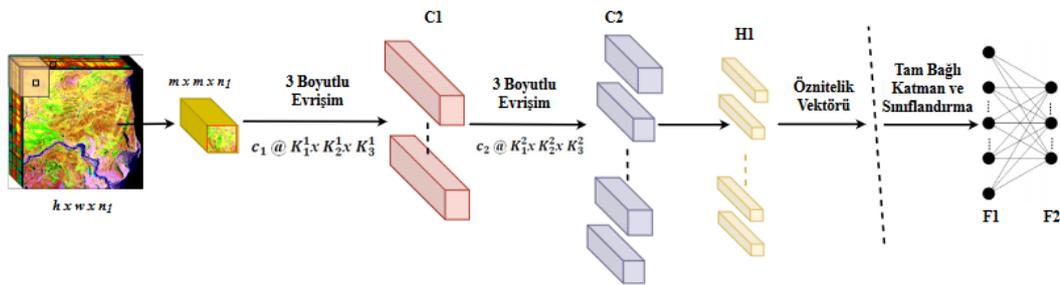
**Çizelge 3.11.** 3B-ESA yapısı

Veri Seti	Pencere Boyutu	C1 Aktivasyon	C2 Aktivasyon	H1	F1 Aktivasyon	F2 Aktivasyon
Pavia University	$7 \times 7 \times 103$	$3 \times 3 \times 3$ ReLU	$3 \times 3 \times 3$ ReLU	$2 \times 2 \times 2$	Tam Bağlı ReLU	$1 \times 9$ Softmax
Salinas	$7 \times 7 \times 204$	$3 \times 3 \times 3$ ReLU	$3 \times 3 \times 3$ ReLU	$2 \times 2 \times 2$	Tam Bağlı ReLU	$1 \times 16$ Softmax
Öznitelik Haritası		32	48		128	

Sinir ağında işlenen paket boyutu 100, öğrenme adımı ( $\eta$ ), 0,001 olarak belirlenmiştir. Ağırlıkların ilk değerlerini atamak için Xavier başlatıcı kullanılmıştır. Filtre adımı (S) ise üç boyutlu filtreler için (1,1,1) olarak belirlenmiştir. Maliyet fonksiyonu olarak çapraz entropi fonksiyonu kullanılmıştır. Çalışmada, çapraz entropi, ESA maliyetini belirlemek,

hedef ve öngörülen etiketlerden sapmayı ölçmek için kullanılmıştır. Ağ, Adam optimize edici tarafından çapraz entropi kaybı fonksiyonunu en aza indirerek eğitilmiştir.

3B-ESA'da 2B-ESA'da olduğu gibi, her bir piksel istenen boyuttaki komşulukları alınarak komşuluk penceresi şeklinde ifade edilmektedir. Şekil 3.7'de tez çalışmasında tasarlanan 3B-ESA'nın bir görseli sunulmuştur. Bu sinir ağında  $m$  komşuluk sayısı ve  $n_1$  spektral bant sayısı olmak üzere her bir piksel için  $m \times m \times n_1$  boyutundaki örnek verisi sinir ağına giriş olarak kullanılmaktadır. Üç boyutlu evrişim işlemi, üç boyutlu bir komşuluk penceresinde yukarıdan aşağıya, soldan sağa ve içten dışa adım adım uygulanmaktadır. Birinci üç boyutlu evrişim katmanı C1,  $c_1$  adet  $K_1^1 \times K_2^1 \times K_3^1$  ( $K_1^1 \times K_2^1$  uzaysal boyut ve  $K_3^1$  spektral boyut) boyutlu filtre içermektedir. Bu katman  $c_1$  adet filtre ile evrişim işlemi yaparak, aktivasyon fonksiyonu ile çıktı olarak her biri  $((m - K_1^1 - 1)/S) \times ((m - K_2^1 - 1)/S) \times ((n_1 - K_3^1 - 1)/S)$  boyutunda  $c_1$  adet öznelik haritası oluşturmaktadır. Bu katmanda oluşan eğitilebilir parametre sayısı  $((K_1^1 \times K_2^1 \times K_3^1) + 1) \times c_1$  olarak hesaplanmaktadır.  $c_2$  adet  $K_1^2 \times K_2^2 \times K_3^2$  boyutunda filtre içeren üç boyutlu evrişim katmanı C2'de ise  $x_1 = ((m - K_1^1 - 1)/S)$ ,  $x_2 = ((m - K_2^1 - 1)/S)$  ve  $x_3 = ((n_1 - K_3^1 - 1)/S)$  olmak üzere  $c_2$  adet  $((x_1 - K_1^2 - 1)/S) \times ((x_2 - K_2^2 - 1)/S) \times ((x_3 - K_3^2 - 1)/S)$  boyutunda çıktı oluşturmaktadır. C2 katmanında hesaplanan eğitilebilir parametre sayısı ise  $((K_1^2 \times K_2^2 \times K_3^2) + 1) \times c_2$  olarak hesaplanır.  $f_1$  adet nöron içeren tam bağlı katman F1'de eğitilebilir parametre sayısı  $((x_1 - K_1^2 - 1)/S) \times ((x_2 - K_2^2 - 1)/S) \times ((x_3 - K_3^2 - 1)/S) \times f_1 + 1$  olarak hesaplanmaktadır. Çıkış katmanı olan F2 katmanında ise veri setlerine ait sınıf sayıları  $O$  olmak üzere; eğitilebilir parametre sayısı  $O \times f_1$  olarak hesaplanmaktadır.



Şekil 3.7. Üç boyutlu evrişimsel sinir ağı (3B-ESA)

Detaylı analiz için olarak öğrenme adımının sınıflandırma başarımına etkisi de incelenmiştir. Bu amaçla öğrenme adımı değiştirilerek 3B-ESA mimarisini ile sınıflandırma yapılmıştır ve sonuçlar incelenmiştir.

Katman ve sinir ağı derinliğinin sınıflandırmaya etkisini gözlemlemek için 3B-ESA mimarisi genişletilmiştir. Genişletilmiş 3B-ESA mimarisinde C1 ve C2 katmanlarının öznitelik haritası sayısı 48 ve 64'e çıkarılarak, 128 adet 3x3x3 boyutunda filtre içeren C3 evrişim katmanı eklenmiştir. F1 katmanının öznitelik haritası sayısı 256'ya çıkarılmış ve 400 adet öznitelik haritası içeren bir tam bağlı katman daha eklenmiştir. Genişletilmiş 3B-ESA mimarisine ait katmanların filtre ve öznitelik haritaları sayısı Çizelge 3.12'de gösterilmiştir.

**Çizelge 3.12.** Genişletilmiş 3B-ESA yapısı

Veri Seti	Pencere Boyutu	C1 Aktivasyon	C2 Aktivasyon	C3 Aktivasyon	F1 Aktivasyon	F2 Aktivasyon	F3 Aktivasyon
Pavia University	7x7x103	3x3x3 ReLU	3x3x3 ReLU	3x3x3 ReLU	Tam Bağlı ReLU	Tam Bağlı ReLU	1x9 Softmax
Salinas	7x7x204	3x3x3 ReLU	3x3x3 ReLU	3x3x3 ReLU	Tam Bağlı ReLU	Tam Bağlı ReLU	1x16 Softmax
Öznitelik Haritası		48	64	128	256	400	

### 3.2.2. Boyut indirgeme yöntemleriyle sınıflandırma

Hiperspektral görüntüler, sınırlı sayıda eğitim örneğinden oluşan yüksek boyutlu verilerdir. Denetimli sınıflandırıcılar ile eğitim süreci zaman alıcı ve maliyetli olduğundan, veri daha küçük bir uzayda temsil edilerek sınıflandırılabilir. Fakat veriyi farklı bir uzayda temsil etmek, veri setinin orijinal yapısına zarar vererek kullanışlı bilgilerin yok olmasına sebep olabilir. Bu deney aşamasında veri setlerine farklı boyut indirgeme teknikleri uygulanarak sınıflandırma işleminin başarımı, spektral ve uzaysal bilgileri değiştirmeden kullanan ESA mimarileri ile karşılaştırılmıştır.

Çalışmada boyut indirgeme adımında Python'un scikit-learn makine öğrenme paketi kullanılmıştır (Pedregosa ve ark. 2011). Detaylı bir karşılaştırma için çeşitli denetimsiz

ve denetlenen boyutsallık azaltma teknikleri test edilmiştir. İndirgenen boyut sayısı aşamalı olarak arttırılarak hesaplama maliyeti azaltılmaya çalışılmıştır. Sınıflandırma sonuçları aracılığıyla farklı boyut azaltma tekniklerinin değerlendirilmesi için, scikit-learn kütüphanesindeki çeşitli sınıflandırıcılar uygulanmıştır.

Boyutu indirgenmiş veriler sınıflandırma aşamasında  $K$  adet eşit büyüklükteki alt kümelere bölünmüştür.  $K$ -katlamalı çapraz geçeleme işlemiyle  $K$  kere sınıflandırma işlemi yapılmıştır. Her adımda veri kümesinin daha önce test için ayrılan 1 parçası test için kullanılırken, geri kalan  $K-1$  parçası eğitim için kullanılmaktadır. Nihai sınıflandırma sonucu, bütün sınıflandırma fonksiyonlarının performanslarının toplamının,  $k$  sayısına bölünmesiyle elde edilir.

Bu tez çalışmasında klasik boyut indirme yöntemlerinden PCA, LDA, ICA, FA ve SVD kullanılmıştır. PCA (Fukunaga, 2013) en yaygın kullanılan denetlenmemiş boyutluluk azaltma yöntemidir ve öz vektör ayrışması ile spektral bantlar arasındaki bağımlılıkları ortadan kaldırmaktadır. Bu nedenle, hiperspektral görüntü işlemede sıklıkla kullanılmaktadır. Veri içerisindeki varyansın büyük kısmını koruyarak verilerin daha küçük boyutlu bir gösterimini oluşturmaktadır. Boyutsallığı azaltmak için verinin projeksiyonu için en önemli tekil vektörleri tutar (Lee ve ark 1993). Bir diğer boyut indirgeme yöntemi olan SVD ise ayrıştırma işlemi kovaryans matrisi üzerinde yapan PCA'den farklı olarak ayrıştırmayı veri matrisi üzerinde yapmaktadır. PCA'ye oldukça benzer olan bu yöntemde verilerin temel bileşenleri dönüşüm için daha verimli ve sağlam bir şekilde hesaplanmaktadır (Wall ve ark 2003). Uzaktan algılamada ve boyut indirgemedede yaygın şekilde kullanılan diğer bir yöntem olan LDA ise sınıf içi dağılımı en aza indiren, sınıflar arası dağılımı ise en üst düzeye çıkaran en iyi projeksiyon düzlemini aramaktadır (Bandos ve ark, 2009). FA yöntemi ise gözlenen verilerden orijinal verilerin yerine geçecek potansiyel faktörleri oluşturmak için geliştirilen doğrusal bir istatistiksel yöntemdir. Faktör analizi, ölçülen veya faktörlendirilmiş varlıkların (örneğin değişkenler) altında yatan yapıyı deneysel olarak tanımlamak için kullanılmaktadır. Girdideki farklı bölgelerin bir yerel faktör verileri modeli oluşturmasına izin verdiği için yüksek boyutlu veri oluşturma modeli için çok faydalı bir yöntemdir (Wang ve Wang 2015). Kullanılan sınıflandırıcılar ise Gaussian Process Sınıflandırıcı (GPC) (Mackay 1998), Rassal Orman Sınıflandırıcısı (Random Forest Classifier, RFC)

(Beriman ve ark. 1984), Ada Boost Sınıflandırıcı (Ada) (Hastie ve ark. 2009), Quadratic Discriminant Sınıflandırıcı (QDC) (Duda ve ark. 1973) ve Karar Ağacı Sınıflandırıcısı (Decision Tree Classifier, DTC) (Dumont ve ark. 2009)'dır.

Tez çalışmasında, ESA tabanlı modellerin etkinliği, hiperspektral sınıflandırmada yaygın olarak kullanılan yaklaşımlardan olan boyut indirgeyerek sınıflandırma yöntemi ile karşılaştırılmıştır.



## 4. BULGULAR ve TARTIŞMA

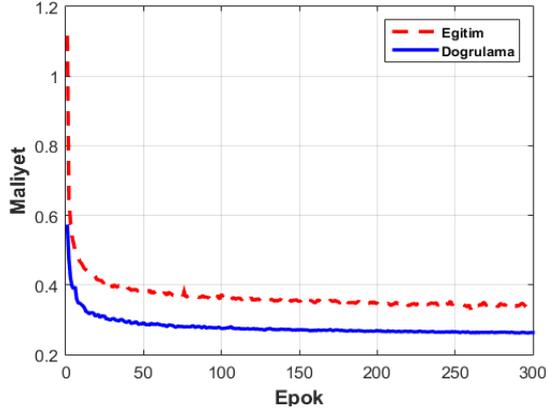
### 4.1. 1B –ESA Sınıflandırma Sonuçları

Geliştirilen 1B-ESA mimarisinin sınıflandırma sırasında her bir katmanda oluşan çıktı boyutları ve eğitilebilir parametre sayıları Çizelge 4.1’de gösterilmiştir. 1B-ESA mimarisinde öğrenme adımı ( $\eta$ ) 0,01 ve epok sayısı 300 olarak belirlenmiştir. Ayrıca test verisinin sınıflandırma sonucu da çizelgede gösterilmiştir.

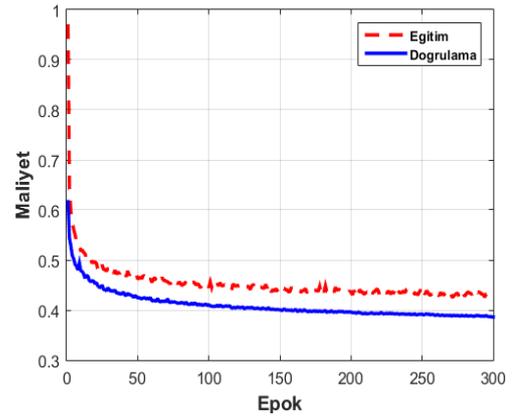
Çizelge 4.1. 1B-ESA çıktı ve parametre sayısı

Katman	Çıktı Şekli (Paket Sayısı, Girdi Nöronu, Çıkış Nöronu)		Parametre Sayısı	
	Pavia University	Salinas	Pavia University	Salinas
Girdi	(100, 103, 1)	(100, 204, 1)	0	0
C1	(100, 103, 64)	(100, 204, 64)	256	256
H1	(100, 51, 64)	(100, 102, 64)	0	0
C2	(100, 51, 128)	(100, 102, 128)	24 704	24 704
H2	(100, 25, 128)	(100, 51, 128)	0	0
Düzleştirme	(100, 3200)	(100, 6528)	0	0
F1	(100, 150)	(100, 150)	480 150	979 350
Seyreltme (0,5)	(100, 150)	(100, 150)	0	0
F2	(100, 9)	(100, 16)	1359	2416
Eğitilebilir Parametre Sayısı	506 469	1 006 726		
Test Doğruluk	0,85	0,89		
Maliyet	0,27	0,27		

Salinas ve Pavia University veri setleri için eğitim aşamasındaki maliyet kaybı grafikleri Şekil 4.1’de gösterilmiştir. Salinas veri setinde ortalama 50 epoktan sonra doğrulama ve eğitim sabit bir eğilim gösterirken, Pavia University veri setinde ise maliyet değerleri azalma eğilimindedir. Eğitim maliyetlerinin doğrulama maliyetlerinden yüksek olması, doğrulama verilerinin modelin tahmin etmesi için eğitim verilerinden daha kolay olduğunu göstermektedir. Modelin eğitilmesinde Pavia University için harcanan süre yaklaşık 364 saniye, Salinas veri seti için yaklaşık 1 055 saniyedir.



(a)



(b)

Şekil 4.1. 1B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,01) (a) Salinas veri seti (b) Pavia University veri seti

Çizelge 4.2. Salinas veri seti 1B-ESA sınıflandırma sonucu karmaşıklık matrisi

		TAHMİN																	
		Sımf	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	
GERÇEK	1	%97,9	%2,1																
	2		%99,9																%0,1
	3			%98,9	%0,1	%0,4						%0,1	%0,4	%0,1					
	4				%99,5	%0,5													
	5			%0,5	%0,6	%98,5	%0,1					%0,1	%0,1	%0,2					
	6						%99,8							%0,0			%0,1		
	7		%0,0					%99,5	%0,4								%0,0		
	8							%0,0	%0,0	%85,7		%2,2	%0,1			%0,1	%11,8		
	9									%0,0	%99,3	%0,6	%0,1			%0,1			
	10			%1,6		%0,1	%0,1			%0,2	%0,6	%98,1	%2,3	%1,6		%0,1	%0,3	%0,2	
	11			%2,9		%0,3					%2,8	%1,6	%89,6	%2,8					
	12											%0,1		%99,9					
	13														%98,4	%1,6			
	14											%0,5				%93,8			
	15			%0,1						%44,6		%1,1	%0,0				%54,0	%0,2	
	16					%0,1		%3,8	%0,3		%0,5						%0,6	%94,8	
Kesinlik		1,00	1,00	0,95	0,99	0,99	1,00	0,98	0,74	0,99	0,87	0,90	0,96	0,95	0,96	0,74	0,99		
Anma		0,98	1,00	0,99	0,99	0,98	1,00	0,99	0,86	0,99	0,90	0,90	1,00	0,98	0,94	0,54	0,95		
F1		0,99	0,99	0,97	0,99	0,99	1,00	0,99	0,80	0,99	0,89	0,90	0,98	0,97	0,95	0,63	0,97		

Geliştirilen 1B-ESA sınıflandırma (doğruluk) sonuçları Pavia University veri seti için %85 ve Salinas veri seti için %89'dur (bkz. Çizelge 4.1). Aynı zamanda Salinas veri seti için sınıflandırma sonucunda oluşan karmaşıklık matrisi, anma, kesinlik ve F1 değerleri Çizelge 4.2'de, Pavia University için karmaşıklık matrisi, anma, kesinlik ve F1 değerleri Çizelge 4.3'te gösterilmiştir.

Karmaşıklık matrislerinden görüleceği üzere; Salinas veri seti için en çok yanlış etiketlenen örnekler işlenmemiş bağ ve üzüm sınıflarına aittir. İşlenmemiş bağ ve üzüm sınıflarının F1 değerleri de bu sebeple en düşük değere sahiptir. İşlenmemiş bağ ve üzüm sınıfı olarak tahmin edilen örneklerin %74'ü gerçekten bu sınıflara aittir. Öte yandan işlenmemiş bağ sınıfına ait örneklerin yalnızca %54'ü, üzüm sınıfına ait örneklerin ise yalnızca %86'sı doğru etiketlenmiştir. Sınıflandırma işlemi bu sınıflar üzerinde yüksek başarı gösterememiştir.

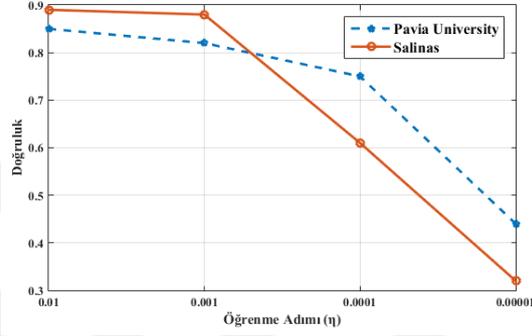
**Çizelge 4.3.** Pavia University veri seti 1B-ESA sınıflandırma sonucu karmaşıklık matrisi

		TAHMİN								
GERÇEK	Sınıf	1	2	3	4	5	6	7	8	9
	1	<b>%89,5</b>	%0,5	%1,5		%0,0	%0,6	%3,8	%4,0	
	2	%0,0	<b>%98,7</b>		%0,5		%0,8		%0,0	
	3	%18,1	%0,5	<b>%40,3</b>			%0,5	%0,1	%40,5	
	4		%17,8		<b>%82,0</b>		%0,2			
	5	%0,1	%0,1			<b>%99,4</b>	%0,1		%0,3	
	6	%0,3	%64,5		%0,1	%0,1	<b>%34,7</b>		%0,4	
	7	%15,6		%0,2				<b>%83,6</b>	%0,6	
	8	%2,2	%0,6	%4,0			%0,6	%0,1	<b>%92,5</b>	
	9	%0,1								<b>%99,9</b>
<b>Kesinlik</b>	0,90	0,83	0,77	0,96	0,99	0,88	0,81	0,74	1,00	
<b>Anma</b>	0,90	0,99	0,40	0,82	0,99	0,35	0,84	0,92	1,00	
<b>F1</b>	0,90	0,90	0,53	0,89	0,99	0,50	0,82	0,82	1,00	

Pavia University veri setinde ise en düşük doğru tahmin oranı çakıl ve toprak sınıfına aittir. Çakıl sınıfına ait örneklerin %40,5 kadarı tuğla olarak etiketlenirken; %18,1'i asfalt olarak etiketlenmiştir. Toprak sınıfına ait %64,5'i ise çayır olarak tahmin edilmiştir. Zift sınıfına ait örneklerin %15,6 kadarı ise asfalt olarak etiketlenmiştir. En düşük F1 değeri çakıl ve toprak sınıflarına aittir. Sınıflandırma işlemi bu sınıflarda yüksek başarı

gösterememiştir. Çakıl sınıfına ait olan örneklerin yalnızca %40'ı, toprak sınıfına ait örneklerin ise yalnızca %35'i doğru sınıflandırılmıştır

Tasarlanan 1B-ESA mimarisinde öğrenme adımının sınıflandırma başarımını etkisi gözlemek için  $\eta = 0,01$ ,  $\eta = 0,001$ ,  $\eta = 0,0001$  ve  $\eta = 0,00001$  değerleri için 1B-ESA sınıflandırma sonuçları Şekil 4.2'de sunulmuştur. Şekilde görüldüğü üzere öğrenme adımı azaldıkça sınıflandırma başarımı her iki veri seti için azalmıştır. Bu durum yapay sinir ağının geri-yayılım esnasında yerel minimum noktalarına takılarak alt çözümlerde sıkıştığını göstermektedir.

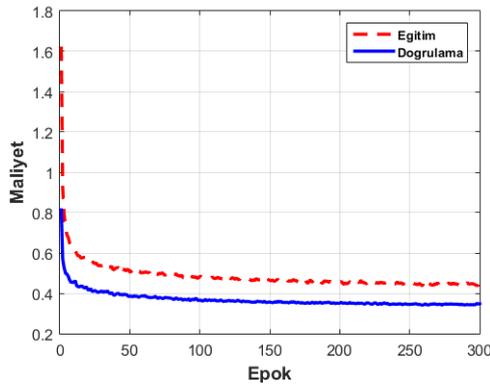


Şekil 4.2. Öğrenme adımının 1B-ESA sınıflandırma başarımına etkisi

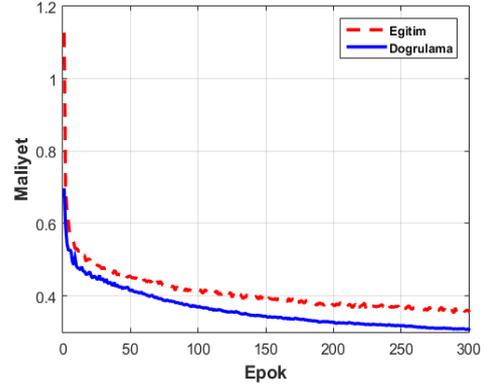
Katman ve sinir ağı derinliğinin sınıflandırmaya etkisini gözlemek için veri setleri genişletilmiş 1B-ESA mimarisi ile de sınıflandırılmıştır. Genişletilmiş 1B-ESA mimarisinin her katman için çıktı boyutları ve eğitilebilir parametre sayısı Çizelge 4.4'de gösterilmiştir. Genişletilmiş 1B-ESA mimarisinde öğrenme adımı ( $\eta$ ) 0,01 ve epok sayısı 300 olarak belirlenmiştir.

Çizelge 4.4. Genişletilmiş 1B-ESA çıktı ve eğitilebilir parametre sayıları

Katman	Çıktı Şekli (Paket Sayısı, Girdi Nöronu, Çıkış Nöronu)		Parametre Sayısı	
	Pavia University	Salinas	Pavia University	Salinas
<b>Girdi</b>	(100, 103, 1)	(100, 204, 1)	0	0
<b>C1</b>	(100, 103, 64)	(100, 204, 64)	256	256
<b>H1</b>	(100, 51, 64)	(100, 102, 64)	0	0
<b>C2</b>	(100, 51, 128)	(100, 102, 128)	24 704	24 704
<b>H2</b>	(100, 25, 128)	(100, 51, 128)	0	0
<b>C3</b>	(100, 25, 256)	(100, 51, 256)	164 096	164 096
<b>H3</b>	(100, 12, 256)	(100, 25, 256)	0	0
<b>Düzleştirme</b>	(100, 3072)	(100, 6400)	0	0
<b>F1</b>	(100, 150)	(100, 150)	460 950	1 958 550
<b>Seyreltme (0,5)</b>	(100, 150)	(100, 150)	0	0
<b>F2</b>	(100, 300)	(100, 300)	45 300	45 300
<b>Seyreltme (0,5)</b>	(100, 300)	(100, 300)	0	0
<b>F3</b>	(100, 9)	(100, 16)	2709	4816
<b>Eğitilebilir Parametre Sayısı</b>	698 015	2 197 722		
<b>Test Doğruluk</b>	0,82	0,84		
<b>Maliyet</b>	0,41	0,36		



(a)



(b)

Şekil 4.3. Genişletilmiş 1B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,01) (a)

Salinas veri seti (b) Pavia University veri seti

Genişletilmiş 1B-ESA mimarisinin eğitim aşamasında doğruluk ve maliyet değerlerinin değişimleri ise Şekil 4.8 ve Şekil 4.9'da gösterilmiştir. Sınıflandırma sonuçlarından

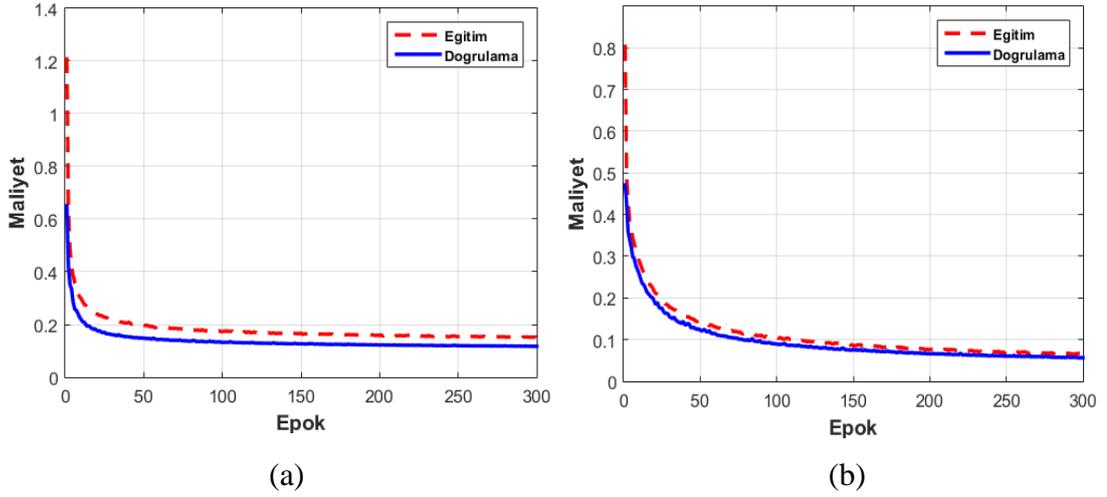
anlaşılacağı üzere katman sayısını arttırmak test başarımını azaltmış ve test maliyetini yükseltmiştir. Salinas veri setinde eğitim aşamasında maliyet değerleri yükselmiştir. Pavia University veri setinde ise ağın genişletilmesiyle beraber eğitim aşamasında maliyet değerleri azalmıştır. Bu veri setinde maliyet değerleri azalmaya devam ettiği için modelin daha fazla eğitilmesi sürecin gözlenmesi açısından faydalı olabilir. Fakat yine de her veri seti için doğrulama verileri eğitim verilerine oranla daha kolay kaldığı için maliyet değerleri eğitim verilerinin maliyetinden düşük seyretmiştir. Genişletilmiş 1B-ESA mimarisi modelinin Pavia University için eğitim süresi 447 saniye, Salinas veri seti için 820 saniyedir.

#### 4.2. 2B-ESA Sınıflandırma Sonuçları

2B-ESA, uzaysal tabanlı öznitelikleri kullanarak sınıflandırma yapılan yapay sinir ağı modelidir. Çizelge 4.5'te ise her bir katmanda oluşan çıktı verileri, eğitilebilir parametre sayıları ve test başarımı gösterilmiştir.  $\eta$  değeri 0,001 ve epok sayısı 300 olarak belirlenmiştir.

**Çizelge 4.5.** 2B-ESA çıktı ve eğitilebilir parametre sayıları

Katman	Çıktı Şekli (Paket Sayısı, Girdi Nöronu, Çıkış Nöronu)		Parametre Sayısı	
	Pavia University	Salinas	Pavia University	Salinas
<b>Girdi</b>	(100, 7, 7, 103)	(100, 7, 7, 204)	0	0
<b>C1</b>	(100, 7, 7, 50)	(100, 7, 7, 50)	46 400	91 850
<b>C2</b>	(100, 7, 7, 100)	(100, 7, 7, 100)	45 100	45 100
<b>H1</b>	(100, 3, 3, 100)	(100, 3, 3, 100)	0	0
<b>Düzleştirme</b>	(100, 150)	(100, 150)	0	0
<b>F1</b>	(100, 200)	(100, 200)	180 200	180 200
<b>Seyreltme (0,5)</b>	(100, 200)	(100, 200)	0	0
<b>F2</b>	(100, 9)	(100, 16)	1 809	3 216
<b>Eğitilebilir Parametre Sayısı</b>	273 509	320 366		
<b>Test Doğruluk</b>	0,99	0,96		
<b>Maliyet</b>	0,05	0,12		



**Şekil 4.4.** 2B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a) Salinas veri seti  
(b) Pavia University veri seti

Salinas ve Pavia University veri setleri için eğitim ve doğrulama verilerinin eğitim aşamasındaki maliyet değişimleri Şekil 4.4'te gösterilmiştir. Salinas ve Pavia University veri setlerinde eğitim maliyeti doğrulama maliyetinden daha yüksek olsa da değerleri birbirine çok yakındır. Daha fazla eğitim yapılarak eğitim ve doğrulama maliyetlerinin birbirine daha da yaklaşması beklenen bir durumdur. Bu durum tasarlanan 2B-ESA'nın veri setleri için uygun olduğunu göstermektedir. 2B-ESA modelinin eğitim süresi Pavia University için 1 106 saniye, Salinas veri seti için 1 898 saniyedir.

Geliştirilen 2B-ESA modelinin sınıflandırma sonuçları Pavia University veri seti için %99 ve Salinas veri seti için %96'dır (bkz. Çizelge 4.5). Aynı zamanda sınıflandırma sonuçlarına ait Pavia University veri seti için karmaşıklık matrisi, anma, kesinlik ve F1 değerleri Çizelge 4.6'da, Salinas veri seti için Çizelge 4.7'de gösterilmiştir.

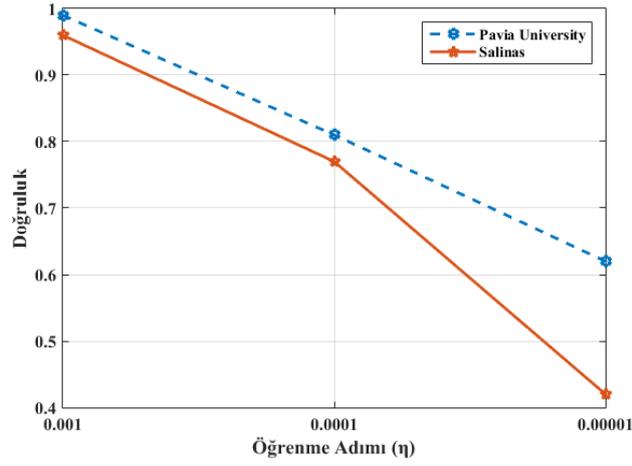
Salinas veri setinde en düşük F1 skoruna sahip sınıf işlenmemiş bağ sınıfıdır. Bu sınıfa ait örneklerin %14,7'si üzüm olarak sınıflandırılmıştır. Pavia University veri setinde ise çakıl sınıfına ait örneklerin %7,6'sı tuğla olarak etiketlenmiştir. Bu nedenle en düşük F1 skoru çakıl sınıfına aittir.

Çizelge 4.6. Pavia University veri seti 2B-ESA sınıflandırma sonucu karmaşıklık matrisi

		TAHMİN									
		Sımf	1	2	3	4	5	6	7	8	9
GERÇEK	1	%98,6		%0,4					%0,3	%0,7	
	2		%99,8		%0,0		%0,2				
	3	%0,2		%92,2						%7,6	
	4		%1,0		%99,0					%0,1	
	5					%100					
	6		%1,8					%98,2			
	7	%4,5						%0,3	%95,2		
	8	%1,4		%0,7				%0,2		%97,6	
	9										%100,0
	Kesinlik		0,98	0,99	0,97	1,00	1,00	0,99	0,98	0,95	1,00
Anma		0,99	1,00	0,92	0,99	1,00	0,98	0,95	0,98	1,00	
F1		0,98	1,00	0,95	0,99	1,00	0,99	0,97	0,96	0,00	

Çizelge 4.7. Salinas veri seti 2B-ESA sınıflandırma sonucu karmaşıklık matrisi

		TAHMİN																
		Sımf	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
GERÇEK	1	%100																
	2		%98,9															%1,1
	3			%99,7		%0,3												
	4				%99,5	%0,5												
	5				%1,1	%98,9												
	6						%100											
	7							%100										
	8								%92,0		%0,2							%7,8
	9									%99,6		%0,1	%0,1					
	10			%1,3					%2,4	%0,2	%94,1	%1,4					%0,4	%0,1
	11				%0,6						%0,9	%97,5	%0,9					
	12												%100					
	13													%100				
	14														%100			
	15								%14,7		%0,2						%95,1	
	16							%0,4	%0,6		%0,2							%98,9
Kesinlik		1,00	1,00	0,98	0,97	0,99	1,00	1,00	0,90	1,00	0,98	0,95	0,99	1,00	1,00	0,87	0,98	
Anma		1,00	0,99	1,00	1,00	0,99	1,00	1,00	0,92	1,00	0,94	0,97	1,00	1,00	1,00	0,85	0,99	
F1		1,00	0,99	0,99	0,98	0,99	1,00	1,00	0,91	1,00	0,96	0,96	1,00	1,00	1,00	0,86	0,98	



**Şekil 4.5** Öğrenme adımının 2B-ESA sınıflandırma başarımına etkisi

Tasarlanan 2B-ESA’da öğrenme adımının sınıflandırma başarımına etkisini gözlemlemek için öğrenme adımı  $\eta = 0,0001$  ve  $\eta = 0,00001$  şeklinde azaltılmıştır. Azaltılan öğrenme adımlarına göre sınıflandırma başarımı Şekil 4.5’te gösterilmiştir. Sonuçlara göre Pavia University ve Salinas veri setinin sınıflandırma başarımının öğrenme adımı azaldıkça düştüğü gözlemlenmiştir. Bu durum, sinir ağının hata oranının minimize edilmesi sırasında yerel minimum noktalarına takıldığına göstergesidir.

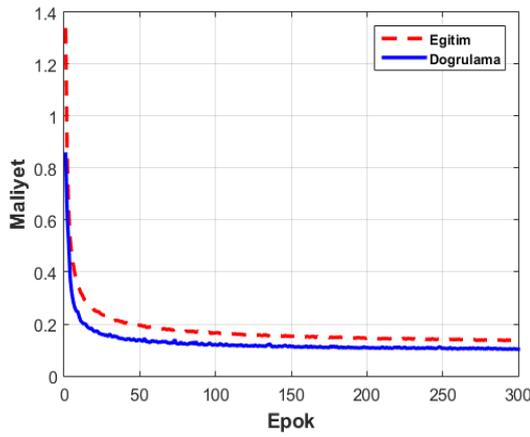
Katman ve sinir ağı derinliğinin etkisini gözlemlemek için ikinci aşamada 2B-ESA mimarisi genişletilmiştir. Genişletilmiş 2B-ESA mimarisinin her katman için çıktı boyutları ve eğitilebilir parametre sayısı Çizelge 4.8’de gösterilmiştir. Görüldüğü üzere evrişim katmanı ve havuzlama katmanı eklendiğinde eğitilebilir parametre sayısı iki veri seti için de artmıştır. Genişletilmiş 2B-ESA mimarisinin eğitim süresi Pavia University veri seti için 1 901 saniye, Salinas veri seti için 3 573 saniyedir.

Genişletilmiş 2B-ESA mimarisinin eğitim aşamasında doğruluk ve maliyet değerlerinin değişimleri Şekil 4.6’da gösterilmiştir. Pavia University veri seti maliyet grafiğinden görüleceği üzere eğitim ve doğrulama verilerinin maliyetleri birbirine oldukça yakındır. Bu durum genişletilmiş 2B-ESA mimarisinin Pavia University veri seti için oldukça uygun olduğunu göstermektedir. Nitekim Pavia University için %100 oranında test

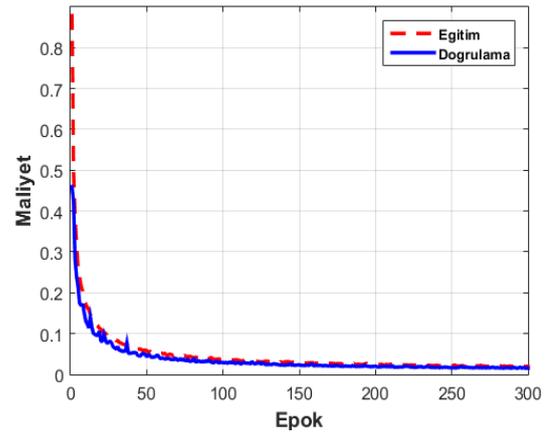
başarımı elde edilmiştir. Salinas veri setinde ise test başarımı ve maliyet önemli oranda değişmese de eğitim ve doğrulama maliyetleri birbirine yakın değerlere yaklaşmıştır.

**Çizelge 4.8.** Genişletilmiş 2B-ESA çıktı ve eğitilebilir parametre sayıları

Katman	Çıktı Şekli (Paket Sayısı, Girdi Nöronu, Çıkış Nöronu)		Parametre Sayısı	
	Pavia University	Salinas	Pavia University	Salinas
Girdi	(100, 7, 7, 103)	(100, 7, 7, 204)	0	0
C1	(100, 7, 7, 100)	(100, 7, 7, 100)	92 800	183 700
C2	(100, 7, 7, 150)	(100, 7, 7, 150)	135 150	135 150
H1	(100, 3, 3, 150)	(100, 3, 3, 150)	0	0
C3	(100, 3, 3, 200)	(100, 3, 3, 200)	750 200	750 200
H2	(100, 1, 1, 200)	(100, 1, 1, 200)	0	0
Seyreltme (0,5)	(100, 1, 1, 200)	(100, 1, 1, 200)	0	0
Düzleştirme	(100, 200)	(100, 200)	0	0
F1	(100, 300)	(100, 300)	60 300	60 300
Seyreltme (0,5)	(100, 300)	(100, 300)	0	0
F2	(100, 9)	(100, 16)	2 709	4816
Eğitilebilir Parametre	1 041 159	1 134 166		
Test Doğruluk	1,00	0,96		
Maliyet	1,00	0,10		



(a)



(b)

**Şekil 4.6.** Genişletilmiş 2B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a)

Salinas veri seti (b) Pavia University veri seti

### 4.3. 3B-ESA Sınıflandırma Sonuçları

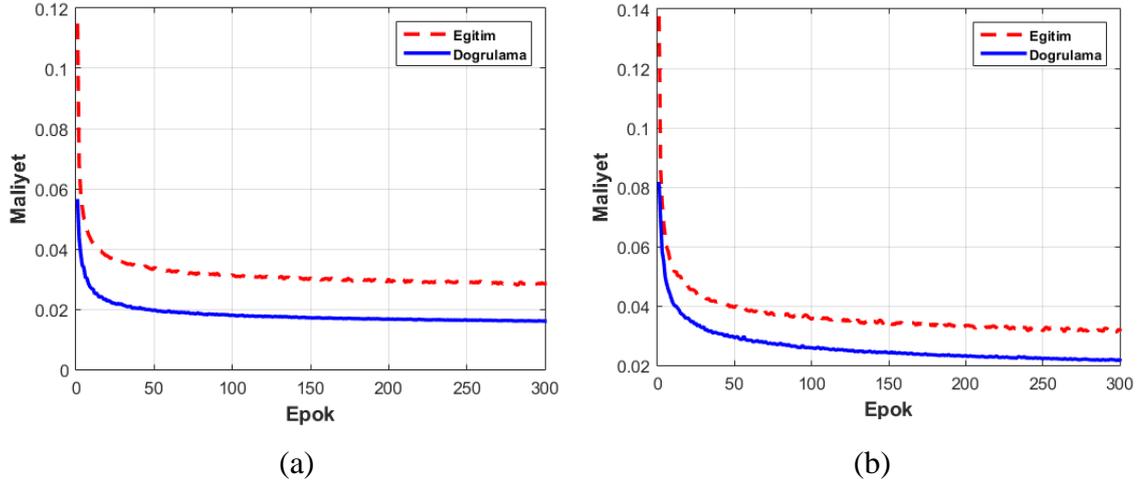
3B ESA, uzaysal-spektral tabanlı öznitelikleri kullanarak sınıflandırma yapılan yapay sinir ağı modelidir. Üç boyutlu evrişimsel sinir ağı optimizasyonu, gizli katman sayısı, düğüm sayısı, öğrenme hızı ve filtre büyüklüğü parametrelerini belirlemek için deneme-yanılma yaklaşımı kullanılmıştır. Öğrenme adımı ( $\eta$ ) 0,001 ve epok sayısı 300'dür.

Çizelge 4.9'da ise her bir katmanda oluşan çıktı verileri, eğitilebilir parametre sayıları ve test başarımları gösterilmiştir. 3B-ESA modelinin eğitim süresi Pavia University için 4 795 saniye, Salinas veri seti için 10 646 saniyedir.

**Çizelge 4.9.** 3B-ESA çıktı ve eğitilebilir parametre sayıları

Katman	Çıktı Şekli (Paket Sayısı, Girdi Nöronu, Çıkış Nöronu)		Parametre Sayısı	
	Pavia University	Salinas	Pavia University	Salinas
<b>Girdi</b>	(100, 7, 7, 103, 1)	(100, 7, 7, 204,1)	0	0
<b>C1</b>	(100, 5, 5 101, 32)	(100, 5, 5, 202, 32)	1344	896
<b>C2</b>	(100, 3, 3, 99, 48)	(100, 3, 3, 200, 48)	83 008	41 520
<b>H1</b>	(100, 2, 2, 98, 48)	(100, 2, 2, 199, 48)	221 312	0
<b>Seyreltme (0,5)</b>	(100, 2, 2, 98, 48)	(100, 2, 2, 199, 48)	0	0
<b>Düzleştirme</b>	(100, 18 816)	(100, 38 208)	0	0
<b>F1</b>	(100, 128)	(100, 128)	3 178 752	4 890 752
<b>Seyreltme (0,5)</b>	(100, 128)	(100, 128)	0	0
<b>F2</b>	(100, 9)	(100, 16)	3609	2064
<b>Eğitilebilir Parametre Sayısı</b>	2 452 153	4 935 232		
<b>Test Doğruluk</b>	0,99	0,99		
<b>Maliyet</b>	0,02	0,02		

Salinas ve Pavia University veri setleri için 3B-ESA sınıflandırma eğitim aşaması maliyet fonksiyonu değerleri Şekil 4.7'de gösterilmiştir. Doğrulama verilerinin maliyetinin eğitim verilerinin maliyetinden düşük olması, doğrulama verilerinin modelin tahmin etmesi için eğitim verilerinden daha kolay olduğunu göstermektedir.



**Şekil 4.7.** 3B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a) Salinas veri seti (b) Pavia University veri seti

Pavia University ve Salinas veri setleri için 3B-ESA sınıflandırma başarımı %99 ve maliyet değeri 0,02'dir (bkz. Çizelge 4.9). Aynı zamanda sınıflandırma sonuçlarına ait Salinas veri seti için karmaşıklık matrisi, anma, kesinlik ve F1 değerleri Çizelge 4.10'da, Pavia University için Çizelge 4.11'de gösterilmiştir.

Salinas veri setinin 3B-ESA sınıflandırma sonucuna göre oluşan karmaşıklık matrisinden görüleceği üzere (bkz. Çizelge 4.10) en düşük doğru sınıflandırma oranı işlenmemiş bağ sınıfına aittir. İşlenmemiş bağ sınıfına ait %18,3 oranında örnek üzüm olarak etiketlenmiştir. Öte yandan üzüm sınıfına ait örneklerin %8,9'u ise işlenmemiş bağ sınıfı olarak etiketlenmiştir.

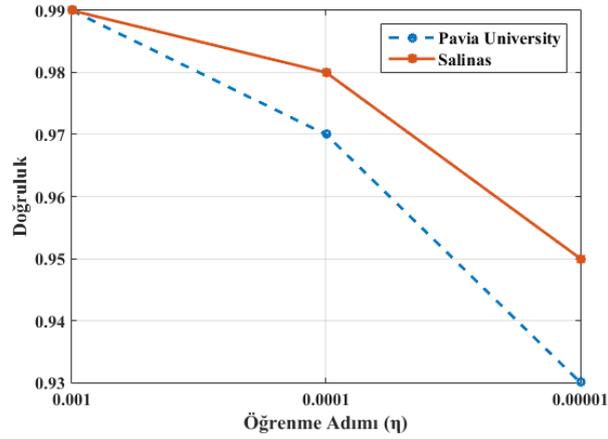
Pavia University veri setinin 3B-ESA sınıflandırma sonucuna göre oluşan karmaşıklık matrisinden görüleceği üzere (bkz. Çizelge 4.11) en düşük sınıflandırma başarımı ve F1 skoru çakıl sınıfına aittir. Çakıl sınıfına ait örneklerin %14,6'sı tuğla olarak etiketlenmiştir. Zift sınıfına ait örneklerin ise %8,3'ü asfalt olarak, toprak sınıfına ait örneklerin %5,5'i çayır olarak etiketlenmiştir.

Çizelge 4.10. Salinas veri seti 3B-ESA sınıflandırma sonucu karmaşıklık matrisi

		TAHMİN																
		Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
GERÇEK	1	%100																
	2		%100															
	3			%99,8						%0,2								
	4				%99,8	%0,2												
	5				%0,4	%99,6												
	6						%100											
	7							%100										
	8								%91,0	%0,0	%0,1							%8,9
	9									%99,9	%0,1							
	10		%1,2						%0,1	%0,5	%97,0	%0,6	%0,4					%0,1
	11		%0,6	%0,3					%0,3		%0,3	%97,8	%0,6					
	12												%100					
	13													%100				
	14													%0,9	%99,1			
	15									%18,3								%81,7
	16		%0,9							%0,6								%0,4
	<b>Kesinlik</b>	1,00	1,00	0,98	0,99	1,00	1,00	1,00	0,88	1,00	0,99	0,98	0,99	0,99	1,00	0,85	1,00	
	<b>Anma</b>	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,91	1,00	0,97	0,98	1,00	1,00	0,99	0,82	0,98	
	<b>F1</b>	1,00	1,00	0,99	0,99	1,00	1,00	1,00	0,90	1,00	0,98	0,98	0,99	0,99	1,00	0,84	0,99	

Çizelge 4.11. Pavia University veri seti 3B-ESA sınıflandırma sonucu karmaşıklık matrisi

		TAHMİN									
		Sınıf	1	2	3	4	5	6	7	8	9
GERÇEK	1	%97,8			%1,4				%0,2	%0,6	
	2		%98,5		%0,1		%1,4				
	3	%1,9		%83,1			%0,2	%0,2	%14,6		
	4		%0,5		%99,5						
	5					%100					
	6		%5,5				%94,5				
	7	%8,3		%0,3				%91,5			
	8	%0,3	%0,9				%0,3		%98,6		
	9									%100	
	<b>Kesinlik</b>	0,98	0,98	0,93	1,00	1,00	0,94	0,99	0,91	1,00	
	<b>Anma</b>	0,98	0,98	0,83	0,99	1,00	0,94	0,91	0,99	1,00	
	<b>F1</b>	0,98	0,98	0,88	1,00	1,00	0,94	0,95	0,95	1,00	



**Şekil 4.8.** Öğrenme adımının 3B-ESA sınıflandırma başarımına etkisi

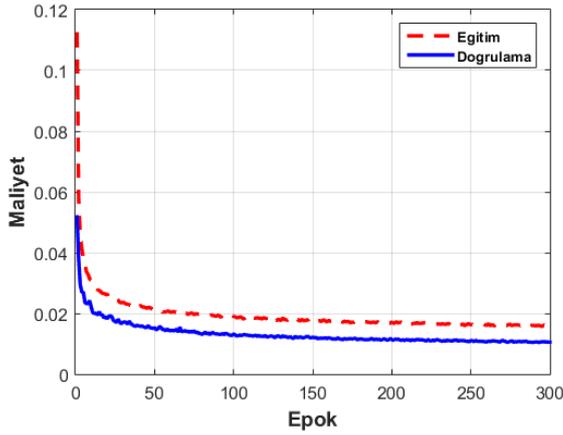
Tasarlanan 3B-ESA’da öğrenme adımının sınıflandırma başarımına etkisini gözlemlemek için öğrenme adımı  $\eta = 0,0001$  ve  $\eta = 0,00001$  şeklinde azaltılmıştır. Azaltılan öğrenme adımlarına göre sınıflandırma başarımı Şekil 4.8’de gösterilmiştir. Sonuçlara göre Pavia University ve Salinas veri setinin sınıflandırma başarımının öğrenme adımı azaltıldıkça düştüğü gözlemlenmiştir. Bu durum, sinir ağının hata oranının minimize edilmesi sırasında yerel minimum noktalarına ve alt çözümlere takıldığına göstergesidir.

Katman ve sinir ağı derinliğinin etkisini gözlemlemek için 3B-ESA mimarisi genişletilmiştir. Genişletilmiş 3B-ESA mimarisinin her katman için çıktı boyutları, eğitilebilir parametre sayısı ve test başarımı Çizelge 4.12’de gösterilmiştir. Görüldüğü üzere evrişim katmanı ve tam bağlı katman eklenerek nöron sayıları da arttırıldığında eğitilebilir parametre sayısı iki veri seti için de artmıştır.

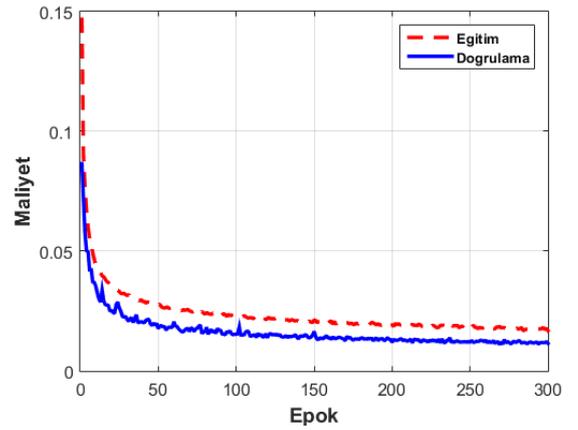
Genişletilmiş 3B-ESA modelinin eğitim süresi Pavia University için 7 484 saniye, Salinas veri seti için 18 779 saniyedir. Genişletilmiş 3B-ESA mimarisine ait eğitim aşamasındaki eğitim maliyeti Şekil 4.9’da gösterilmiştir. 3B-ESA mimarisinin genişletilmesi ile eğitim aşamasında doğrulama ve eğitim maliyetleri arasındaki fark azalmıştır. Bu durum genişletilmiş 3B-ESA mimarisinin veri setleri için daha uygun olduğunu göstermektedir. Aynı zamanda genişletilmiş 3B-ESA mimarisi ile her iki veri seti için %100 oranında başarımlar sağlanmıştır ve test maliyeti 3B-ESA mimarisine oranla azalmıştır (bkz. Çizelge 4.12).

Çizelge 4.12. Genişletilmiş 3B-ESA çıktı ve eğitilebilir parametre sayıları

Katman	Çıktı Şekli (Paket Sayısı, Girdi Nöronu, Çıkış Nöronu)		Parametre Sayısı	
	Pavia University	Salinas	Pavia University	Salinas
Girdi	(100, 7, 7, 103, 1)	(100, 7, 7, 204,1)	0	0
C1	(100, 5, 5 101, 48)	(100, 5, 5, 202, 48)	1344	1344
C2	(100, 3, 3, 99, 64)	(100, 3, 3, 200, 64)	83 008	83 008
C3	(100, 1, 1, 97, 128)	(100, 1, 1, 198, 128)	221 312	221 312
Seyreltme (0,5)	(100, 1, 1, 97, 128)	(100, 1, 1, 198, 128)	0	0
Düzleştirme	(100, 12 416)	(100, 25 344)	0	0
F1	(100, 256)	(100, 256)	3 178 752	6 488 320
Seyreltme (0,5)	(100, 256)	(100, 256)	0	0
F2	(100, 400)	(100, 400)	102 800	102 800
Seyreltme (0,5)	(100, 400)	(100, 400)	0	0
F3	(100, 9)	(100, 16)	3609	6416
Eğitilebilir Parametre	3 590 825	6 903 200		
Test Doğruluk	1,00	1,00		
Maliyet	0,01	0,01		



(a)



(b)

Şekil 4.9. Genişletilmiş 3B-ESA eğitim aşaması maliyet grafikleri ( $\eta$ : 0,001) (a)

Salinas veri seti (b) Pavia University veri seti

#### 4.4. Boyut İndirgeme Yöntemleriyle Sınıflandırma Sonuçları

Önerilen ESA mimarilerinin sınırlı eğitim örnekleriyle hiperspektral veri setlerini sınıflandırmak için uygun olduğunu doğrulamak için farklı geleneksel sınıflandırma teknikleri ile karşılaştırma yapılmıştır. Sınıflandırmadan önce veri setlerine çeşitli geleneksel boyut indirgeme yöntemleri uygulanmıştır. İndirgenen boyut sayısı her iki hiperspektral veri seti için 50'ye kadar aşamalı şekilde arttırılmıştır. Daha sonra geçerli boyuta göre indirgenmiş veriye 10-katlı çapraz geçişleme yöntemiyle sınıflandırma uygulanmıştır.

Boyutları aşamalı olarak 1'den 50'ye kadar indirgenmiş olan verilerin ortalama sınıflandırma sonuçları Çizelge 4.13 ve Çizelge 4.14'te gösterilmiştir.

Salinas veri seti için en yüksek başarımlı LDA boyut indirgeme yöntemi ile sağlanmıştır. Sınıf içi dağılımı en aza indirip sınıflar arası dağılımın en yüksek olduğu alt dönüşüm uzayını bulan bu yöntem ile %95,7 oranında test başarımlı sağlanmıştır. Pavia University veri seti için en yüksek başarımlı FA boyut indirgeme yöntemi ile sağlanmıştır. Deneysel sonuçlar ayrıca FA algoritmasının diğer boyutluluk azaltma yöntemlerinden daha iyi performans gösterdiğini de göstermektedir. FA, belirli bir gruptaki değişkenlerin kendi aralarında yüksek derecede korelasyonu olduğunu ancak farklı bir gruptaki değişkenlerle nispeten küçük korelasyonları var olduğunu varsaymaktadır. Her iki veri seti için düşük performans gösteren AdaBoost algoritması, zayıf sınıflandırıcılarla güçlü sınıflandırıcı oluşturmaktadır. Zayıf sınıflandırıcılar AdaBoost algoritmasını kullanan topluluk sınıflandırıcısının üyesidir. AdaBoost, her bir döngüdeki ağırlıkları uyarlamalı olarak ayarlayarak üye zayıf sınıflandırıcılardan oluşan bir komite oluşturur. Mevcut bir zayıf sınıflandırıcı tarafından yanlış sınıflandırılan eğitim numunelerinin ağırlıkları artarken, mevcut bir zayıf sınıflandırıcı tarafından doğru sınıflandırılan eğitim numunelerinin ağırlıkları azaltılır. AdaBoost, topluluk sınıflandırıcısı oluşturmak için iyi bir algoritmadır, ancak genelleme ortalamasını en aza indirmek için her zaman topluluk sınıflandırıcısı üretemez. Ayrıca gürültülü verilere karşı duyarlıdır. Her noktaya mükemmel şekilde uymaya çalıştığı için aykırılıklardan oldukça etkilenmektedir.

**Çizelge 4.13.** Salinas veri seti boyut indirgeme ile ilk 50 boyutunun sınıflandırma başarımı ortalaması

Sınıflandırıcı / Boyut İndirgeme	RFC	Ada	GPC	QDC	DTC
<b>FA</b>	%91,18	%32,62	%84,76	%89,48	%89,80
<b>ICA</b>	%94,72	%46,16	%87,91	%92,79	%92,61
<b>LDA</b>	<b>%95,77</b>	%46,34	%92,99	%93,78	%94,27
<b>SVD</b>	%94,34	%40,79	%88,69	%92,83	%92,80
<b>PCA</b>	%88,94	%34,82	%83,42	%87,53	%87,55

**Çizelge 4.14.** Pavia University veri seti boyut indirgeme ile ilk 50 boyutunun sınıflandırma başarımı ortalaması

Sınıflandırıcı / Boyut İndirgeme	RFC	Ada	GPC	QDC	DTC
<b>FA</b>	%89,69	%57,92	%82,19	<b>%91,85</b>	%86,76
<b>ICA</b>	%88,90	%61,02	%84,03	%91,57	%85,21
<b>LDA</b>	%89,99	%61,90	%86,42	%88,73	%86,58
<b>SVD</b>	%88,94	%58,39	%80,39	%91,39	%85,67
<b>PCA</b>	%88,92	%62,19	%81,16	%91,57	%85,92

## 5. SONUÇ

Tez çalışmasında, hiperspektral görüntü sınıflandırmasının iyileştirilmesi amacıyla bir boyutlu, iki boyutlu ve üç boyutlu evrişimsel sinir ağları kullanılarak, hiperspektral verilerin spektral, uzaysal ve spektral-uzaysal bilgilerinden tam olarak faydalanan sinir ağı mimarileri önerilmiştir. Bu sayede evrişimsel sinir ağlarının hiperspektral verilerin üç boyutlu yapısına sınıflandırma bazında uyarlanabilirliği test edilmiştir.

Çalışmada tasarlanan ESA mimarileri iki adet yaygın olarak kullanılan hiperspektral veri setiyle test edilmiştir. 2B-ESA ve 3B-ESA'da piksellerin uzamsal tutarlılığını korumak adına her bir piksel küçük bir komşuluk alanı ile temsil edilmiştir. Hiperspektral görüntüleri sınıflandırılmasında yaygın olarak karşılaşılan aşırı-uyum ve az-uyum problemlerini engelleyebilmek için tasarlanan mimarilerin veriye uygun olması oldukça önemlidir. Bu nedenle ESA mimarilerinde öğrenme oranları ve katman sayıları değiştirilerek bu değişimlerin sınıflandırma başarımını etkisi gözlemlenmiştir.

ESA mimarileri değiştirildiğinde katman sayısının artmasının sınıflandırma başarımını her zaman arttırmadığı gözlemlenmiştir. Bu nedenle sinir ağlarını tasarlarken veri setine uygun mimariyi geliştirmek oldukça önemlidir. Ayrıca öğrenme adımını azaltmak, hata oranının minimize edilirken yerel minimum noktalarında sıkışma sorununa sebep olduğundan sınıflandırma başarımını düşürebilmektedir. Bu nedenle uygun öğrenme adımının seçimine dikkat edilmelidir.

Hiperspektral uzaktan algılama verilerinde sınırlı sayıda etiketli eğitim örnekleri mevcuttur. Tez çalışmasında aşırı uyum problemine sebep olan bu durumu çözmek için katmanları arasında seyreltme işlemi uygulanmıştır.

Yapılan deneysel çalışmalarda 1B-ESA mimarisinde Pavia University veri seti için %85, Salinas veri seti için %89 oranında sınıflandırma başarımı elde edilmiştir. 2B-ESA mimarisinde Salinas veri seti için %96, Pavia University veri seti için %100, 3B-ESA mimarisinde ise Salinas ve Pavia University veri seti için %100 oranında başarımlar sağlanmıştır. Spektral-uzaysal öznitelikleri bir arada kullanan 3B-ESA en yüksek başarımları göstermiştir.

Geleneksel boyut indirgeme yöntemleriyle yapılan sınıflandırmaya kıyasla geliştirilen ESA mimarileri Salinas veri seti için yaklaşık %5 ve Pavia University veri seti için yaklaşık %9 oranında başarıyı yükseltmiştir. Bu sayede evrimsel sinir ağları ile hiperspektral verilerin spektral bilgileri daha alt uzaya dönüştürülmeden ve orijinalliğini kaybetmeden daha yüksek başarımlar elde edilmiştir.

Hiperspektral uzaktan algılamada çok sayıda etiketli örneğe sahip olmak oldukça maliyetlidir. Gelecekteki çalışmalar açısından, hiperspektral görüntülerde etiketlenmemiş örneklerden yararlanabilen daha etkili ESA tabanlı sınıflandırma yaklaşımları denenebilir. 3B-ESA'ya dayanan denetimsiz ve yarı denetimli sınıflandırma yöntemlerinin bir entegrasyonu sonraki çalışmalarda değerlendirilebilir. Ayrıca data augmentation (veri büyütme) işlemiyle eğitim verileri çoğaltılabilir.

## KAYNAKLAR

- Amidi, A., Amidi S., 2018.** Stanford, Convolutional Neural Networks cheatsheet. <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks->(Erişim Tarihi: 01.05.2019).
- Atkinson, P. M., Tatnall, A. R. 1997.** Introduction neural networks in remote sensing. *International Journal of remote sensing*, 18(4): 699-709.
- Bandos, T. V., Bruzzone, L., Camps-Valls, G. 2009.** Classification of hyperspectral images with regularized linear discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3): 862-873.
- Ben-Dor, E., Schläpfer, D., Plaza, A. J., Malthus, T. 2013.** Hyperspectral remote sensing. Airborne Measurements for Environmental Research: Methods and Instruments, Ed.: Wendisch M., Brenguier J.L., Germany, pp: 413-456.
- Borengasser, M., Hungate, W. S., Watkins, R. 2007.** *Hyperspectral remote sensing: principles and applications*. CRC press.
- Chen, C., Jiang, F., Yang, C., Rho, S., Shen, W., Liu, S., Liu, Z. 2018.** Hyperspectral classification based on spectral–spatial convolutional neural networks. *Engineering Applications of Artificial Intelligence*, 68(2018): 165-171.
- 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.
- Chen, Y., Lin, Z., Zhao, X., Wang, G., Gu, Y. 2014.** Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected topics in applied earth observations and remote sensing*, 7(6): 2094-2107.
- 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.
- Chen, Y., Zhu, L., Ghamisi, P., Jia, X., Li, G., Tang, L. 2017.** Hyperspectral images classification with Gabor filtering and convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 14(12): 2355-2359.
- Cheng, G., Han, J., Lu, X. 2017.** Remote sensing image scene classification: Benchmark and state of the art. *Proceedings of the IEEE*, 105(10): 1865-1883.
- Copeland, M. 2016.** Nvidia, What's the Difference Between Artificial Intelligence, Machine Learning, and Deep Learning? [https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/-](https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/)(Erişim Tarihi: 30.04.2019).
- Danaher, S., Herries, G., Selige, T., Mac Surtan, M. 1997.** A comparison of the characterisation of agricultural land using singular value decomposition and neural networks. In *Neurocomputation in Remote Sensing Data Analysis*, Ed.: Kanellopoulos, I., Wilkinson, G.G., Roli, F., Austin, J., Springer, Berlin, Heidelberg, pp: 14-27.
- David, L. 2002.** Hyperspectral image data analysis as a high dimensional signal processing problem. *IEEE Signal processing Mag*, 19(1): 17-28.

- Duda, R. O., Hart, P. E., Stork, D. G. 1973.** Pattern classification and scene analysis (3), Wiley, New York, pp: 472.
- Dumont, M., Marée, R., Wehenkel, L., Geurts, P. 2009.** Fast multi-class image annotation with random subwindows and multiple output randomized trees International Conference on Computer Vision Theory and Applications (VISAPP), 5-8 February 2009, Lisboa, Portugal.
- Chuvieco, E. 2009.** Sensors and Remote Sensing Satellites: Fundamentals of satellite remote sensing, Ed.: CRC press, pp: 63-114.
- Fang, H., Hu, C. 2014.** Recognizing human activity in smart home using deep learning algorithm. 33rd Chinese Control Conference, 28-30 July, 2014, Nanjing, China.
- Freund, Y., Haussler, D. 1992.** Unsupervised learning of distributions on binary vectors using two layer networks. Advances in neural information processing systems, Ed.: Moody, J.E., Hanson, S.J., Lippman, R.P., pp: 912-919.
- Friedman, J. H. 1997.** On bias, variance, 0/1-loss, and the curse-of-dimensionality. *Data mining and knowledge discovery*, 1(1): 55-77.
- Fukunaga, K. 2013.** Feature extraction and linear mapping for classification: *Introduction to statistical pattern recognition*, Ed.: Rheinboldt W., West Lafayette, Indiana, pp: 441-507.
- Gardner, M. W., Dorling, S. R. 1998.** Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15): 2627-2636.
- Ghamisi, P., Couceiro, M. S., Fauvel, M., Benediktsson, J. A. 2014.** Integration of segmentation techniques for classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 11(1): 342-346.
- Glorot, X., Bengio, Y. 2010.** Understanding the difficulty of training deep feedforward neural networks. The thirteenth international conference on artificial intelligence and statistics, March 2010, Chia Laguna Resort, Sardinia, Italy.
- Glorot, X., Bordes, A., Bengio, Y. 2011.** Deep sparse rectifier neural networks. In Proceedings of the fourteenth international conference on artificial intelligence and statistics, June 2011, Fort Lauderdale, FL, USA.
- Goetz, A. F., Vane, G., Solomon, J. E., Rock, B. N. 1985.** Imaging spectrometry for earth remote sensing. *science*, 228(4704): 1147-1153.
- Green, R. O., Eastwood, M. L., Sarture, C. M., Chrien, T. G., Aronsson, M., Chippendale, B. J., Olah, M. R. 1998.** Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS). *Remote sensing of environment*, 65(3): 227-248.
- Gowen, A. A., O'Donnell, C., Cullen, P. J., Downey, G., Frias, J. M. 2007.** Hyperspectral imaging—an emerging process analytical tool for food quality and safety control. *Trends in food science & technology*, 18(12): 590-598.
- Ha, S., Yun, J. M., Choi, S. 2015.** Multi-modal convolutional neural networks for activity recognition. 2015 IEEE International Conference on Systems, Man, and Cybernetics, 9-12 October 2015, Nanjing, China.

- Hastie, T., Rosset, S., Zhu, J., Zou, H. 2009.** Multi-class adaboost. *Statistics and its Interface*, 2(3): 349-360.
- Haut, J. M., Paoletti, M., Plaza, J., Plaza, A. 2017.** Cloud implementation of the K-means algorithm for hyperspectral image analysis. *The Journal of Supercomputing*, 73(1): 514-529.
- Haykin, S. 2009.** *Neural networks and learning machines (Vol. 3)*. Upper Saddle River: Pearson education, Ontario. Canada 903 pp.
- He, K., Zhang, X., Ren, S., Sun, J. 2015.** Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *IEEE international conference on computer vision*, 7-13 December 2015, Santiago, Chile.
- Hochreiter, S. 1991.** Untersuchungen zu dynamischen neuronalen Netzen. *Master's Thesis*, Technische Universität München, München, Germany.
- Holzwarth, S., Muller, A., Habermeyer, M., Richter, R., Hausold, A., Thiemann, S., Strobl, P. 2003.** HySens-DAIS 7915/RODIS imaging spectrometers at DLR. 3rd EARSeL Workshop on Imaging Spectroscopy, 13 - 16 May 2003, Germany.
- Hossain, Md.A., Rahman, Md.M., Prodhon, U.K., Khan, Md.F. 2013.** Implementation Of Back-Propagation Neural Network For Isolated Bangla Speech Recognition. *International Journal of Information Sciences and Techniques (IJIST)*, 3(4).
- Hu, W., Huang, Y., Wei, L., Zhang, F., Li, H. 2015.** Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015(2): 1-12.
- Huang, X., Zhang, L. 2009.** A comparative study of spatial approaches for urban mapping using hyperspectral ROSIS images over Pavia City, northern Italy. *International Journal of Remote Sensing*, 30(12): 3205-3221.
- Hughes, G. 1968.** On the mean accuracy of statistical pattern recognizers. *IEEE transactions on information theory*, 14(1): 55-63.
- İnik, Ö., Ülker, E. 2017.** Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3): 85-104.
- Jabbar, H., Khan, D. R. Z. 2015.** Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Computer Science, Communication and Instrumentation Devices*.
- Jimenez-Rodriguez, L. O., Arzuaga-Cruz, E., Velez-Reyes, M. 2007.** Unsupervised linear feature-extraction methods and their effects in the classification of high-dimensional data. *IEEE Transactions on Geoscience and Remote Sensing*, 45(2): 469-483.
- Jin, X., Jie, L., Wang, S., Qi, H., Li, S. 2018.** Classifying wheat hyperspectral pixels of healthy heads and Fusarium head blight disease using a deep neural network in the wild field. *Remote Sensing*, 10(3): 395.
- Kalita, S., Biswas, M. 2018.** Hyperspectral Image Classification Using Modified Convolutional Neural Network. 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS), 14-15 June 2018, Madurai, India.

- Karlik, B., Olgac, A. V. 2011.** Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4): 111-122.
- Khalifa, A. B., Frigui, H. 2016.** Multiple Instance Fuzzy Inference Neural Networks. arXiv preprint arXiv:1610.04973.
- Koturwar, S., Merchant, S. 2017.** Weight initialization of deep neural networks (DNNs) using data statistics. arXiv preprint arXiv:1710.10570.
- Kurt, F. 2018.** Evriřimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi, *Y. Lisans Tez*, HÜ, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Ankara.
- Lee, C., Landgrebe, D. A. 1993.** Analyzing high-dimensional multispectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 31(4): 792-800.
- Lee, J., Weger, R. C., Sengupta, S. K., Welch, R. M. 1990.** A neural network approach to cloud classification. *IEEE Transactions on Geoscience and Remote Sensing*, 28(5): 846-855.
- Li, T., Zhang, J., Zhang, Y. 2014.** Classification of hyperspectral image based on deep belief networks. 2014 IEEE international conference on image processing (ICIP), October 2014, Paris, France.
- Li, Y., Zhang, H., Shen, Q. 2017.** Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sensing*, 9(1): 67.
- Liang, H., Li, Q. 2016.** Hyperspectral imagery classification using sparse representations of convolutional neural network features. *Remote Sensing*, 8(2): 99.
- Liu, W., Wen, Y., Yu, Z., Yang, M. 2016.** Large-margin softmax loss for convolutional neural networks. *ICML*, 2(3): 7.
- Luo, R., Liao, W., Zhang, H., Zhang, L., Scheunders, P., Pi, Y., Philips, W. 2017.** Fusion of Hyperspectral and LiDAR Data for Classification of Cloud-Shadow Mixed Remote Sensed Scene. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8): 3768 – 3781.
- Luo, Y., Zou, J., Yao, C., Zhao, X., Li, T., Bai, G. 2018.** Hsi-cnn: A novel convolution neural network for hyperspectral image. International Conference on Audio, Language and Image Processing (ICALIP), July 2018, Shanghai, China.
- MacKay, D. J. 1998.** Introduction to Gaussian processes. NATO ASI Series F Computer and Systems Sciences, (168): 133-166.
- Makantasis, K., Karantzalos, K., Doulamis, A., Doulamis, N. 2015.** Deep supervised learning for hyperspectral data classification through convolutional neural networks. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 2015, Milan, Italy.
- Manolakis, D., Marden, D., Shaw, G. A. 2003.** Hyperspectral image processing for automatic target detection applications. *Lincoln laboratory journal*, 14(1): 79-116.
- Mei, S., Yuan, X., Ji, J., Zhang, Y., Wan, S., Du, Q. 2017.** Hyperspectral image spatial super-resolution via 3D full convolutional neural network. *Remote Sensing*, 9(11): 1139.

- Melgani, F., Bruzzone, L. 2004.** Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on geoscience and remote sensing*, 42(8): 1778-1790.
- Mercier, G., Lennon, M. 2003.** Support vector machines for hyperspectral image classification with spectral-based kernels. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceeding , 21-25 July 2003, Toulouse, France.
- Mohan, A., Sapiro, G., Bosch, E. 2007.** Spatially coherent nonlinear dimensionality reduction and segmentation of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 4(2): 206-210.
- Morchhale, S. 2016.** Deep convolutional neural networks for classification of fused hyperspectral and LiDAR data, *Master's Thesis*, Department of Computer Science, Wake Forest University California.
- Natrajan, P., Rajmohan, S., Sundaram, S., Natarajan, S., Hebbar, R. 2019.** A Transfer Learning based CNN approach for Classification of Horticulture plantations using Hyperspectral Images. 8th International Advance Computing Conference (IACC), 2018, Nodia, India.
- Orhan, U., Hekim, M., Ozer, M. 2011.** EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. *Expert Systems with Applications*, 38(10): 13475-13481.
- Pal, M., Foody, G. M. 2010.** Feature selection for classification of hyperspectral data by SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 48(5): 2297-2307.
- Paoletti, M. E., Haut, J. M., Plaza, J., Plaza, A. 2018.** A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS journal of photogrammetry and remote sensing*, 145(2018): 120-147.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Vanderplas, J. 2011.** Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 12(Oct): 2825-2830.
- Piotrowski, A.P., Napiorkowski, J.J. 2013.** A comparison of methods to avoid overfitting in neural networks training in the case of catchment runoff modeling. *J. Hydrol.* 476(2013): 97–111.
- Richards, J. A. 2009.** *Remote sensing with imaging radar* (Vol. 1). Heidelberg, Germany, 361 pp.
- Ruder, S. 2016.** An overview of gradient descent optimization algorithms. arXiv preprint arXiv:1609.04747.
- Slavkovikj, V., S. Verstockt, W. D. Neve, S. V. Hoecke, and R. V. Walle. 2015.** Hyperspectral Image Classification with Convolutional Neural Networks."ACM International Conference on Multimedia (ACMMM). Brisbane, 26-30 October, 2015, Brisbane.
- Stutz, D. 2014.** Understanding convolutional neural networks. *Seminar Report*, Fakultät für Mathematik, Informatik und Naturwissenschaften Lehr-und Forschungsgebiet Informatik VIII Computer Vision.

- Sun, D. W. 2010.** Hyperspectral imaging for food quality analysis and control, Elsevier, 496 pp.
- 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.
- van der Aalst, W. M., Rubin, V., Verbeek, H. M. W., van Dongen, B. F., Kindler, E., Günther, C. W. 2010.** Process mining: a two-step approach to balance between underfitting and overfitting. *Software & Systems Modeling*, 9(1): 87-111.
- Vargas, R., Mosavi, A., Ruiz, R. 2017.** Deep learning: a review. *Advances in Intelligent Systems and Computing*, 5(2).
- Villa, A., Benediktsson, J. A., Chanussot, J., Jutten, C. 2011.** Hyperspectral image classification with independent component discriminant analysis. *IEEE transactions on Geoscience and remote sensing*, 49(12): 4865-4876.
- Vorovencii, I. 2009.** The hyperspectral sensors used in satellite and aerial remote sensing. Bulletin of the Transilvania University of Brasov. Forestry, Wood Industry, Agricultural Food Engineering. Series II, 2, 51.
- Wall, M. E., Rechtsteiner, A., Rocha, L. M. 2003.** Singular value decomposition and principal component analysis. A practical approach to microarray data analysis, Ed.: Berrar, D.P., Dubitzky, W., Granzow, M., Springer, Boston, MA, pp: 91-109.
- Wang, S., Wang, C. 2015.** Research on dimension reduction method for hyperspectral remote sensing image based on global mixture coordination factor analysis. 2015 International Workshop on Image and Data Fusion, 21 – 23 July 2015, Kona, Hawaii, USA.
- Wengert, R. E. 1964.** A simple automatic derivative evaluation program. *Communications of the ACM*, 7(8), 463-464.
- Zhao, W., Li, S., Li, A., Zhang, B., Li, Y. 2019.** Hyperspectral images classification with convolutional neural network and textural feature using limited training samples, *Remote Sensing Letters*, 10(5): 449-458.
- Yang, X., Ye, Y., Li, X., Lau, R. Y., Zhang, X., Huang, X. 2018.** Hyperspectral image classification with deep learning models. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9): 5408-5423.
- Yazan, E., Talu, M. F. 2017.** Comparison of the stochastic gradient descent based optimization techniques. International Artificial Intelligence and Data Processing Symposium (IDAP), Malatya, Türkiye.
- Yiğit, A. 2017.** İş süreçlerinde insan görüşünü derin öğrenme ile destekleme, *Yüksek Lisans tezi*, TÜ, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Edirne.
- Yu, S., Jia, S., Xu, C. 2017.** Convolutional neural networks for hyperspectral image classification. *Neurocomputing*, 219(2017): 88-98.
- Yue, J., Mao, S., Li, M. 2016.** A deep learning framework for hyperspectral image classification using spatial pyramid pooling. *Remote Sensing Letters*, 7(9): 875-884.

**Yue, J., Zhao, W., Mao, S., Liu, H. 2015.** Spectral–spatial classification of hyperspectral images using deep convolutional neural networks. *Remote Sensing Letters*, 6(6): 468-477.

**Zhang, L., Zhang, L., Du, B. 2016.** Deep learning for remote sensing data: A technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2): 22-40.

**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.

**Xu, B., Wang, N., Chen, T., Li, M. 2015.** Empirical evaluation of rectified activations in convolutional network. arXiv preprint arXiv:1505.00853.



## ÖZGEÇMİŞ

Adı Soyadı : Gizem ORTAÇ  
Doğum Yeri ve Tarihi : 07/06/1991, Susurluk/BALIKESİR  
Yabancı Dil : İngilizce

Eğitim Durumu  
Lise : Afyon Anadolu Öğretmen Lisesi  
Lisans : Süleyman Demirel Üniversitesi  
Yüksek Lisans : Uludağ Üniversitesi

Çalıştığı Kurum/Kurumlar : Bursa Teknik Üniversitesi

İletişim (e-posta) : gizem.ortac@btu.edu.tr

Yayınları : Ortaç, G., Özcan, G. 2018. A comparative study for hyperspectral data classification with deep learning and dimension reduction techniques, *Uludağ University Journal of The Faculty of Engineering*, 23(3): 73-90.

Ortaç, G., Bilgin, T.T., Özcan, G. 2018. A comparative analysis of dimension reduction techniques for hyperspectral image classification. 7th International Conference on Advanced Technologies, 28 April-1 May 2018, Antalya, TURKEY.