



T.C.
İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA

Fatih Mehmet TEKCAN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

DANIŞMAN

Prof. Dr. Ahmet SERTBAŞ

II. DANIŞMAN

Dr. Öğr. Üyesi Tolga ENSARİ

Haziran, 2018

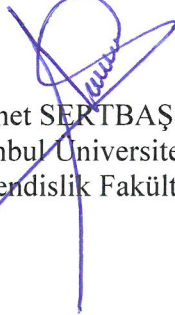
İSTANBUL

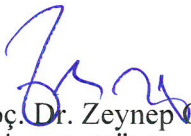
Uygundur

Prof. Dr. Ahmet SERTBAŞ
Bilgisayar Mühendisliği
Bölüm Başkanı

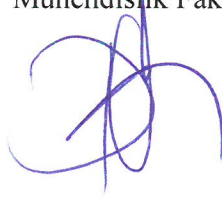
Bu çalışma, 25.06.2018 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

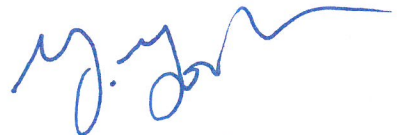
Tez Jürisi


Prof. Dr. Ahmet SERTBAŞ (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi


Doç. Dr. Zeynep ÖRMAN
İstanbul Üniversitesi
Mühendislik Fakültesi


Dr. Öğr. Üyesi Tolga ENSARİ
İstanbul Üniversitesi
Mühendislik Fakültesi


Dr. Öğr. Üyesi Pelin GÖRGEL
İstanbul Üniversitesi
Mühendislik Fakültesi


Dr. Öğr. Üyesi Yusuf YASLAN
İstanbul Teknik Üniversitesi
Bilgisayar ve Bilişim Fakültesi



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Tez çalışmam boyunca destek ve yardımlarını esirgemeyen çok değerli danışman hocalarım Sayın Prof. Dr. Ahmet SERTBAŞ' a ve Sayın Dr. Öğr. Üyesi Tolga ENSARİ' ye teşekkürlerimi sunarım.

Tüm arkadaşlarıma özellikle de bilgisini ve desteğini esirgemeyen değerli arkadaşım Kadir Güzel' e çok teşekkür ederim.

Hayatım boyunca hiçbir zaman desteklerini esirgemeyen ve her zaman yanımda olan kardeşlerim Adem ve Hamza başta olmak üzere tüm aileme sonsuz teşekkür ederim.

Bu tezi çok sevdiğim babama ithaf ediyorum.

Haziran 2018

Fatih Mehmet TEKCAN

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	ix
SİMGE VE KISALTMA LİSTESİ	xi
ÖZET	xiii
SUMMARY.....	xv
1. GİRİŞ.....	1
2. GENEL KISIMLAR	3
2.1 UZAKTAN ALGILAMA	3
2.2 HİPERSPEKTRAL GÖRÜNTÜLEME	4
2.2.1 Hiperspektral Görüntüler	6
2.3 BOYUT İNDİRGEME	9
2.3.1 Temel Bileşen Analizi	9
2.4 SPEKTRAL – UZAMSAL ÖZİNİTELİK ÇIKARMA YÖNTEMLERİ	11
2.4.1 Spektral Yöntem	11
2.4.2 Yerel İkili Örüntü.....	12
2.4.3 Gabor Filtresi	14
2.4.4 Yönlü Gradyant Histogramı.....	15
2.5 SINIFLANDIRMA YÖNTEMLERİ.....	17
2.5.1 Destek Vektör Makineleri.....	18
2.5.2 Evrişimsel Sinir Ağları	22
2.5.2.1 Evrişim Katmanı.....	24
2.5.2.2 Alt Örneklem Katmanı.....	25
2.5.2.3 Dropout Katmanı.....	26
2.5.2.3 Aktivasyon Fonksiyonları.....	27
2.6 METRİKLER.....	28
2.7 LİTERATÜR ÖZETİ.....	31
3. MALZEME VE YÖNTEM.....	34
3.1 VERİ KÜMELERİ	34

3.2 BANT ÇIKARMA	37
3.3 SPEKTRAL – UZAMSAL SINIFLANDIRMA	39
3.5 ÖNERİLEN EVRİŞİMSEL SINIR AĞININ MİMARİSİ	42
4. BULGULAR.....	45
4.1 UZAMSAL ÖZNİTELİK ÇIKARMA YÖNTEMLERİ İÇİN EN UYGUN PARAMETRE DEĞERLERİNİN BELİRLENMESİ	45
4.1.1 Yerel İkili Örüntü Parametre Değerlerinin Belirlenmesi	46
4.1.2 Gabor Filtresi Parametre Değerlerinin Belirlenmesi.....	48
4.1.3 Yönlü Gradyant Histogramı Parametre Değerlerinin Belirlenmesi	49
4.1.4 Spektral ve Uzamsal Sınıflandırma Sonuçları.....	50
4.2 ÖZNİTELİK BİRLEŞTİRME VE KARAR BİRLEŞTİRME YÖNTEMLERİ İLE SINIFLANDIRMA	55
4.3 PERFORMANS DEĞERLENDİRMESİ	60
5. TARTIŞMA VE SONUÇ	64
KAYNAKLAR.....	67
ÖZGEÇMİŞ	72

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Uzaktan algılama genel şeması [1].	3
Şekil 2.2: Elektromanyetik spektrum [2].	5
Şekil 2.3: Hiperspektral görüntüleme düzeneği [3].	6
Şekil 2.4: Hiperspektral görüntü küpü.	6
Şekil 2.5: Hiperspektral görüntüdeki bir pikseldeki maddeye ait spektral imza [4].	7
Şekil 2.6: Pavia University veri kümesindeki her bir sınıfa ait birer piksel için spektral imza örnekleri.	8
Şekil 2.7: Yerel İkili Örüntü değeri hesaplama.	12
Şekil 2.8: Farklı (m,r) YİÖ operatörleri. (m,r) sırasıyla (8,1), (8,2), (16,2).	13
Şekil 2.9: 1 bant HSG' den YİÖ ile öznitelik elde etme adımları.	13
Şekil 2.10: Sırası ile $[0, \pi/8, \pi/4, 3\pi/8, \pi/2, 5\pi/8, 3\pi/4, 7\pi/8]$ açılarındaki 2 boyutlu Gabor çekirdekleri.	15
Şekil 2.11: Yönlü Gradyant Histogramı için Sobel çekirdekleri.	16
Şekil 2.12: HSG 1 bant görüntüsü için YGH ile histogram çıkarma.	17
Şekil 2.13: Yapay Sinir Ağı nöronun genel yapısı [23].	22
Şekil 2.14: 2 gizli katmana sahip ÇKA [24].	23
Şekil 2.15: LeNet-5 ESA ağının yapısı [25].	24
Şekil 2.16: Bir görüntüye 1 filtre uygulanması (üst) ve 6 farklı filtre evrişimin uygulanması (alt) [27].	25
Şekil 2.17: 2x2 filteri ve 2 adım kaydırma ile en büyüğünü örnekleme (Max pooling) örneği.	26
Şekil 2.18: Dropout katmanı içermeyen (a) ve içeren (b) ağ [30].	27
Şekil 3.1: Indian Pines a) 3 bant (43, 21, 11) renkli görüntü b) yer doğrusu c) sınıf renk kodları.	35
Şekil 3.2: Pavia University a) 3 bant (44, 24, 10) renkli görüntü b) yer doğrusu c) sınıf renk kodları.	36

Şekil 3.3: Salinas a) 3 bant (50, 30, 20) renkli görüntü b) yer doğrusu c) sınıf renk kodları	37
Şekil 3.4: Öznitelik Birleştirme (ÖB) ile yöntemi ile spektral-uzamsal HSG sınıflandırma akışı.....	40
Şekil 3.5: Karar Birleştirme (KB) ile yöntemi ile spektral-uzamsal HSG sınıflandırma akışı.....	41
Şekil 3.6: Önerilen ESA mimarisi.....	43
Şekil 4.1: YİÖ pencere boyutlarına göre DVM tüm doğruluk sonuçları.....	47
Şekil 4.2: Gabor Filtresi bant genişliğinin (bw) DVM ile sınıflandırma başarımına etkisi.....	48
Şekil 4.3: YGH hücre boyutunun DVM sınıflandırma başarımına etkisi	50
Şekil 4.4: ESA tur (epoch) sayısının doğruluk-hata grafiği.....	62

TABLO LİSTESİ

	Sayfa No
Tablo 2.1: İki sınıflı sınıflandırma için karışıklık matrisi	29
Tablo 2.2: Çoklu etiket sınıflandırma için karışıklık matrisi [37].....	30
Tablo 3.1: Indian Pines veri kümesine ait sınıflar ve örnekler sayıları.....	34
Tablo 3.2: Pavia University veri kümesine ait sınıflar ve örnekler sayıları.....	35
Tablo 3.3: Salinas veri kümesine ait sınıflar ve örnekler sayıları.....	36
Tablo 3.4: HSG veri kümelerine ait TBA ile elde edilen TB değişinti oranları (%)......	38
Tablo 3.5: Önerilen ESA ağının katmanları.....	44
Tablo 4.1: Eğitim Test Kümesi – 1 (ETK-1).....	46
Tablo 4.2: Pavia University için (m,r) çiftlerine göre DVM ile sınıflandırma doğruluk sonuçları.	47
Tablo 4.3: YİÖ özneliklerinin elde edilmesinde kullanılan parametreler ve değerleri.	48
Tablo 4.4: Veri kümeleri için alınan Gabor Filtresi bant genişliği (bw) değerleri.....	49
Tablo 4.5: Veri kümeleri için alınan YGH hücre boyutları.	49
Tablo 4.6: ETK-1 örnekleri kullanılarak yapılan Indian Pines DVM sınıflandırma sonuçları.	51
Tablo 4.7: ETK-1 örnekleri kullanılarak yapılan Pavia University DVM sınıflandırma sonuçları.	52
Tablo 4.8: ETK-1 örnekleri kullanılarak yapılan Salinas DVM sınıflandırma sonuçları.	52
Tablo 4.9: ETK-1 örnekleri ile Indian Pines DVM sınıflandırma yer doğrusu sonuçları.	53
Tablo 4.10: ETK-1 örnekleri ile Pavia University DVM sınıflandırma yer doğrusu sonuçları.	53
Tablo 4.11: ETK-1 örnekleri ile Salinas DVM sınıflandırma yer doğrusu sonuçları.....	54
Tablo 4.12: Eğitim Test Kümesi – 2 (ETK-2).....	56
Tablo 4.13: Indian Pines ETK-2 örnek sayılarına göre sınıflandırma sonuçları.....	57

Tablo 4.14: Indian Pines DVM ve ESA sınıflandırma yer doğrusu sonuçları.	57
Tablo 4.15: Pavia University ETK-2 örnek sayılarına göre sınıflandırma sonuçları.	58
Tablo 4.16: Pavia University DVM ve ESA sınıflandırma yer doğrusu sonuçları.	59
Tablo 4.17: Salinas ETK-2 örnek sayılarına göre sınıflandırma sonuçları.	59
Tablo 4.18: Salinas DVM ve ESA sınıflandırma yer doğrusu sonuçları.	60
Tablo 4.19: TBA ve uzamsal öznitelik yöntemlerinin 1 bant için saniye cinsinden süreleri.	61
Tablo 4.20: DVM ve ESA ile ÖB(Spekt.-YİÖ-Gabor) sınıflandırmada eğitim ve test süreleri.	61
Tablo 4.21: Indian Pines için alınan eğitim kümesi oranının sınıflandırma başarımına etkisi.	63
Tablo 4.22: Pavia University ve Salinas için alınan örnek sayılarına göre sonuçlar.	63

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
nm	: Nanometre
μm	: Mikrometre
μ	: Aritmetik Ortalama
G	: Gabor Dalgacığı
δ	: Gabor Filtresi Dalga Boyu
θ	: Yönelim açısı
ψ	: Gabor Filtresi faz açısı
σ	: Standart sapma
bw	: Gabor Filtresi uzamsal frekans bant genişliği
γ	: Gabor Filtresi uzamsal en boy oranı

Kısaltmalar	Açıklama
ANN	: Artificial Neural Networks
AVIRIS	: Airborne Visible / Infrared Imaging Spectrometer
CNN	: Convolutional Neural Networks
ÇKA	: Çok Katmanlı Algılayıcı
DF	: Decision Fusion
DVM	: Destek Vektör Makineleri
ESA	: Evrişimsel Sinir Ağları
ETK	: Eğitim Test Kümesi
FF	: Feature Fusion
GF	: Gabor Filtresi
HOG	: Histogram of Oriented Gradients
HSG	: Hiperspektral görüntü
KB	: Karar Birleştirme
LBP	: Local Binary Patterns
LiDAR	: Laser Imaging Detection and Ranging
LOGP	: Logarithmic Opinion Pool
LOP	: Linear Opinion Pool

MLP	: Multilayer Perceptron
OA	: Overall accuracy
ÖB	: Öznitelik birleştirme
PReLU	: Parametric Rectified Linear Unit
RBF	: Radial Basis Function
ReLU	: Rectified Linear Unit
ROSIS	: Reflective Optics System Imaging Spectrometer
SGD	: Stochastic Gradient Descent
SVM	: Support Vector Machines
TB	: Temel Bileşen
TBA	: Temel Bileşen Analizi
TD	: Tüm doğruluk
YGH	: Yönlü Gradyant Histogramı
YİÖ	: Yönlü Gradyant Histogramı
YSA	: Yapay Sinir Ağları

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA

Fatih Mehmet TEKCAN

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Ahmet SERTBAŞ

II. Danışman : Dr. Öğr. Üyesi Tolga ENSARİ

Hiperspektral görüntüler nesnelere yansıyan enerjinin dar ve sürekli aralıklı çok sayıda dalga boyu bandında ölçümü ile edilir. Ölçülen spektral değerler spektral imza niteliğinde olup her bir nesne için ayırt edici bir özellik olmaktadır. Spektral imza kullanılarak nesnelere sınıflandırılması yapılabilmektedir.

Bu tez çalışmasında hiperspektral görüntülerin spektral-uzamsal sınıflandırılmaları üzerinde çalışılmıştır. Spektral bilgilerin yanında hiperspektral görüntüden elde edilecek uzamsal özelliklerin de hiperspektral görüntü sınıflandırmada kullanılması amaçlanmıştır. Hiperspektral görüntüler yüksek boyutlu verilerden oluştuğu için sınıflandırma başarımını ve hesaplama performansını etkilemektedir. Temel Bileşen Analizi boyut indirgeme yöntemi kullanılarak en bilgilendirici ve ayırt edici bantlar elde edilmiştir. Elde edilen bu bant görüntülerinden yüksek bilgiye sahip uzamsal öznitelikler elde edilmiştir. Uzamsal özniteliklerin elde edilmesi için görüntü tanımada yaygın olarak kullanılan Yerel İkili Örnekleme, Gabor Filtresi ve Yönlü Gradyant Histogramı yöntemleri kullanılmıştır.

Elde edilen spektral-uzamsal öznitelikler Destek Vektör Makineleri ve Evrimsel Sinir Ağları ile sınıflandırma yapılmıştır. Öznitelik birleştirme ve karar birleştirme yöntemleri uygulanarak sınıflandırma sonuçları elde edilmiştir. Sınıflandırma deneyleri Indian Pines, Pavia University ve Salinas veri kümeleri ile yapılmıştır. Sınıflandırma sonuçları farklı metrikler ile sunulmuş

ve sonuçlar deęerlendirilmiřtir. Az sayıda bant ve düşük sayıda eęitim örnekleri alınarak yapılan deneylerde spektral ve uzamsal özniteliklerin birlikte kullanılması sınıflandırma başarımını artırdığı görülmüřtür.

Haziran 2018, 88 sayfa.

Anahtar kelimeler: Hiperspektral görüntü, Destek Vektör Makineleri, Evriřimsel Sinir Aęları, Yerel İkili Örüntü, Yönlü Gradyant Histogramı



SUMMARY

M.Sc. THESIS

HYPERSPECTRAL IMAGE CLASSIFICATION WITH MACHINE LEARNING

Fatih Mehmet TEKCAN

İstanbul University

Institute of Graduate Studies in Science and Engineering

Department of Computer Engineering

Supervisor : Prof. Dr. Ahmet SERTBAŞ

Co-Supervisor : Assist. Prof. Dr. Tolga ENSARİ

Hyperspectral images are obtained by measuring the energy reflected from objects in multiple wavelength bands with narrow and continuous intervals. The measured spectral values are spectral signature and are a distinguishing feature for each object. Classification of objects can be done using spectral signature.

In this thesis, spectral-spatial classification of hyperspectral images has been studied. Beside spectral information, it is aimed to use the spatial features obtained from the hyperspectral image in hyperspectral classification image. Because hyperspectral images are composed of high-dimensional data, they affect classification performance and computational performance. The most informative and distinctive bands were obtained using the Principal Component Analysis dimensionality reduction method. Then spatial features with higher information were obtained from this band images. In order to extract spatial features, Local Binary Pattern, Gabor Filter and Histogram of Oriented Gradients methods which are widely used in pattern recognition have been used.

Spectral - spatial features were classified by using Support Vector Machines and Convolutional Neural Networks. Classification results were obtained with feature fusion and decision fusion

methods. For classification experiments, Indian Pines, Pavia University and Salinas data sets were used. The classification results are presented with different metrics and the results are evaluated. It has been seen that the use of spectral and spatial features together with few bands and low number of training samples increase the classification accuracy.

June 2018, 88 pages.

Keywords: Hyperspectral image, Support Vector Machines, Convolutional Neural Networks, Local Binary Patterns, Histogram of Oriented Gradients



1. GİRİŞ

Hiperspektral görüntüler dar bantlı ve sürekli aralıklı çok sayıdaki spektral banttan oluşmaktadır ve uzaktan algılama yöntemlerinden olan hiperspektral görüntüleme ile elde edilmektedir. Hiperspektral görüntüdeki her bir piksel için ölçüm yapılan bandın dalga boyuna bağlı olarak elde edilen spektral değerler her bir madde için ayırt edici bir özellik taşımaktadır. Bir piksel için tüm bantlardaki dalga boylarında ölçülen bu değerler o pikseldeki nesnenin spektral imzasını oluşturmaktadır. Spektral imza kullanılarak görüntünün sınıflandırılması ve nesnelerin belirlenmesi gibi birçok amaç için kullanılır. Hiperspektral görüntüler sağladıkları yüksek bilgi sayesinde günümüzde tarım, ormancılık, jeoloji ve askeri sistemler gibi birçok alanda kullanılmaktadır.

Hiperspektral görüntülerin sınıflandırılması hiperspektral algılayıcıların yaygın olarak farklı amaçlarla kullanılması ile ayrı bir önem kazanmaktadır. Sınıflandırma yapmak için geleneksel sınıflandırıcıların yanı sıra son zamanlarda grafik işlemcilerinin yüksek hesaplama güçlerinin etkisi ile derin öğrenme yaklaşımları sıklıkla kullanılmıştır. Hiperspektral görüntüler yüksek boyutlu verilerden oluştuğu için sınıflandırma başarımını ve hesaplama performansını etkilemektedir. Bu nedenle sınıflandırma öncesinde ön işlem olarak hiperspektral görüntüde boyut indirilmesi yapılmaktadır. Sadece spektral bilgiler kullanılarak sınıflandırma başarımı yeterli oranda olamayabilir. Bu nedenle hiperspektral görüntü sınıflandırmada hiperspektral görüntünün uzamsal boyutundaki piksellere ait uzamsal öznitelikler de kullanılarak sınıflandırma yapmak sınıflandırma başarımını artırmaktadır. Uzamsal öznitelikler için görüntü sınıflandırmada kullanılan yöntemler, temel çalışma prensipleri korunarak hiperspektral görüntü sınıflandırma için uygun şekilde uygulanabilmektedir.

Hiperspektral görüntü sınıflandırmada piksel tabanlı bir sınıflandırma yapılmaktadır yani hiperspektral görüntüdeki sınıflandırmaya dahil edilecek her bir pikselin ait olduğu sınıf belirlenmektedir. Bu nedenle her bir piksel sınıflandırma için bir giriş örneği olmaktadır. Her bir örneğin özniteliklerini ise hiperspektral görüntüdeki bantların spektral değerleri oluşturmaktadır.

Hiperspektral görüntüler uzaktan algılama yöntemleri ile edilmektedir. Sınıflandırma probleminin ve sınıflandırmada kullanılacak hiperspektral görüntünün veri yapısının daha iyi

anlaşılabilmesi için uzaktan algılama ve hiperspektral görüntüler Bölüm 2' de anlatılmıştır. Yine bu bölümde yüksek boyut problemini aşmak için kullanılan yöntemlerden ve sınıflandırma başarımını artırmak için uzamsal öznitelik çıkarım yöntemlerinden bahsedilmiştir. Son olarak çalışmada kullanılan sınıflandırma yöntemlerine, sınıflandırma başarımlarını değerlendirmek için kullanılan metriklere ve literatür özetine yine bu bölümde yer verilmiştir.

Çalışma kapsamındaki deneylerde kullanılacak hiperspektral görüntü veri kümeleri ve bu veri kümelerinden boyut indirgeme amaçlı bant çıkarım işlemleri Bölüm 3' te anlatılmıştır. Yine bu bölümde önerdiğimiz spektral ve uzamsal öznitelikler kullanılarak sınıflandırma yapma aşamaları bu bölümde anlatılmış ve genel şeması verilmiştir.

Farklı veri kümeleri üzerinde yapılan sınıflandırma sonuçları ve değerlendirmeler Bölüm 4' te verilmiştir.


Son bölümde ise yapılan çalışmanın sonuçları üzerinde bir değerlendirme yapılmıştır.

2. GENEL KISIMLAR

2.1 UZAKTAN ALGILAMA

Uzaktan algılama, bir nesneye herhangi fiziksel temas olmadan algılanan nesne ile ilgili bilgi elde etme ve bu bilgileri değerlendirme bilimi olarak tanımlanmaktadır. Nesneye ait bu bilgiler elektromanyetik spektrumun belirli bant aralıklarında hava araçları veya uydular aracılığı ile ölçülmesi sonucunda elde edilirler. Bu sayede yeryüzünde fiziksel olarak ulaşılması zor bölgelerin görüntülenmesi veya nesneye ait gözle görülemeyen özelliklerin elde edilmesi sağlanmış olur.

Bir nesneye ulaşan elektromanyetik enerjinin bir kısmı nesne tarafından emilmekte bir kısmı ise nesneden yansımaktadır. Uzaktan algılamada nesnelere bilgi elde etmenin temelinde bu nesnelere yansıyan elektromanyetik enerjinin hava araçlarında veya uydularda bulunan algılayıcılar ile ölçülmesi yatmaktadır. Ölçülen bu değerler sayısal verilere dönüştürülerek yer istasyonlarına aktarılır. Şekil 2.1’de uzaktan algılamanın genel şeması gösterilmektedir.



Şekil 2.1: Uzaktan algılama genel şeması [1].

Uzaktan algılama algılayıcıların kullandıkları enerjiye göre pasif uzaktan algılama ve aktif uzaktan algılama olarak iki sınıfa ayrılmaktadır. Aktif uzaktan algılamada algılayıcının bulunduğu platformdan veya herhangi bir kaynaktan ilgili nesneye enerji gönderilir ve algılayıcı ile yansıyan enerji ölçülerek veri elde edilir. Radarlar ve LiDAR aktif uzaktan

algılamaya örnek olarak verilebilir. Pasif uzaktan algılamada ise güneş enerjisinden faydalanılır ve yansıyan güneş enerjisi algılayıcı ile ölçülerek veri elde edilir.


Nesnelerden yansıyan elektromanyetik enerji her bir maddeye özgü olmaktadır. Bu nedenle nesneden yansıyan enerjinin bu kısmı, elektromanyetik spektrumda o nesneye ait spektral imzasını oluşturmaktadır. Spektral imza her bir maddeye özgü olduğundan nesnelerin ayırt edilmesi ve tanınması mümkün hale gelmektedir.

Uzaktan algılama alanındaki gelişmeler arttıkça elde edilen verilerin çeşitliliği artmakta ve dolayısı ile bu verilerin kullanım alanları ve amaçları da çeşitlilik kazanmaktadır. Uzaktan algılama teknolojisi jeoloji, tarım, ormancılık, uzay bilimleri, atmosfer gözlemleme ve askeri uygulamalar gibi birçok alanda aktif olarak kullanılmaktadır.

2.2 HİPERSPEKTRAL GÖRÜNTÜLEME


Hiperspektral görüntüleme nesnelere yansıyan enerjinin dar ve bitişik çok sayıda dalga boyu bandında ölçümü olarak tanımlanmaktadır. Görüntüleme spektrometresi olarak da adlandırılmaktadır. Hiperspektral görüntüleme uzaktan algılama yöntemlerinden olan pasif uzaktan algılama yöntemine dayanmaktadır. Hiperspektral görüntüleme nesnelere yansıyan ışığın ölçülmesinden yararlanır. Her bir madde kendine özgü yansıtma özelliği olduğundan ölçülen yansıtma değerleri nesnelere için ayırt edici olmaktadır.

Uzaktan algılamada elektromanyetik spektrumun (tayfın) optik bölgesi olarak adlandırılan 0.4µm ile 14µm dalga boyunu içeren aralığı kullanılır. Elektromanyetik spektrum dalga boyları Şekil 2.2 'de gösterilmektedir. Hiperspektral görüntüleme ise elektromanyetik spektrumun 0.4 – 2.5µm dalga boyu aralığı kullanılmaktadır. Bu bölge elektromanyetik spektrumun görünür bölge, yakın kızıl ötesi ve orta kızıl ötesi bölgelerini kapsamaktadır. Hiperspektral görüntüleme bant genişlikleri 10nm – 20nm arasında değişmekte olup yüzlerce dalga boyunda ölçümler yapılmaktadır.



Şekil 2.2: Elektromanyetik spektrum [2].

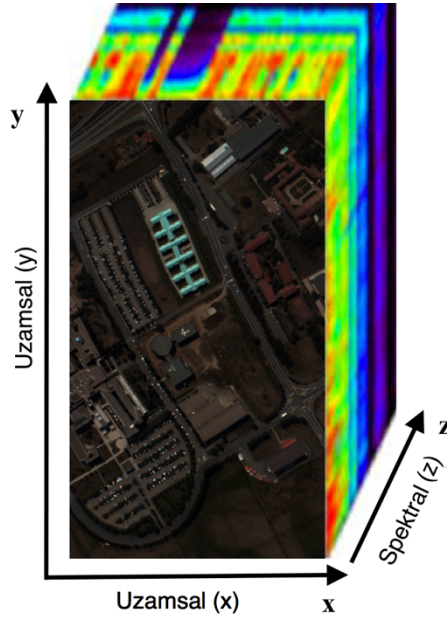
Hiperspektral görüntüleme, spektrometre ya da spektrometre adı verilen cihazlarla yapılmaktadır. Bu cihazlar yardımı ile nesnelere yansıyan ışık nanometreler seviyesindeki dalga boyu aralıkları ile ölçülebilir. Spektrometre içindeki prizmaya benzer optik bileşen, spektrometreye ulaşan ışığı dar ve birbirini takip eden çok sayıda dalga boyu bandına ayırır. Yüzeyden gelen enerji her bir bant için ayrı bir algılayıcı ile ölçülür. Spektrometre, 0,01 mikrometreye kadar dar aralıklarda ve 0,4 – 2,5 μ m gibi geniş bir spektrum için ölçüm yapabilir [3].



Şekil 2.3: Hiperspektral görüntüleme düzeneği [3].

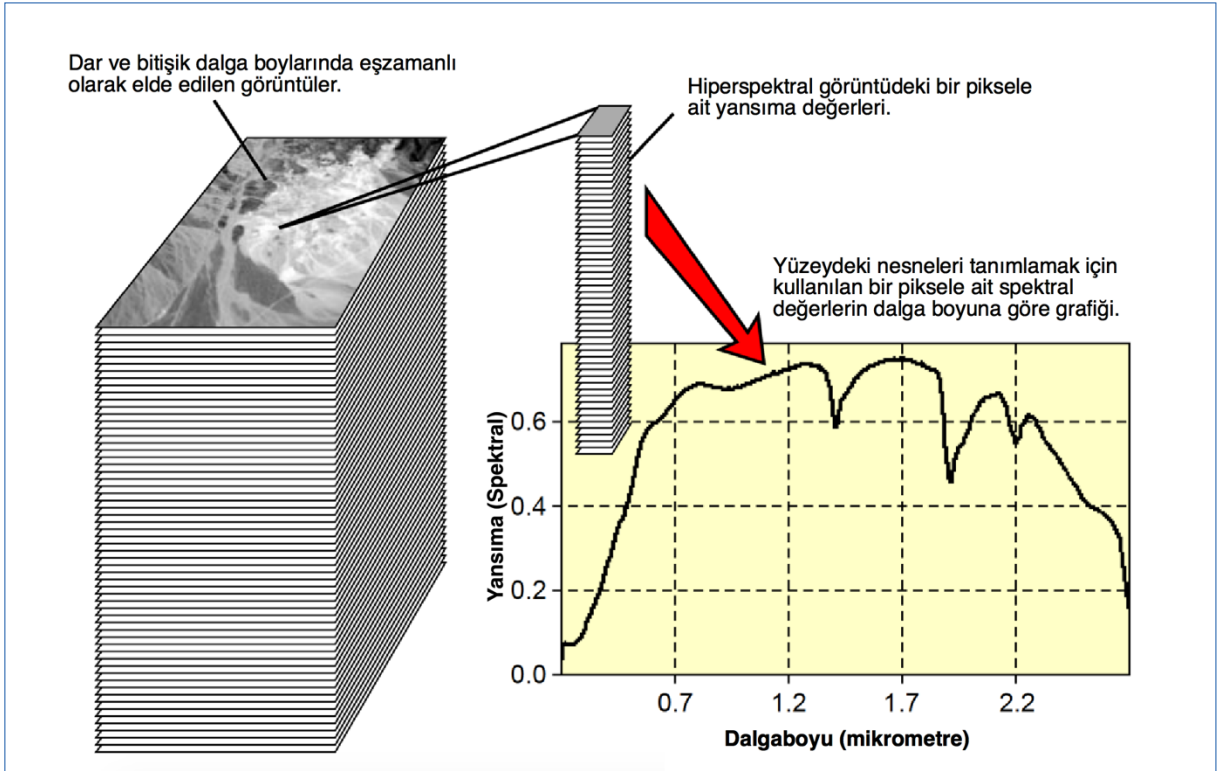
2.2.1 Hiperspektral Görüntüler

Hiperspektral görüntüleme ile elde edilen görüntüler, hiperspektral görüntü (HSG), nesnelere ait spektral bilgileri içermektedir. Hiperspektral görüntülerde, görüntü 3 boyutlu bir veri içermektedir ve bu veri hiper-küp olarak adlandırılmaktadır. Hiperspektral görüntü verisindeki ilk 2 boyut uzamsal çözünürlüğü ifade ederken 3. boyut spektral bant sayısını ifade etmektedir. Şekil 2.4'te örnek bir hiperspektral görüntü küpü gösterilmiştir.



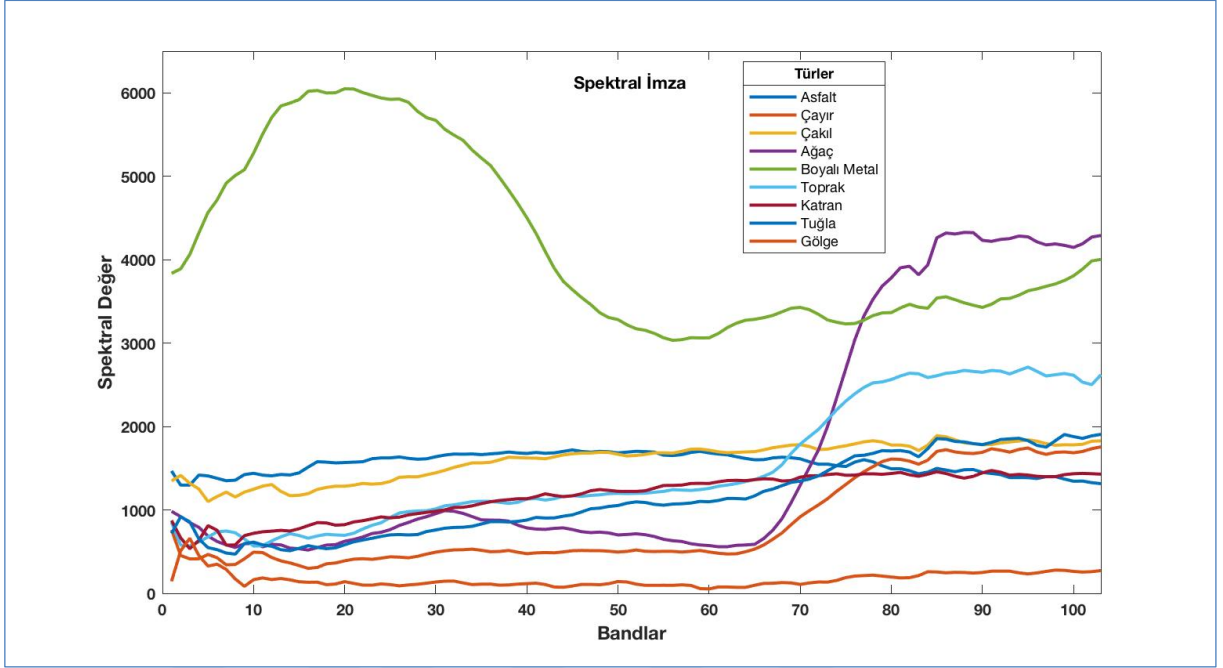
Şekil 2.4: Hiperspektral görüntü küpü.

Hiperspektral görüntüdeki her bir piksel için elde edilen spektral değerler her bir madde için ayırt edici bir özellik taşımaktadır. Yüzeydeki aynı türden nesnelerin veya maddelerin ölçülen spektral değerleri tamamen aynı olmasa da birbirlerine çok yakın değerler içermektedir. Bu nedenle farklı türden maddeler için ölçülen spektral değerler o madde için özeldir ve madde için parmak izi niteliğindedir. Bu nedenle maddeye ait spektral değerler “spektral imza” olarak adlandırılmaktadır. Şekil 2.5’te hiperspektral görüntünün bir pikselindeki maddeye ait spektral yansıma değerlerinden oluşan spektral imza grafiği gösterilmiştir.



Şekil 2.5: Hiperspektral görüntüdeki bir pikseldeki maddeye ait spektral imza [4].

Şekil 2.6’da Pavia University [5] hiperspektral görüntüsündeki farklı her bir sınıfa ait birer piksel için spektral imza grafiği örnekleri gösterilmiştir. Şekilde 2.6’ da görüldüğü üzere her bir madde türü için oluşan spektral imza grafiği sınıf türüne özgü oluşmuştur. Hiperspektral görüntüdeki nesnelerin sınıflandırılması gibi birçok uygulamada spektral imzalardan yararlanılmaktadır.



Şekil 2.6: Pavia University veri kümesindeki her bir sınıfa ait birer piksel için spektral imza örnekleri.

Hiperspektral görüntüler, zengin ve anlamlı bilgiler içerdikleri için birçok alanda aktif olarak kullanılmaktadır. Spektral imza gibi nesnelere belirleyici bilgileri içermesi nedeniyle özellikle sınıflandırma çalışmalarında yaygın olarak kullanılmaktadır. Hiperspektral görüntülerin kullanıldığı uygulama alanlarından bazıları aşağıdaki gibi sıralanabilir:

- Uzaktan algılama alanlarında,
- Ormancılık, tarım arazilerinin ve bitkilerinin izlenmesi çalışmalarında,
- Adli Tıp, Biyoteknoloji ve Medikal Bilimler alanlarında,
- Askeri alanda, savunma, hedef tespiti, hedef tanıma ve savunma gibi uygulamalarda,
- Jeoloji ve madencilik alanlarında,
- Astronomi, uzay bilimleri alanlarında,
- Kimyasal ve çevresel olay çalışmalarında.

2.3 BOYUT İNDİRGEME

HSG' ler yüksek sayıda bant içerdiği için sınıflandırma performansını ve başarımını etkilemektedir. Bu nedenle sınıflandırma öncesi yer, süre ve sınıflandırma başarımı açısından boyut indirgemenin yapılması gerekmektedir. Boyut indirgeme işlemi orijinal veriyi tamamen veya büyük oranda temsil edecek şekilde orijinal veri boyutunun azaltılması olarak tanımlanır. İndirgenen verinin orijinal veriyi temsil etme oranının yüksek olması sınıflandırma başarımı açısından önemlidir. Yüksek boyutlu verilerde az sayıda eğitim örneği ile yapılan sınıflandırma işleminde veri boyutundaki artış belli belirli bir boyuttan sonra sınıflandırma başarımının düştüğünü göstermektedir [6] ve bu davranış Hughes olgusu [7] olarak adlandırılmaktadır. HSG' ler çok sayıda spektral banttan oluştuğu için bu yüksek miktardaki boyut problemi HSG sınıflandırmada da sorun olarak ortaya çıkmaktadır. Bu durum az sayıdaki eğitim kümesi ve çok sayıdaki spektral bant verilerinin sınıflandırılmasında eğitim kümesinin aşırı uydurulması (overfitting) riski oluşmaktadır [8]. HSG' lerde boyut indirgeme bant seçme (bant selection) ve bant çıkarma (bant extraction) olmak üzere iki farklı yöntem ile yapılmaktadır [9]. Bant seçme yönteminde orijinal veri korunarak en bilgilendirici ve en ayırt edici bantlar seçilerek boyut indirgeme yapılır. Bant çıkarma yönteminde veri doğrusal veya doğrusal olmayan yöntemler ile farklı bir uzaya taşınarak boyut indirgeme yapıldığı için elde edilen veri orijinal veriden farklı olmaktadır. Her iki yaklaşımda birbiri ile yüksek ilintili yani birbiri ile yüksek kovaryansa sahip bantları gruplayarak değişiminin yüksek olduğu en ayırt edici ve bilgilendirici bantlar seçilir. Bant seçimi ve bant çıkarımı yöntemlerinin geniş özeti [6]' da yer almaktadır. [10] ve [11]' de hiperspektral verilerde boyut indirgeme yöntemleri detaylı olarak anlatılmış ve yöntemlerin sınıflandırmadaki başarımları kıyaslanmıştır. Bu tez çalışmasında bant çıkarma yöntemi olarak sınıflandırma çalışmalarında boyut indirgemedede sıklıkla kullanılan Temel Bileşen Analizi yöntemi kullanılmıştır.

2.3.1 Temel Bileşen Analizi

Temel Bileşen Analizi (TBA) [12], özellikle yüksek boyutlu verilerde kullanılan denetimsiz ve doğrusal bir boyut indirgeme yöntemidir. TBA' inde temel amaç, çok değişkenli verilerin boyutsallığını azaltmak ve mümkün olduğunca ilgili bilgileri yüksek oranda korumaktır. Bunu yaparken en bilgilendirici ve ayırt edici özellikleri bulmaya çalışır. Bunun için ilintisi (kovaryans) yüksek olan özellikleri gruplayıp değişintisi yüksek olan özellikleri çıkarmaktadır.

Yüksek boyutlu verideki özellikler doğrusal bir yaklaşım ile farklı bir uzaya taşınır ve bu uzaydaki deęişintisi daha yüksek olan özellikler öncelikli temel bileşenler olmaktadır.

TBA uygulanırken hiperspektral 3 boyutlu bir veri küpü 2 boyutlu bir veri küpü olarak düşünülüp işlemler yapılabilir. d sayıda spektral banda sahip $(w \times h \times d)$, (genişlik \times yükseklik \times bant sayısı), boyutlu X hiper-küpü (w^*h,d) Eşitlik 2.1'deki gibi iki boyutlu Y matrisi olarak tanımlanabilir. N HSG' deki toplam piksel sayısını, μ bütün piksellerin değerlerinin ortalamasını, A iz düşüm matrisini, C ise Y matrisine ait $d \times d$ boyutundaki kovaryans matrisini ifade etmektedir. Kovaryans matrisinden d sayıda öz değerler ve öz vektörler elde edilip öz değerler büyükten küçüğe doğru sıralanırken öz vektörler de buna baęlı olarak sıralanır. Böylece en büyük öz değere sahip öz vektör giriş verisinin ilk temel bileşeni olur. m sayıda temel bileşen için $d \times m$ boyutunda öz vektörlerden oluşan A iz düşüm matrisi kullanılarak Eşitlik 2.4 ile boyut indirgenmiş $N \times m$ boyutlu Z matrisi elde edilir.

$$Y = \{(\mathbf{x}_1, \dots, \mathbf{x}_N), \mathbf{x}_i \in \mathbf{R}^d, i = 1, 2, \dots, N\} \quad (2.1)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \quad (2.2)$$

$$C = \frac{1}{N-1} \sum_{i=1}^N (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^T \quad (2.3)$$

$$Z = A^T(Y - \mu) \quad (2.4)$$

TBA, d boyutlu bir veriyi m boyutlu ($m < d$) yeni bir veriye indirgemek için aşağıdaki işlem adımlarını uygular [8].

- Verinin ortalaması hesaplanarak ortalama kendisinden çıkarılır.
- Kovaryans matrisi hesaplanır, elde edilen kovaryans matrisi $d \times d$ boyutundadır.
- Kovaryans matrisinin özdeęer ve özvektörleri hesaplanır.
- Özdeęerler büyükten küçüğe doğru sıralanır. Özdeęerlere baęlı olarak özvektörler de sıralanır.

- En yüksek m sayıdaki özdeğere karşılık gelen özvektörün transpozu alınır ve ortalaması çıkarılmış veri ile çarpılır. Elde edilen veri m boyutlu indirgenmiş veri olur.

2.4 SPEKTRAL – UZAMSAL ÖZİNİTELİK ÇIKARMA YÖNTEMLERİ

Hiperspektral görüntü (HSG) spektral değerleri içeren çok sayıda banttaki görüntülerden oluşmaktadır. Hiperspektral görüntülerin sınıflandırılmasında spektral değerlerin yanı sıra uzamsal özneliklerden de faydalanılabilir. Uzamsal öznelikler her bir bant görüntüsüne çeşitli morfolojik, yerel ve genel görüntü işleme yöntemleri uygulanarak elde edilebilir. Uzamsal öznelik çıkarma yöntemleri olarak Yerel İkili Örneği (YİÖ), Gabor Filtresi (GF) ve Yönlü Gradyant Histogramı (YGH) kullanılmıştır. Spektral ve uzamsal öznelik çıkarma yöntemleri sırası ile anlatılmaktadır.

2.4.1 Spektral Yöntem


HSG' de bant sayısı fazla olduğundan sınıflandırmada kullanılacak spektral öznelik boyutu da fazla olmaktadır. Veri boyutunu azaltmak için sadece en ayırt edici ve bilgilendirici bantlar kullanılabilir. Bunun için bant seçimi veya bant transformasyonu (bant çıkarma) yöntemleri kullanılmaktadır. HSG' den bant çıkarmak için yaygın olarak Temel Bileşen Analizi (TBA) [12] kullanılmakta ve elde edilen bant verileri spektral öznelik olarak sınıflandırma işleminde kullanılmaktadır. HSG 3 boyutlu bir veri kümesinin boyutları (w,h,d) olsun (w görüntünün genişlik piksel sayısı, h görüntünün yükseklik piksel sayısı, d HSG' nün bant sayısı). Görüntüdeki her piksel sınıflandırılacak her bir girişi örneği olarak değerlendirilir. Bu nedenle HSG' de tüm pikseller sınıflandırmaya dahil edildiğinde toplam örnek sayısı $(w*h)$ olmaktadır. 3 boyutlu veri 2 boyutlu $(w*h, d)$ olarak düşünülür. Her bir örnek için TBA ile öznelik seçimi bu 2 boyutlu veriden elde edilir.

2.4.2 Yerel İkili Örüntü

Yerel İkili Örüntü (Local Binary Patterns - LBP) [13], görüntü işleme ve sınıflandırma alanlarında oldukça yaygın olarak kullanılmakta olan ve hesaplama maliyeti düşük bir yöntemdir. YİÖ operatörü, görüntünün dönmesinden bağımsızdır ve yerel komşuluk değerlerine dayalı olarak öznelik çıkarımı yapmaktadır. YİÖ operatörü bir piksele belli uzaklıkta ve sayıda komşuluğundaki piksellerin değerleri ile kıyaslanmasını sağlar. YİÖ' ye ait denklem Eşitlik 2.5 ve Eşitlik 2.6' da verilmiştir.


$$YIO_{m,r}(x_c) = \sum_{i=0}^{m-1} u(x_i - x_c) 2^i \quad (2.5)$$

$$u(y) = \begin{cases} 1, & y \geq 0 \\ 0, & y < 0 \end{cases} \quad (2.6)$$




Şekil 2.7: Yerel İkili Örüntü değeri hesaplama.

YİÖ değerinin hesaplama işlemi Şekil 2.7' de gösterilmiştir. Şekil 2.7' deki örnek dikkate alındığında, merkez pikselin 3x3 komşuluğundaki piksellerin değerleri ile kıyaslanarak ikili bir kod elde edilir. Elde edilen bu kod onluk tabana çevrilir ve merkez pikselin değeri olarak belirlenir. Komşuluk nokta sayısı ve merkeze uzaklık çifti (m,r) olarak belirlenir. m komşu piksel sayısı, r merkez piksele uzaklık, X_i komşu pikselleri, X_c merkez piksel olarak ifade edilmiştir. YİÖ için ele alınan komşuluk nokta sayısı olan m aslında üretilecek ikili koddaki bit sayısını vermektedir.



Şekil 2.8: Farklı (m,r) YİÖ operatörleri. (m,r) sırasıyla (8,1), (8,2), (16,2).



Şekil 2.9: 1 bant HSG' den YİÖ ile öznelik elde etme adımları.

YİÖ operatörü uygulandıktan sonra elde edilen ikili kod dairesel olarak ele alındığında koddaki 1-0 ya da 0-1 geçiş sayısı en fazla 2 olan kodlar düzgün YİÖ' yü oluştururlar [14]. 8 bitlik bir kod için $2^8 = 256$ farklı değer oluşurken bunlardan sadece 58 tanesi geçiş sayısı kuralına uymakta iken 198 tanesi bu kurala uymamaktadır. YİÖ ile etiketlenen görüntü üzerindeki değerlerin dağılımlarını belirlemek için ikili bit geçiş kuralı dikkate alınmak kaydı ile histogram kullanılır [15]. YİÖ histogramı oluşturulurken her bir düzenli örüntü için histogramda ayrı ayrı etiketler bulunurken düzgün olmayan diğer tüm örüntüler için histogramda ortak tek bir etiket

bulunur. Dolayısı ile bir görüntü için m komşuluk sayısı 8 olarak alındığında oluşan 256 koddan 58 tanesi düzenli, 198 tanesi düzensiz kod olduğu için histogramdaki etiket sayısı 59 ($58 + 1$) olarak elde edilir ve bu histogram HSG sınıflandırmada öznitelik olarak ele alınır. Genel olarak histogram özellik sayısı $(m \times (m-1) + 3)$ formülü ile elde edilir.

HSG' de her bir banttaki görüntüye YİÖ operatörü uygulanarak uzamsal öznitelik çıkarımı yapılabilir [16]. HSG sınıflandırma piksel bazlı sınıflandırma olduğu için YİÖ görüntüden elde edilen genel histogram HSG sınıflandırma için bir anlam ifade etmez. Bu nedenle HSG' deki her bir piksel için ayrı ayrı yerel histogram oluşturmak gerekmektedir. Her bir piksel için yerel histogram elde etmek için ilgili pikselin çevresindeki $(k \times k)$ boyutlu çerçevedeki piksellerin YİÖ değerleri dikkate alınarak histogram hesaplaması yapılır. Aslında ele alınan $(k \times k)$ boyutlu çerçeve ayrı bir görüntü gibi varsayılarak histogram elde edilir. Böylece HSG' deki her bir piksel için elde edilen yerel histogramlar piksel için öznitelik olarak ele alınır. HSG sınıflandırmada YİÖ elde etmek için kullanılan (m, r) parametreleri sınıflandırma başarısı açısından önemlidir. Bu nedenle en uygun (m, r) çiftinin seçilmesi gerekmektedir. Farklı (m, r) YİÖ operatör çiftleri Şekil 2.8' de gösterilmiştir.

2.4.3 Gabor Filtresi

Gabor Filtresi HSG sınıflandırmada sıkça kullanılan bir filtre haline gelmiştir. Filtredeki açı ve dalga boyu parametrik olduğu için istenilen yöndeki desenler elde edilebilmektedir. İki boyutlu (a, b) koordinat sistemindeki gerçek ve sanal bileşenleri içeren G Gabor dalgacığının genel denklemi Eşitlik 2.7' de verilmiştir.

$$G_{\delta, \theta, \psi, \sigma, \gamma}(a, b) = \exp\left(-\frac{a'^2 + \gamma^2 b'^2}{2\sigma^2}\right) \exp\left(j\left(2\pi \frac{a'}{\delta} + \psi\right)\right) \quad (2.7)$$

$$a' = a \cos \theta + b \sin \theta \quad (2.8)$$

$$b' = -a \sin \theta + b \cos \theta \quad (2.9)$$


$$\sigma = \frac{\delta}{\pi} \sqrt{\frac{\ln 2}{2} \frac{2^{bw} + 1}{2^{bw} - 1}} \quad (2.10)$$

Gabor Filtresinin gerçek ve sanal kısımları ise Eşitlik 2.11 ve Eşitlik 2.12' de verilmiştir.

$$\mathbf{G}_{\delta,\theta,\psi,\sigma,\gamma}(a,b) = \exp\left(-\frac{a'^2 + \gamma^2 b'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{a'}{\delta} + \psi\right) \quad (2.11)$$

$$\mathbf{G}_{\delta,\theta,\psi,\sigma,\gamma}(a,b) = \exp\left(-\frac{a'^2 + \gamma^2 b'^2}{2\sigma^2}\right) \sin\left(2\pi \frac{a'}{\delta} + \psi\right) \quad (2.12)$$

Burada, (a,b) görüntüdeki pikselin koordinatını, δ dalga boyunu, θ yönelim ayırma açısını, ψ faz açısını, σ standart sapmayı, bw uzamsal frekans bant genişliğini göstermektedir. Yapılan çalışmada θ yönelim açısı için $[0, \pi/8, \pi/4, 3\pi/8, \pi/2, 5\pi/8, 3\pi/4, 7\pi/8]$ değerleri alınmıştır. γ uzamsal en-boy oranı için $\gamma = 0.5$ varsayılan değeri ve δ dalga boyu için ise $\delta = 16$ olarak alınmıştır [17]. $\psi = 0$ ve $\psi = \pi/2$ değerleri için Gabor Filtresinin gerçek ve sanal kısımları elde edilir.




Şekil 2.10: Sırası ile $[0, \pi/8, \pi/4, 3\pi/8, \pi/2, 5\pi/8, 3\pi/4, 7\pi/8]$ açılarındaki 2 boyutlu Gabor çekirdekleri.

2.4.4 Yönlü Gradyant Histogramı

Yönlü Gradyant Histogramı (YGH) (Histogram of Oriented Gradients - HOG), [18], görüntüdeki nesnelere belirlemede kullanılan özellik tanımlayıcı bir yöntemdir. Bu yöntemde yerel bir bölgedeki eğim yönlerinin histogramı çıkarılır ve bu histogram yerel bölge için özellik olarak kullanılır. Bu yöntemde hem eğim yönü hem de eğim büyüklüğü dikkate alındığı için elde edilen histogram nesnelere belirlenmesinde etkili olmaktadır. YGH bir görüntünün

hücelere ve bloklara bölündükten sonra her bir bloktaki yön vektörlerinin açısal değerinin histogramı çıkarılması mantığına dayanır.



Şekil 2.11: Yönlü Gradyant Histogramı için Sobel çekirdekleri.

$$I_x = I * S_x \quad (2.13)$$

$$I_y = I * S_y \quad (2.14)$$

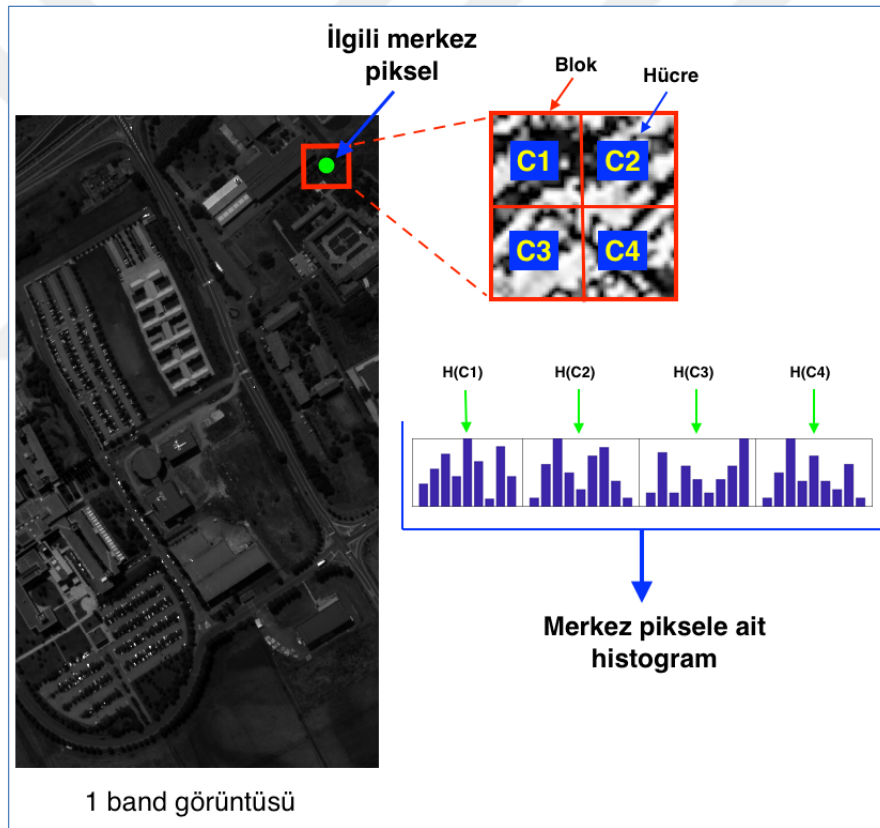
$$s = \sqrt{I_x^2 + I_y^2} \quad (2.15)$$

$$\theta = \tan^{-1} \frac{I_y}{I_x} \quad (2.16)$$

s eğim büyüklüğü fonksiyonunu, θ eğim yönü fonksiyonunu, S_x ve S_y çekirdek matrislerini, I ise görüntüyü ifade etmektedir. YGH hesaplama için Şekil 2.11' de gösterilen çekirdekler S_x ve S_y , I görüntüsüne ayrı ayrı olarak uygulanır. Elde yeni görüntüler ile eğim büyüklüğü Eşitlik 2.15, eğim yönü ise Eşitlik 2.16 ile hesaplanır. Daha sonra görüntü 8×8 piksel boyutunda hücelere ve 2×2 hücre boyutunda bloklara ayrılır. $0-\pi$ veya $0-2\pi$ aralığında eşit aralıklarla K sayıda açı değerleri belirlenir ve bu açı değerlerine karşılık gelen eğim büyüklükleri hesaplanarak her bir hücre için hücre histogramı hesaplanır. Blok içindeki tüm hücreler için histogramlar hesaplanır ve tüm hücre histogramları birleştirilerek tek bir blok histogramı elde edilir. Bu işlem görüntüdeki tüm bloklar için uygulanarak görüntüye ait gradyan histogramı elde edilir.

HSG üzerinde piksel bazlı sınıflandırma yapıldığı için her piksele ait YGH elde etmek gerekmektedir. Bunun için ilgili piksel (merkez piksel) $W \times W$ boyutunda pencere ile görüntüden alt görüntü alınır. Alınan alt görüntüden merkez piksel için YGH elde edilir.

Örneğin 16x16 boyutunda pencere ile merkez piksel için alt görüntü oluşturulur. Daha sonra bu görüntü 8x8 hücreler ve 2x2 bloklar kullanılarak her bir blok için bir tane olmak üzere toplam 4 farklı histogram elde edilir ve bu histogramlar ele alınan pencere boyutu için birleştirilerek tek bir histogram elde edilir. Histogram [0, 20, 40, 60, 80, 100, 120, 140, 160] olmak üzere 9 açılı değeri alınarak elde edilebilir. Bu işlem HSG içinde sınıflandırmaya tabi tutulacak tüm pikseller için tekrarlanır. Sonuçta merkez piksel için elde edilecek YGH öznitelik sayısı $4 \times 9 = 36$ olacaktır. YGH ile elde edilen öznitelik sayısı genel olarak (Hücre Sayısı * Açılı Sayısı) ile elde edilir. YGH ile öznitelik elde etme adımları Şekil 2.12’de özetlenmiştir.



Şekil 2.12: HSG 1 bant görüntüsü için YGH ile histogram çıkarma.

2.5 SINIFLANDIRMA YÖNTEMLERİ

HSG sınıflandırma için geleneksel sınıflandırma yöntemlerinden olan Destek Vektör Makineleri ile derin öğrenme yöntemlerinden olan Evrişimsel Sinir Ağları kullanılmıştır.

2.5.1 Destek Vektör Makineleri

Destek Vektör Makineleri (DVM) (Support Vector Machines - SVM) [19], istatistiksel öğrenme temelli bir sınıflandırma algoritmasıdır. DVM eğitim verilerinin az olduğu durumlarda da iyi sonuçlar verebilmektedir. DVM iki sınıfa ait verileri ayırabilecek en uygun düzlemi veya hiper-düzlemi belirlemeye çalışmaktadır. DVM doğrusal ve doğrusal olmayan verilerin sınıflandırılmalarında kullanılabilir. Doğrusal olarak ayrılabilen veriler kendi özellik uzayındaki bir düzlem ile ayrılabilir. Doğrusal olarak ayrılamayan verilerin sınıflandırılmasında ise çekirdek (kernel) fonksiyonları kullanılarak veri yüksek boyutlu bir uzaya taşınır ve veriler belirlenen bir hiper-düzlem ile doğrusal olarak ayrılabilir duruma getirilir.

HSG sınıflandırma genellikle çoklu etiket sınıflandırmayı gerektirir. DVM ise ikili bir sınıflandırmadır. Ancak DVM, bire-bir ve bire-hepsi gibi yaygın olarak kullanılan bu iki yöntem ile çoklu etiket sınıflandırmayı yapabilmektedir. DVM yüksek sınıflandırma başarılarından dolayı HSG sınıflandırmada kullanılan popüler bir yöntemdir [20], [21], [22].

DVM, farklı sınıflara ait en yakın örnekler arasındaki uzaklığın en büyük olmasını sağlayan en uygun ayırma düzlemini (hiper-düzlemi) belirlemeye çalışmaktadır. Doğrusal olarak ayrılabilen iki sınıflı bir S eğitim kümesi $\{x_i, y_i\}$ $i = 1, \dots, N$, $y_i \in \{-1, +1\}$ ve $x_i \in \mathbb{R}^d$ olmak üzere N sayıdaki örnekten oluşsun. x_i d boyutlu özellik vektörünü, y_i ikili etiket değerlerini göstermektedir. Bu örnekleri ayıran en iyi düzlem fonksiyonu;

$$f(x) = w \cdot x + b \quad (2.17)$$

Eşitlik 2.17 ile ifade edilir. w ağırlık vektörü optimum ayırma düzlemine olan normali ve b ise yanlılık (bias) değerini ifade etmektedir. Örnekleri birbirinden ayıran optimum ayırma düzleminin bulunabilmesi için sınıfların sınırını belirleyen ve optimum ayırma düzlemine paralel olan düzlemler;

$$w \cdot x + b = +1 \quad y_i = +1 \text{ için} \quad (2.18)$$

$$w \cdot x + b = -1 \quad y_i = -1 \text{ için} \quad (2.19)$$

Eşitlik 2.18 ve Eşitlik 2.19 tek bir formül olarak yazıldığında;

$$y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, N \quad (2.20)$$

Sınır düzlemlerini belirleyen noktalar destek vektörleri olarak adlandırılmaktadır. Bu iki sınır düzlemleri arasında kalan uzaklık $\frac{2}{\|w\|}$ olarak elde edilir. Burada $\|w\|$, w ağırlık vektörünün Öklid normunu ifade etmektedir ve $\|w\|^2 = w^T w$ olarak da ifade edilmektedir. $\frac{|b|}{\|w\|}$ ise optimum ayırma düzleminin (hiper-düzlemden) orijine olan dik uzaklığı göstermektedir.

$$\|w\| = \sqrt{\sum_{i=1}^k w_i^2} \quad (2.21)$$

Optimum ayırma düzleminin bulunması için $\frac{2}{\|w\|}$ sınır genişliği değerinin en büyük olduğu değeri bulmak gerektiğinden öncelikle w değerlerinin bulunması gerekmektedir. $\frac{2}{\|w\|}$ sınır genişliğini en büyük yapan durum $\|w\|^2$ değerinin en küçük olduğu durum olduğundan $\|w\|^2$ değerinin en küçük değerinin bulunması gerekmektedir. Bu durumda optimum ayırma düzleminin bulabilmek için aşağıdaki denklemlerin çözülmesi gerekmektedir.

$$\min \left\{ \frac{1}{2} \|w\|^2 \right\} \quad (2.22)$$

$$\text{Kısıtlamalar: } y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, N \text{ ve } y_i \in \{-1, +1\} \quad (2.23)$$

Burada w ve b değerlerini bulmak için ikinci dereceden eşitsizlik kısıtlı bir denklemin çözümünün yapılması gerekir. Eşitlik 2.22' deki en küçük değeri bulmak için Eşitlik 2.23' deki kısıtlar dikkate alındığında bu problem bir optimizasyon problemi olarak karşımıza çıkmaktadır. Bu optimizasyon problem Langrange çarpanları yöntemi ile çözülebilmektedir ve elde edilecek optimizasyon denklemi Eşitlik 2.24' teki gibi yeniden yazılabilir.

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i(w \cdot x_i + b) + \sum_{i=1}^N \alpha_i \quad (2.24)$$

Burada α_i değerleri Langrange çarpanlarını ifade etmekte ve $\alpha_i \geq 0$ olmaktadır. $\alpha_i \geq 0$ şartının sağlandığı durumlardaki noktalar destek vektörleri olmaktadır. Eşitlik 2.24' deki denklemin w ve b 'ye göre kısmi türevleri 0 olmaktadır.

$$\frac{\partial}{\partial w} L_p = 0, \quad w = \sum_{i=1}^N \alpha_i y_i x_i, \quad \alpha_i \geq 0 \quad (2.25)$$

$$\frac{\partial}{\partial b} L_p = 0, \quad \sum_{i=1}^N \alpha_i y_i = 0, \quad \alpha_i \geq 0 \quad (2.26)$$

Eşitlik 2.25 ve Eşitlik 2.26' daki eşitlikler Eşitlik 2.24' de yerlerine koyulduğunda Eşitlik 2.27 yazılabilir.

$$\max \left\{ \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \right\} \quad (2.27)$$

Bu durumda sisteme verilen yeni örnekleri sınıflandırmak için kullanılacak olan karar fonksiyonu Eşitlik 2.28' de belirtilmiş olup x_i destek vektörlerini x ise giriş vektörünü ifade etmektedir.

$$f(x) = \sum_{i=1}^N \alpha_i y_i (x_i \cdot x) + b \quad (2.28)$$

$$y_i = \begin{cases} -, & f(x) < 0 \\ +, & f(x) > 0 \end{cases} \quad (2.29)$$

Tam olarak doğrusal ayırlamayan örneklerin sınıflandırılmasında ise belirli bir hata oranı dikkate alınarak yumuşak sınır yaklaşımı uygulanarak sınıflandırma işlemi yapılmaktadır. Bunun için ζ düzenleme değişkeni ve arttıran yapay değişkeni ξ (slack variable) kullanılmaktadır. Bu durumlardaki durumlar için Eşitlik 2.22 yeniden yazıldığında 2.30 elde edilmektedir. Eşitlik 2.30' daki ilk ifade Eşitlik 2.22' deki ifade ile aynıdır.

$$\min \left\{ \frac{1}{2} \|w\|^2 + \varsigma \sum_{i=1}^N \xi_i \right\} \quad (2.30)$$

$$\text{Kısıtlamalar: } y_i(w \cdot x_i + b) \geq 1 - \xi_i \text{ ve } \xi_i \geq 0, i = 1, \dots, N \text{ ve} \} \quad (2.31)$$

Doğrusal olarak ayrılamayan verilerin sınıflandırılmalarında ise çekirdek fonksiyonları kullanılarak giriş verisi daha yüksek boyutlu bir uzaya taşınarak sınıflandırmanın doğrusal olarak yapılması sağlanmaktadır. Çekirdek fonksiyonu $K(\cdot)$ ile ifade edildiğinde Eşitlik 2.27 çekirdek fonksiyonu kullanılarak yeniden yazıldığında Eşitlik 2.32 elde edilmektedir.

$$\max \left\{ \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \right\} \quad (2.32)$$

$$\text{Kısıtlamalar: } \sum_{i=1}^N \alpha_i y_i = 0 \text{ ve } 0 \leq \alpha_i \leq \varsigma, i = 1, \dots, N \quad (2.33)$$

Doğrusal olarak ayrılamayan verinin çekirdek fonksiyonları kullanılarak sınıflandırılmasında kullanılacak karar fonksiyonu Eşitlik 2.34' deki gibi Eşitlik 2.28 yeniden yazıldığında elde edilecektir.

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i (x_i \cdot x) + b \right) \quad (2.34)$$

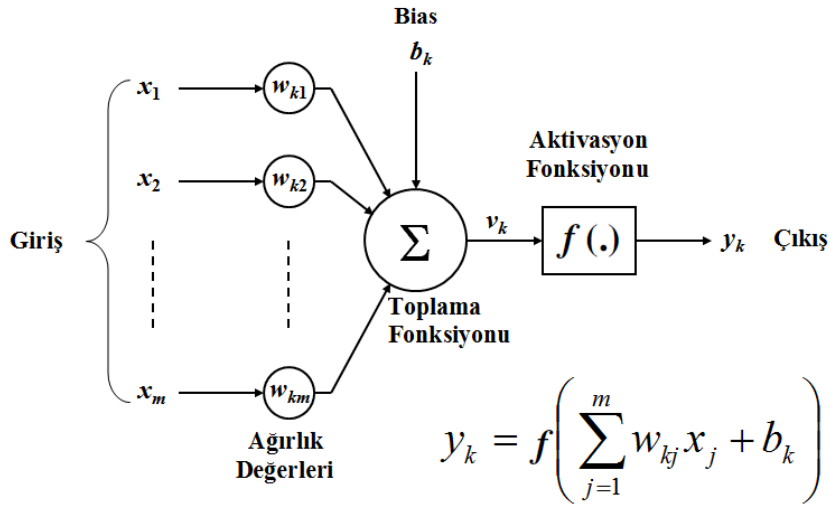
Doğrusal olmayan verilerin sınıflandırılmalarında yaygın olarak kullanılan çekirdekler polinom (polynomial) fonksiyonu, Radyal Tabanlı Fonksiyon (Radial Basis Function - RBF) ve sigmoid fonksiyonlarıdır. Kullanılan çekirdek fonksiyonu ve çekirdek için belirlenen parametreler sınıflandırma başarısını etkilemektedir. Bu çalışmada yüksek performans gösterdiği için Radyal Tabanlı Fonksiyonu çekirdek olarak tercih edilmiştir. Radyal tabanlı çekirdek fonksiyonun denklemi Eşitlik 2.35' te verilmiştir.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (2.35)$$

Çekirdek fonksiyonundaki en iyi doğruluk değerlerini bulabilmek için düzenleme parametreleri çapraz geçerlilik yöntemi ile belirlenmiştir.

2.5.2 Evrimsel Sinir Ağları

Yapay Sinir Ağları (YSA), (Artificial Neural Networks - ANN), insan beyninin çalışma prensibinden esinlenilerek geliştirilmiş makine öğrenme yöntemlerindedir. YSA ağırlıklı bağlantılar ile birbirlerine bağlanan ve en temel işlem birim olan nöronlardan oluşmaktadır. Nöronlar kendisine giriş olarak verilen alır değerleri alıp topladıktan sonra aktivasyon fonksiyonu olarak adlandırılan ve genellikle doğrusal olmayan bir fonksiyondan geçirerek kendi çıktısını üretmektedir. Nöronların girişleri ağa giriş olarak verilen değerler olabileceği gibi bağlantılı oldukları diğer nöronların çıktıları da olabilir. Bir nörondaki temel girişler bağlantı ağırlıkları ve yanlılık (bias) değerleri olmaktadır.




Şekil 2.13: Yapay Sinir Ağı nöronun genel yapısı [23].

Yapay sinir ağlarındaki bir nöronun genel yapısı Şekil 2.13' de gösterilmiştir. x_i giriş değerleri, w_i ağırlık değerleri ve b yanlılık (bias) değeri olmak üzere nörona giriş olarak verildiğinde nöron bu değerleri toplama fonksiyonundan elde ettiği değeri aktivasyon fonksiyonuna giriş olarak verir. Aktivasyon fonksiyon ile hesaplanan değer nöronun çıktısı olarak verilir. Toplama fonksiyonu x_i ve w_i değerlerinin çarpımlarının toplamları olabildiği gibi bu değerlerin çarpımı, en büyüğünü alma veya en küçüğünü bulma gibi farklı işlemler de olabilmektedir. y nöronun çıkış değeri ve $f(.)$ aktivasyon fonksiyonu olmak üzere nörona ait çıkış Eşitlik 2.36' daki gibi hesaplanmaktadır.


$$y_k = f \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (2.36)$$

Birden fazla katmandan oluşan ağlar Çok Katmanlı Algılayıcı (ÇKA), (Multi-Layer Perceptron - MLP) olarak adlandırılmaktadır. ÇKA 'larda giriş katmanı, çıkış katmanı ve en az bir tane gizli katman bulunmaktadır. Giriş katmanı ağa girdi olarak verilen girişleri hiçbir işlem uygulamadan ilk gizli katmana giriş olarak aktarır. Şekil 2.14'e iki gizli katmana sahip ÇKA ağ yapısı gösterilmektedir.



Şekil 2.14: 2 gizli katmana sahip ÇKA [24].

Derin ileri beslemeli sinir ağlarından biri olan Evrişimsel Sinir Ağları (ESA), (Convolutional Neural Networks - CNN) Yann LeCun tarafından el yazısı rakam tanımaya geri yayılım yöntemi ile uygulanmıştır [25]. Derin ESA görüntü sınıflandırmadaki başarısı [26] ve son zamanlardaki grafik işlemcilerinin sinir ağlarının eğitilmesinde kullanılması ile ağın eğitimi için harcanan zamanın azalması ile son zamanlarda popülerlik kazanmıştır. Ayrıca derin sinir ağlarının eğitilmesinde ihtiyaç duyulan yüksek eğitim verilerinin artması da derin sinir ağlarının kullanılmasında etkili olmuştur. ESA genelde evrişim katmanları, havuzlama (pooling) veya alt örnekleme (subsampling) katmanları ve çok katmanlı algılayıcı ağlarındakine benzer yapıda tam bağlantılı katmanlar olmak üzere üç ana katman yapısından oluşmaktadır.



Şekil 2.15: LeNet-5 ESA ağının yapısı [25].

2.5.2.1 Evrişim Katmanı


Evrişim katmanı giriş verisinden yerel öznitelik çıkarımını sağlamaktadır. Tam bağlantılı ağlarda her bir nöron bir önceki katmanda yer alan tüm nöronlarla bağlantılıdır. Evrişim katmanındaki bir nöron ise alıcı alandaki giriş sayısı kadar bağlantı içermektedir ve buna yerel bağlantılılık (local connectivity) denir. İki boyutlu bir I görüntüsüne ($w \times h$) boyutundaki K çekirdek matrisinin uygulanmasını ifade eden Eşitlik 2.37’ de ve evrişim işlemi Eşitlik 2.38 ‘de gösterilmiştir. f fonksiyonu aktivasyon fonksiyonunu, d ise görüntünün kanal sayısını ifade etmektedir. K çekirdek matrisinin boyutu alıcı alan (receptive field) olarak adlandırılmaktadır.

$$(I * K)_{xy} = \sum_{i=1}^h \sum_{j=1}^w K_{ij} \cdot I_{x+i-1, y+j-1} \quad (2.37)$$

$$C(I, K)_{xy} = f \left(b + \sum_{i=1}^h \sum_{j=1}^w \sum_{k=1}^d K_{ijk} \cdot I_{x+i-1, y+j-1, k} \right) \quad (2.38)$$

Evrişim (konvolüsyon) sonucu oluşan çıkış verisi kayma adım değerine (stride), çekirdek matrisini boyutlarına ve dolgu yapılmasına göre değişmektedir. W giriş boyutundaki bir görüntüye F boyutunda çekirdek matrisi, P dolgu miktarı ve S adım değerleriyle evrişim uygulandığında nöronun çıkış veri boyutu $((W-F+2P) / S+1)$ formülü ile hesaplanmaktadır [24].

Her bir alıcı alan bir nöron ile bağlandığında oluşan ağırlık sayısı, görüntünün derinliğinin ve çekirdek matrisinin boyutlarının çarpımları kadar olmaktadır. Örneğin $[32 \times 32 \times 3]$ boyutlu bir görüntüye $[5 \times 5 \times 3]$ filtresi 1 adım ve dolgulama (padding) yapmadan uygulandığında elde edilen görüntü boyutu $[28 \times 28]$ ve ağırlık sayısı 75 olmaktadır. Görüntünün her bir kanalında farklı ağırlıklar kullanmak yerine tek bir ağırlık kullanılarak parametre paylaşımı (parameter sharing) yapılabilir. Böylece eğitilecek parametre sayısı azaltılmış olur. Evrişimsel katmandaki her bir görüntü çıktısı özellik haritası veya aktivasyon haritası olarak adlandırılır.




Şekil 2.16: Bir görüntüye 1 filtre uygulanması (üst) ve 6 farklı filtre evrişimin uygulanması (alt) [27].

2.5.2.2 Alt Örnekleme Katmanı

Genel olarak evrişim katmanından sonra alt örnekleme katmanı ağa eklenmektedir [24]. Alt örnekleme belli boyutlardaki bir filtre ile alıcı alandaki değerleri bir fonksiyondan geçirme olarak tanımlanır. Bu fonksiyon alıcı alandaki değerlerin en büyüğünü alma veya tüm değerlerin ortalamasını alma olarak tanımlanabilir. Alt örnekleme katmanının temel amacı konvolüsyon sonucu elde edilen özelliklerin konuma göre değişmezliğini sağlamak ve alt örnekleme alıcı alanında kalan nöronların çıktısını özetlemektir [28]. Alt örnekleme katmanının en büyük

özelliklerinden bir diğeri ise veri boyutunu azalttığı için ağda eğitilecek toplam parametre sayısını önemli ölçüde azaltmasıdır. Alt örneklemede evrişimsel ağlardaki gibi kayma miktarı (stride) değeri önemli bir parametredir. En büyük değeri veya ortalama değeri alma en yaygın olarak kullanılan alt örnekleme yöntemleridir [29]. Şekil 2.17’ de en büyüğünü örnekleme (max pooling) işlemi gösterilmiştir.




Şekil 2.17: 2x2 filtresi ve 2 adım kaydırma ile en büyüğünü örnekleme (Max pooling) örneği.

2.5.2.3 Dropout Katmanı

Dropout (seyreltme) katmanı [30] bir katmandaki bazı nöronların rastgele olarak işleme alınmaması olarak tanımlanır. Katmandaki düğümlerden bazılarının alınmaması ile katmanlar arasındaki nöronlar birbirlerinden daha az etkilenmektedir. Dropout katmanı aşırı uyumu (overfitting) engelleme amacı ile ağa eklenmekte olup bazı nöronların işleme alınmaması hesaplama yükünü de azaltacaktır [31].

Dropout katmanı ESA’nda iyileştirme (regularization) amaçlı kullanılan en sık yöntemlerden olup genellikle tam bağlantılı katmanlardan sonra kullanılmaktadır. Dropout uygulanan nöronların çıktıları ileri besleme de sıfıra setlenir ve geri yayılım (backpropagation) [32] aşamasında bu nöronlar dikkate alınmaz yani işlemlere dahil edilmez [33]. Şekil 2.18’ de Dropout katmanının genel yapısı gösterilmektedir [30].



Şekil 2.18: Dropout katmanı içermeyen (a) ve içeren (b) ağ [30].

2.5.2.3 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları için genellikle doğrusal olmayan fonksiyonlar kullanılmaktadır.

Sigmoid fonksiyonu;

$$f(x) = \frac{1}{1 + e^x} \quad (2.39)$$

Tanh fonksiyonu;

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.40)$$

ReLU (Doğrultulmuş Doğrusal Birim) (Rectified Linear Unit) fonksiyonu [34];

$$f(x) = \max(0, x) \quad (2.41)$$

PReLU (Parametrik ReLU) (Parametric ReLU) fonksiyonu [35];

$$f(a, x) = f(x) = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.42)$$

Softmax fonksiyonu;

$$f(x)_j = \frac{e^{x_j}}{\sum_{n=1}^N e^{x_n}} \quad (2.43)$$

Softmax genellikle ağıın son katmanında sınıflandırma amaçlı kullanılmaktadır. Eşitlik 2.44' te x giriş vektörünü, w_j ve b_j j. nöron ağırlığını ve yanlılık (bias) değerlerini, N ağıın son katmanındaki çıkış sayısını (sınıf sayısını) göstermek üzere Softmax fonksiyonu j. sınıfa ait ihtimali vermektedir. Softmax fonksiyonu $[0,1]$ aralığındaki değerlerden oluşan ve her bir sınıfa ait ihtimali gösteren çıkış vektörünü üretmektedir [33]. Genellikle en büyük ihtimal değeri sınıf etiketi olarak kabul edilir.

$$P(y = j | x, w, b) = \frac{e^{x w_j + b_j}}{\sum_{n=1}^N e^{x w_n + b_n}} \quad (2.44)$$

2.6 METRİKLER

Sınıflandırma işleminin başarımını değerlendirebilmek için veya farklı sınıflandırıcıların başarımlarını kıyaslayabilmek için literatürde genellikle karışıklık matrisi (confusion matrix) [36] kullanılmaktadır. Başarımın ölçülmesinde kullanılan karışıklık matrisinde sınıflandırma sonucu her bir sınıf için doğru sınıflandırılmış ve yanlış sınıflandırılmış örneklerin sayısı veya oranları gösterilmektedir. Bu tablodan yararlanarak doğruluk başarımının değerlendirilmesinde kullanılan doğruluk (accuracy), hata oranı (error rate), kesinlik (precision), duyarlılık veya anma (sensitivity veya recall), ve F-ölçütü (F-score) değerleri hesaplanabilir [36]. İki sınıfa sahip bir verinin sınıflandırılması sonucu oluşturulan karışıklık matrisinin genel yapısı Tablo 2.1' de gösterilmiştir.

Tablo 2.1: İki sınıflı sınıflandırma için karışıklık matrisi.

		Tahmin	
		P (Positive)	N (Negative)
Gerçek	P (Positive)	TP (True Positive)	FN (False Negative)
	N (Negative)	FP (False Positive)	TN (True Negative)

Bu tablodaki;

P ve N sırası ile Positive ve Negative sınıflarını,

True ve False sırası ile tahmin sonucunun doğru ve yanlış olduğunu,

TP, gerçekte P sınıfına ait olup tahminin P sınıfı olarak doğru yapıldığını,

FP, gerçekte N sınıfına ait olup tahminin P sınıfı olarak yanlış yapıldığını,

FN, gerçekte P sınıfına ait olup tahminin N sınıfı olarak yanlış yapıldığını,

TN, gerçekte N sınıfına ait olup tahminin N sınıfı olarak doğru yapıldığını göstermektedir.

Bu bilgilerden yararlanarak aşağıdaki Doğruluk, Hata Oranı, Kesinlik, Duyarlılık, başarımlık değerlendirme yöntemleri yazılabilir.

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FN + FP + TN} \quad (2.45)$$

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP} \quad (2.46)$$

$$\text{Duyarlılık (Sensitivity)} = \frac{TP}{TP + FN} \quad (2.47)$$

$$\text{Özgüllük (Specificity)} = \frac{TN}{FP + TN} \quad (2.48)$$

$$F - \text{ölçütü}(F - \text{score}) = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2.49)$$

Tablo 2.2: Çoklu etiket sınıflandırma için karışıklık matrisi [37].

	Cp_1	...	Cp_k
Ca_1	p_{11}	...	p_{1k}
\vdots	\vdots	...	\vdots
Ca_k	p_{k1}	...	p_{kk}

Çoklu sınıflı sınıflandırmada karışıklık matrisi Tablo 2.2' deki genelleştirilebilir. k toplam sınıf sayısı olmak üzere p_{ij} ($1 \leq i, j \leq k$) her bir sınıfın sınıflandırma sonucundaki doğruluk oranını göstermektedir [37].

Literatürde en popüler başarımlar metriklerinden biri tüm başarı oranı (overall success rate) sıklıkla kullanılmaktadır veya diğer bir ifade ile tüm doğruluk (TD) (overall Accuracy - OA) [37] olarak adlandırılmaktadır. Bu tez çalışmasında tüm doğruluk (TD) bütün sınıflandırma sonuçlarında yer verilmiştir ve Eşitlik 2.45 'teki gibi Tablo 2.2 'den yararlanılarak hesaplanmaktadır.

$$TD(OA) = \sum_{i=1}^k p_{ii} \quad (2.50)$$

Cohen's Kappa (K) skoru [38] ise sınıflandırmanın güvenilirliğini göstermektedir [37] ve HSG sınıflandırma başarısının analizinde sıkça kullanılmaktadır. $[0,1]$ aralığında değerler almakta ve bu değerlerin büyük olması doğruluğun güvenilirliğini yüksek olduğunu ifade eder. Genel olarak gözlemlenen doğruluk değerinin beklenen doğruluk değerine oranı olarak hesaplanmaktadır ve karışıklık matrisinden yararlanılarak bu hesaplama yapılabilir.

$$Kappa = \frac{\text{Gözlemlenen Doğruluk} - \text{Beklenen Doğruluk}}{1 - \text{Beklenen Doğruluk}} = \frac{P_o - P_e}{1 - P_e} \quad (2.51)$$

$$P_o = \frac{TP - TN}{TP + TN + FP + FN} \quad (2.52)$$

$$P_e = \frac{(\text{Gerçek Negative} * \text{Tahmin Negative})}{(TP + TN + FP + FN)^2} + \frac{(\text{Gerçek Positive} * \text{Tahmin Positive})}{(TP + TN + FP + FN)^2} \quad (2.53)$$

$$= \frac{(FP + TN) * (FN + TN) + (TP + FN) * (TP + FP)}{(TP + TN + FP + FN)^2}$$

2.7 LİTERATÜR ÖZETİ

Hiperspektral görüntülerin sınıflandırılması, hiperspektral görüntülemedeki en popüler çalışma alanlarından biridir. Hiperspektral görüntü (HSG) birçok dar dalga boyu bandından oluştuğu için çok fazla miktarda veri içermektedir. Verinin fazla olması işlem bakımından sınıflandırıcının performansını etkilemektedir. Bu nedenle incelenen önceki çalışmalarda hiperspektral görüntü boyutunun azaltılmasının sınıflandırma başarımı kadar önemli olduğu görülmüştür. Hiperspektral görüntü sınıflandırmada büyük miktardaki spektral bant sayısı, spektral imzanın uzamsal değişebilirliği doğru sınıflandırmanın yüksek maliyeti ve verinin kalitesi gibi konular bu alandaki temel sorunlardandır [8]. HSG' den çeşitli yöntemlerle elde edilen uzamsal özniteliklerin kullanılması ile sınıflandırma başarısının artırıldığı çalışmalarda literatürde yer almaktadır.

HSG sınıflandırma için birçok yöntem ortaya atılmış olup bunlardan bazıları sadece spektral özellikleri kullanırken bazıları da hem spektral hem de uzamsal bilgileri kullanmıştır. Destek Vektör Makineleri (Support Vector Machines) [19], yüksek boyuttaki veri ve az sayıdaki eğitim kümesi ile spektral bilgileri kullanarak yüksek başarımlı sağlayabilmektedir [20], [21]. İlgililik Vektör Makineleri (Relevance Vector Machines) yine çekirdek temelli HSG sınıflandırma için önerilen yöntemler arasında yer almıştır [39].

Son yıllarda uzamsal bilgiler de kullanılarak sınıflandırma yapılmış ve spektral - uzamsal sınıflandırma olarak ifade edilmiştir. Uzamsal bilgileri elde etmek için iki temel yöntem kullanılmaktadır. Bunlardan birincisi HSG' den morfolojik özellikler ve doku bilgisi elde etmek, ikincisi ise uzamsal bir piksele ait komşu piksellerden faydalanmaktır [40].

Uzamsal özniteliklerin komşu piksellerin ortalaması veya standart sapması alınarak elde edildiği ve spektral özniteliklerle birlikte kullanıldığı çalışmada DVM için farklı çekirdeklerin birleştirilmesi ile sınıflandırma yapılmıştır [41]. HSG' den bant çıkarımı ile elde edilen bant görüntülerine açma-kapama gibi morfolojik işlemler uygulanarak özniteliklerin elde edilerek sınıflandırılması [22] ve [42]'te önerilmiştir. Markov Rastgele Alanlar [43], uzamsal komşuluğa bağlı olarak doku özniteliklerini çıkarmak için kullanılan ayrı bir yöntem olarak HSG sınıflandırmada [44] ve [45] 'de kullanılmıştır. [46] ve [47] çalışmalarında ise bant çıkarma boyut indirgeme yöntemi ile çıkarılan bantlara Gabor Filtresi uygulanarak uzamsal özniteliklerin kullanıldığı sınıflandırma önerilmiştir. Örüntü tanımada sıklıkla kullanılan Yerel İkili Örüntü (Local Binary Patterns) HSG sınıflandırmada da başarılı sonuçlar vermiştir [48].

HSG sınıflandırmada uzamsal ve spektral özniteliklerin vektörel olarak birleştirilmesi yöntemi (öznitelik birleştirme) ile sınıflandırma yapıldığı gibi bu öznitelikler kullanılarak ayrı ayrı sınıflandırma yaptıktan sonra en son sınıflandırma sonucu bu ayrık sınıflandırma sonuçlarının karar birleştirme yöntemi ile elde edildiği çalışmalarda mevcuttur. [48]' de bant seçimi yöntemi ile elde edilen bant görüntülerinden Yerel İkili Örüntü ve Gabor Filtresi uygulanarak uzamsal öznitelikler ve seçilen bu bantlardan spektral öznitelikler elde edilmiştir. Elde edilen öznitelik vektörleri ayrı ayrı olarak Çekirdek Aşırı Öğrenme Makineleri (Kernel Extreme Learning Machine) ile sınıflandırma yapılmıştır. Sınıflandırma sonuçları olasılıksal değerler kullanılarak LOGP (Logarithmic Opinion Pool) yöntemi ile karar birleştirme (decision fusion) yapılmıştır ve öznitelik birleştirme (feature fusion) ile kıyaslanmış ve karar birleştirme yönteminin başarılı olduğu vurgulanmıştır. Farklı karar birleştirme yöntemlerinin kullanıldığı [49]' da Temel Bileşen Analizi [12] kullanılarak elde edilen temel bileşenlerden uzamsal morfolojik öznitelik vektörleri ayrı ayrı olarak sınıflandırılmıştır. Her bir sınıflandırma sonucu çoğunluk oylaması (majority voting), ağırlık çoğunluk oylaması (weighted majority voting), LOGP gibi farklı karar birleştirme yöntemleri ile sonuçlar elde edilerek karar birleştirme yöntemlerinin başarımları kıyaslanmıştır. Sınıflandırma için DVM ve Rastgele Orman yöntemleri kullanılarak kıyaslama yapılmıştır.

HSG sınıflandırmada yapay sinir ağları son birkaç yıldır literatürde oldukça sık kullanılmaya başlanmıştır. Son yıllarda yüksek hızlı bilgisayarların ve grafik işlemcilerinin (GPU) kullanılması ile yapay sinir ağlarının sınıflandırmada kullanıldığı çalışmalar da artmıştır. [42]'de morfolojik öznitelikler Yapay Sinir Ağları (YSA) kullanılarak yapılmıştır. [50]'deki çalışmada Evrişimsel Sinir Ağları (Convolutional Neural Networks), Derin İnanç Ağları (Deep Belief Networks) gibi farklı YSA yapıları spektral öznitelikler kullanılarak sınıflandırma yapılmıştır. Tüm spektral bantlar alınarak 1 boyutlu Evrişimsel Sinir Ağları (ESA) (1 boyutlu evrişimin uygulandığı ESA) ile sınıflandırma yapılmış ve ESA başarımının DVM başarısından yüksek olduğu gösterilmiştir [28]. Yine TBA ile bant çıkarımı yapıldıktan sonra tüm spektral bant değerleri ile çıkarılan bantlardaki her pikselin uzamsal komşuluğundaki spektral değerler vektör halinde birleştirilerek Derin İnanç Ağları ile sınıflandırma yapılmıştır [51]. Spektral ve uzamsal öznitelikler kurulan ESA'na giriş olarak verilmiş ve 1 boyutlu evrişim (konvolüsyon) uygulayan ESA ile sınıflandırma yapılmış ayrıca ESA'nın son katmandan önce öznitelik değerleri alınarak SVM ile de sınıflandırma yapılmıştır [52]. [53] ve [54]'te bir pikselin komşuluğundaki uzamsal bilgilerden yararlanılarak 2 boyutlu evrişim uygulayan ESA ile [55] ve [56]'da ise 3 boyutlu evrişim uygulayan ESA ile sınıflandırma yapılmıştır. TBA ile çıkarılan bantlara Gabor Filtresi uygulanarak elde edilen öznitelikler 2 boyutlu evrişim uygulayan ESA ile sınıflandırılmıştır [57].

HSG sınıflandırmadaki literatürde son zamanlarda yapılan çalışmalar başarımın daha da artırılması, az sayıda eğitim kümesi ile yüksek başarımların elde edilmesi, uzamsal bilgilerden yararlanılması, ESA gibi derin öğrenme yöntemlerinin uygulanması ve boyut indirgeme gibi alt başlıklar halinde sıralanabilir. Literatürde son yapılan çalışmalarda genellikle yapay sinir ağları ile sınıflandırma yapılmış olup özellikle derin öğrenme yapılarından olan Derin Evrişimsel Sinir Ağları (Deep Convolutional Neural Networks) üzerinde yoğunlaşmıştır. ESA ile sınıflandırma ESA ile yapılan sınıflandırmalarda genellikle eğitim kümesindeki örnek sayıları DVM gibi geleneksel sınıflandırma yöntemlerine göre daha fazla alınmıştır. Ayrıca 2 ve 3 boyutlu ESA eğitim süreleri DVM gibi geleneksel sınıflandırma yöntemlerinin eğitim sürelerinden çok daha fazla olduğu görülmüştür. ESA ile sınıflandırma yaparken eğitim sürelerini azaltmak için genellikle yüksek hızlı grafik işlemcilerinden yararlanılarak eğitimler yapılmıştır. Literatürde HSG sınıflandırmada başarımın artırılmasının yanında az sayıda eğitim verisi kullanarak başarımın yüksek olduğu sınıflandırma çalışmaları da yapılmıştır.

3. MALZEME VE YÖNTEM


3.1 VERİ KÜMELERİ

Tez çalışmasında HSG sınıflandırma çalışmalarında en sık kullanılan veri kümelerinden Indian Pines, Pavia University ve Salinas olmak üzere 3 farklı veri kümesi kullanılmıştır.

Indian Pines veri kümesi [5] AVIRIS sensörü ile 1992 yılında Amerika'nın Indiana eyaletinin kuzey-batı bölgesinden elde edilmiştir. Indian Pines HSG'sü 145x145 piksel ve 0.4 – 2.5 μ dalga boyu aralığına sahip 224 banttan oluşmaktadır ve 20m uzamsal çözünürlüğe sahiptir. Gürültü içeren bantların kaldırılması sonucu 200 bant sınıflandırma amaçlı kullanılmıştır [58]. Bu veri kümesi 16 sınıftan ve toplam 10249 örnekten oluşmaktadır. Indian Pines veri kümesi tarım alanları, orman ve bitki örtüsü gibi birbirine benzer spektral imzalara sahip sınıflardan oluşmaktadır. Spektral imzaların bu yüksek benzerliğinden dolayı sınıflandırılması göreceli olarak daha zor olan bir veri kümesidir [8]. Şekil 3.1'deki siyah renkli pikseller yer doğrusunda sınıfı olmayan ve sınıflandırmaya dahil edilmeyen piksellerdir.

Tablo 3.1: Indian Pines veri kümesine ait sınıflar ve örnekler sayıları.

Sınıf	Adı	Örnek Sayısı
1	Alfalfa (Yonca)	46
2	Corn-notill (Mısır-işlenmemiş)	1428
3	Corn-mintill (Mısır-az işlenmiş)	830
4	Corn (Mısır)	237
5	Grass-pasture (Çimen-otlak)	483
6	Grass-trees (Çimen-ağaç)	730
7	Grass-pasture-mowed (Çimen-biçilmiş otlak)	28
8	Hay-windrowed (Saman)	478
9	Oats (Yulaf)	20
10	Soybean-notill (Soya fasülyesi- işlenmemiş)	972
11	Soybean-mintill (Soya fasülyesi-az işlenmiş)	2455
12	Soybean-clean (Soya fasülyesi)	593
13	Wheat (Buğday)	205
14	Woods (Orman)	1265
15	Buildings-Grass-Trees-Drives(Bina-Çimen-Ağaç-Araç)	386
16	Stone-Steel-Towers (Kaya-Çelik-Bina)	93
Toplam		10249




Şekil 3.1: Indian Pines a) 3 bant (43, 21, 11) renkli görüntü b) yer doğrusu c) sınıf renk kodları.

Pavia University veri kümesi [5] ROSIS sensörü ile 2001 yılında İtalya'nın Pavia şehrinde yer alan Pavia Üniversitesi'ne bir bölgesinden elde edilmiştir. Pavia University HSG'sü 610 x 340 piksel ve 0,43 – 0,86 μ dalga boyu aralığına sahip 112 banttan oluşmaktadır ve 1,3m uzamsal çözünürlüğe sahiptir. Gürültü içeren bantların kaldırılması sonucu 103 bant sınıflandırma amaçlı kullanılmıştır [58]. Bu veri kümesi 9 sınıftan ve toplam 42776 örnekten oluşmaktadır. Pavia University 3 bandı ile elde edilmiş renkli görüntüsü ve yer doğrusu Şekil 3.1'de gösterilmiştir. Siyah renkli pikseller yer doğrusunda sınıfı olmayan ve sınıflandırmaya dahil edilmeyen piksellerdir.

Tablo 3.2: Pavia University veri kümesine ait sınıflar ve örnekler sayıları.

Sınıf	Adı	Örnek Sayısı
1	Asphalt	6631
2	Meadows	18649
3	Gravel	2099
4	Trees	3064
5	Painted metal sheets	1345
6	Bare Soil	5029
7	Bitumen	1330
8	Self-Blocking Bricks	3682
9	Shadows	947
Toplam		42776




Şekil 3.2: Pavia University a) 3 bant (44, 24, 10) renkli görüntü b) yer doğrusu c) sınıf renk kodları.

Tablo 3.3: Salinas veri kümesine ait sınıflar ve örnekler sayıları.

Sınıf	Adı	Örnek Sayısı
1	Brocoli_green_weeds_1	2009
2	Brocoli_green_weeds_2	3726
3	Fallow	1976
4	Fallow_rough_plow	1394
5	Fallow_smooth	2678
6	Stubble	3959
7	Celery	3579
8	Grapes_untrained	11271
9	Soil_vinyard_develop	6203
10	Corn_senesced_green_weeds	3278
11	Lettuce_romaine_4wk	1068
12	Lettuce_romaine_5wk	1927
13	Lettuce_romaine_6wk	916
14	Lettuce_romaine_7wk	1070
15	Vinyard_untrained	7268
16	Vinyard_vertical_trellis	1807
Toplam		54129

Salinas veri kümesi [5] AVIRIS sensörü ile Amerika'nın California eyaletinde yer alan Salinas Vadisi'nin bir bölgesinden elde edilmiştir. Salinas HSG'sü 512 x 217 piksel ve 0,4 – 2,40µ dalga boyu aralığına sahip 224 banttan oluşmaktadır ve 3,7m uzamsal çözünürlüğe sahiptir. Gürültü içeren bantların kaldırılması sonucu 204 bant sınıflandırma amaçlı kullanılmıştır [58]. Bu veri kümesi 16 sınıftan oluşmaktadır ve toplam 54129 örnekten oluşmaktadır. Siyah renkli pikseller yer doğrusunda sınıfı olmayan ve sınıflandırmaya dahil edilmeyen piksellerdir.



Şekil 3.3: Salinas a) 3 bant (50, 30, 20) renkli görüntü b) yer doğrusu c) sınıf renk kodları.

3.2 BANT ÇIKARMA

Hiperspektral görüntülerde bant sayısı fazla olduğundan uzamsal öznitelik çıkarmak için kullanılacak görüntü sayısı da fazla olmaktadır. Bant sayısının fazlalığı uzamsal öznitelik elde etme maliyetini ve sınıflandırma maliyetini artırmaktadır. HSG'nün tüm bantlarına uzamsal öznitelik yöntemleri uygulamak yerine sadece en ayırt edici ve bilgilendirici bantlara uygulanarak öznitelikleri elde edilebilir.

Bu çalışmada bu bantları belirlemek için HSG' den bant çıkarma yaklaşımlarından yaygın olarak kullanılan Temel Bileşen Analizi (TBA) [12] kullanılmıştır. Elde edilen bant görüntülerine uzamsal öznitelik çıkarma yöntemleri ayrı ayrı uygulanarak uzamsal öznitelikler çıkarılır ve bu uzamsal öznitelikler sınıflandırmada kullanılmıştır. TBA ile elde edilen bantlar Temel Bileşen (TB) olarak ifade edilir ve her bir temel bileşenin tüm verideki değişinti (varyasyon) oranı dikkate alınarak uygun sayıda temel bileşen uzamsal öznitelik çıkarma işleminde kullanılır.

Tablo 3.4: HSG veri kümelerine ait TBA ile elde edilen TB değişinti oranları (%).

TB	Indian Pines		Pavia University		Salinas	
	Değer	Toplam	Değer	Toplam	Değer	Toplam
TB1	68,49	68,49	58,31	58,31	74,47	74,47
TB2	23,53	92,02	36,10	94,41	23,53	98,00
TB3	1,49	93,51	4,43	98,84	1,13	99,13
TB4	0,82	94,33	0,30	99,14	0,54	99,67
TB5	0,69	95,02	0,20	99,34	0,17	99,84
TB6	0,51	95,53	0,17	99,51	0,05	99,89
TB7	0,39	95,92	0,12	99,63	0,02	99,91
TB8	0,36	96,28	0,06	99,69	0,01	99,92
TB9	0,30	96,58	0,04	99,73	0,009	99,92
TB10	0,29	96,87	0,03	99,76	0,006	99,93


Tablo 3.4' de deneylerde kullanılan HSG veri kümelerine ait TBA ile elde edilen ilk 10 temel bileşen bantların değişinti oranları % olarak gösterilmiştir. Bu tablodaki kümülatif değişinti oranlarına bakıldığında Indian Pines HSG veri kümesinde bantlar arasındaki bağıntının (korelasyon) daha az olduğu anlaşılmaktadır. Salinas ve Pavia University HSG veri kümesinde ise bantlar arasındaki korelasyonun çok yüksek olduğu görülmektedir. Bu değerler dikkate alınarak her bir veri kümesi için farklı sayıda bantlar alınarak uzamsal özellikler çıkarılmaktadır.

3.3 SPEKTRAL – UZAMSAL SINIFLANDIRMA

HSG sınıflandırmada spektral özelliklerin yanı sıra uzamsal özelliklerin de kullanılması sınıflandırma başarısını artırmaktadır. Bu nedenle bu çalışmada HSG sınıflandırma için hem spektral hem de uzamsal öznitelikler kullanılarak sınıflandırma yapılmıştır. HSG sınıflandırma için iki farklı sınıflandırıcı kullanılmıştır. HSG sınıflandırmada yüksek başarısı ve performansından dolayı Destek Vektör Makineleri birinci sınıflandırıcı olarak kullanılmıştır. İkinci sınıflandırıcı olarak ise son zamanlarda HSG sınıflandırmada da sıklıkla kullanılan Evrişimsel Sinir Ağları kullanılmıştır. Yapılan deneylerde tamamen aynı eğitim ve test örneklerini içeren veriler hem DVM için hem de ESA için kullanılmıştır.


HSG çok fazla bantlardan oluştuğu için tüm bantlardan özellik çıkarmak yerine en fazla bilgi içeren bantlar kullanılarak az sayıda bant ve işlem maliyeti ile sınıflandırma yapılabilir. Bu çalışmada bant çıkarma yöntemi yaklaşımı uygulanmış ve daha az sayıda, en ayırt edici ve bilgilendirici bantları çıkarmak için TBA yöntemi kullanılmıştır. Sınıflandırma işlemi için bir sonraki adım elde edilen her bir banttın uzamsal özelliklerin çıkarılmasıdır. Bunun için YİÖ, YGH ve Gabor Filtresi yöntemleri her bir TB bandına uygulanmıştır. Ayrı ayrı olarak elde edilen uzamsal özellikler ve spektral öznitelikler kullanarak, Öznitelik Birleştirme (ÖB) (Feature Fusion - FF) ve Karar Birleştirme (KB) (Decision Fusion - DF) olmak üzere iki farklı yöntemle sınıflandırma sonuçları elde edilmiştir. Her iki yöntemde de sınıflandırma öncesi uygulanan TB çıkarma ve spektral-uzamsal öznitelik çıkarma işlemleri aynıdır.

Öznitelik Birleştirme yönteminde spektral ve uzamsal öznitelik vektörel olarak birleştirilir ve sınıflandırma için bu öznitelik vektörü kullanılır. Spektral ve uzamsal öznitelikler vektörel olarak birleştirilmeden önce normalleştirme işleminin yapılması gerekmektedir. Öznitelikleri normalleştirme için standart sapma veya $[0,1]$ veya $[-1,1]$ aralıklarına ölçekleme yapılabilir. Yapılan deneylerde sınıflandırma başarımına göre spektral ve uzamsal özellik vektörlerini normalleştirmek için hem standart sapmadan hem de $[0,1]$ aralığına ölçekleme yaklaşımlarından faydalanılmıştır. Şekil 3.4' te ÖB yöntemi ile HSG sınıflandırma şeması gösterilmiştir. Spektral, YİÖ, YGH ve Gabor öznitelikleri ayrı ayrı olarak, ikili birleştirilerek ve üçlü birleştirilerek sınıflandırma başarımları değerlendirilmiştir.



Şekil 3.4: Öznitelik Birleştirme (ÖB) ile yöntemi ile spektral-uzamsal HSG sınıflandırma akışı.

Karar Birleştirme yönteminde ise spektral-uzamsal öznitelikler ayrı ayrı sınıflandırılır. Her bir sınıflandırma sonucunda elde edilen etiketler bir karar birleştirme yönteminden geçirilerek en son yer doğrusu elde edilir. Şekil 3.5’ te KB yöntemine ait sınıflandırma şeması gösterilmektedir.



Şekil 3.5: Karar Birleştirme (KB) ile yöntemi ile spektral-uzamsal HSG sınıflandırma akışı.

Karar Birleştirme için çoğunluk oylaması (majority voting), ağırlıklı çoğunluk oylaması (weighted majority voting), en büyük çıkış olasılığı (maximum a posterior probability), Linear Opinion Pool (LOP) ve Logarithmic Opinion Pool (LOGP) gibi yöntemlerden faydalanılabilir [49]. HSG sınıflandırmada kullanılan, [59], [60], [16], LOGP yöntemi iyi sonuçlar verdiği için

bu çalışmada bu yöntem tercih edilmiştir. Bu yöntem sınıflandırma sonuçlarının ağırlıklı olasılıklarını dikkate alarak sonuç elde eden bir karar birleştirme yöntemidir [49]. Tüm sınıflandırıcıların aynı örnek için ürettiği etiketin olasılığı değerlendirilerek sonuçlar elde edilir.

$$y = \mathop{\text{arg}}_{k=1,\dots,C} \max \mathbf{P}(y_k | x) \quad (3.1)$$

$$\mathbf{P}(y_k | x) = \prod_{s=1}^S p_s(y_k | x)^{a_s} \quad (3.2)$$

$$\log \mathbf{P}(y_k | x) = \sum_{s=1}^S a_s \log p_s(y_k | x) \quad (3.3)$$


Eşitlik 3.1' de LOGP yöntemi verilmiştir ve C sınıf sayısını, S sınıflandırıcı sayısını, a_s s. sınıflandırıcının ağırlığını, $p_s(y_k | x)$ ise s. sınıflandırıcının çıkış olasılığını ifade etmektedir. $\mathbf{P}(y_k | x)$ sınıflandırıcının bir örneğe verdiği çıkış olasılığının sınıflandırıcı ağırlığı ile çarpılmış fonksiyonu ifade etmektedir. Bu fonksiyonun ürettiği en büyük değer alınarak örneğe ait sınıf etiketi belirlenmiş olur.

3.5 ÖNERİLEN EVRİŞİMSEL SİNİR AĞININ MİMARİSİ

Görüntü sınıflandırmada kullanılan ESA ağ yapılarında genellikle 2 boyutlu evrişim uygulanmaktadır. HSG sınıflandırma için spektral ve uzamsal öznitelik çıkarım yöntemleri ile elde edilen spektral ve uzamsal öznitelikler bir vektör halindedir. Bu nedenle bu öznitelikleri sınıflandırmada kullanılacak evrişim de 1 boyutlu olması gerekmektedir. Bu çalışmada 1 boyutlu evrişimin uygulandığı derin ESA modeli kurulmuştur. Kurulan ağın yapısı Şekil 3-6' da gösterilmiştir.

Ağın ilk katmanında giriş katmanı yer almakta ve girişler 1 boyutlu öznitelik vektörü şeklindedir. Giriş öznitelik vektöründeki öznitelik sayısı yani boyutu sınıflandırma için kullanılan bant sayısına, spektral-uzamsal öznitelik sayılarına ve özellik birleştirme yönteminin uygulanıp uygulanmadığına göre değişmektedir. Giriş katmanından sonraki katman ilk evrişimin katmanı olup 16 adet (2x1) boyutundaki filtreyi uygulayarak 16 özellik haritası (feature maps) elde edilir. Doğrusal olmayan PReLU aktivasyon fonksiyonu kullanılmıştır. İlk evrişimden sonrası Max Pooling (2x1) uygulandıktan sonra Yığın Normalizasyon (Batch

Normalization) [61] katmanı yer almaktadır. İkinci evrişim 32 adet (2x1) boyutunda filtre uyguladıktan sonra tekrar yığın normalizasyonu uygulanmıştır. Evrişim ile öznelik çıkarımı yapıldıktan sonra sınıflandırma amaçlı Tam Bağlantılı katman yer almaktadır. İlk tam bağlantılı katmanda 128, ikinci katmanda 96 adet nöron yer almaktadır. İlk tam bağlantılı katmandan sonra nöron seyreltme için Dropout katmanı 0,5 oranında yer almaktadır. Ağın çıkış katmanında ise etiketleri belirlemek için Softmax katmanı yer almaktadır.



Şekil 3.6: Önerilen ESA mimarisi.

Evrişim katmanındaki kayma (stride) değeri 1 olarak alınmıştır ve dolgulama yapılarak evrişim katmanına giriş boyutu ile çıkış boyutunun aynı olması sağlanmıştır. Çıkış katmanındaki beklenen değer ile gözlemlenen değerler arasındaki kaybı hesaplamak için cross-entropy [62] fonksiyonu kullanılmıştır [63]. Ağ eğitiminde optimizasyon stochastic gradient descent (SGD) [64] kullanılmıştır.

Tablo 3.5: Önerilen ESA ağının katmanları.

Katman	İşlem / Açıklama	Çıkış Boyutu
Giriş Katmanı	Giriş: $V \times 1$ (M sayıda örnek)	$V \times 1$
Conv1	Evrişim: 16 @ (2x1)	$V \times 1 \times 16$
Batch Normalization	Yığın Normalizasyonu	$V \times 1 \times 16$
Max Pooling	Alt örnekleme (2x1)	$(V/2) \times 1 \times 16$
Conv1D	Evrişim: 32 @ (2x1)	$(V/2) \times 1 \times 32$
Batch Normalization	Yığın Normalizasyonu	$(V/2) \times 1 \times 32$
Flatten	Vektörleştirme(düzleştirme)	$(32 \times V/2) \times 1$
Full Connected	Tam bağlantılı katman: 128	128×1
Dropout	Seyreltme: 0,5	128×1
Full Connected	Tam bağlantılı katman: 96	96×1
Softmax	Sınıflandırma Katmanı	$N \times 1$

Tablo 3.5' te ESA ağının katmanları, katmanların açıklamaları ve her bir katmanın çıktı boyutu özet halinde verilmiştir. M örnek sayısını, V bir örnek için öznitelik vektörünü, N sınıf sayısını göstermektedir. Bir örnek için birinci katmandan sonra 16 adet öznitelik haritası oluşmaktadır. Max Pooling katmanında (2x1) boyutunda alt örnekleme yapıldığı için çıkış vektörünün büyüklüğü V/2 olacaktır. Flatten (düzleştirme) katmanı evrişim katmanından tam bağlantılı katmana geçiş yapmak için kullanılır ve giriş olarak aldığı değerlere vektörleştirme dışında hiçbir işlem uygulamamaktadır.

4. BULGULAR

Bu bölümde spektral ve uzamsal özniteliklerin ayrı ayrı ve birleştirme (fusion) yöntemi ile sınıflandırma sonuçları sunulmuştur. Farklı eğitim örnek sayılarının ve farklı sayıdaki bantların sınıflandırma başarılarına etkisi değerlendirilmiştir. Sınıflandırma yöntemleri olarak DVM ve ESA kullanılmıştır. DVM sınıflandırma için LIBSVM [65] kütüphanesi, ESA için Keras [63] ve Scikit-learn [66] kütüphaneleri kullanılmıştır. 2,5 GHz Intel Core i7 4 çekirdek bir bilgisayar ile sonuçlar elde edilmiş olup bilgisayarın ESA eğitimi için grafik işlemci desteği mevcut değildir. Sınıflandırma deneyleri her bir veri kümesinden rastgele olarak alınan örneklerden oluşan 10 farklı eğitim ve test kümesi oluşturulup sınıflandırma yapılmıştır ve sonuçlar bu 10 eğitim ve test kümelerinin sınıflandırma sonuçlarının aritmetik ortalamaları olarak verilmiştir.

4.1 UZAMSAL ÖZİNTELİK ÇIKARMA YÖNTEMLERİ İÇİN EN UYGUN PARAMETRE DEĞERLERİNİN BELİRLENMESİ

Sınıflandırma için HSG' den uzamsal özniteliklerin elde edilmesi için uzamsal öznitelik çıkarma yöntemlerinde kullanılan ve sınıflandırma başarımını önemli ölçüde etkileyen parametrelerin en uygun değerlerini belirlemek gerekmektedir. Bu çalışmada önerdiğimiz uzamsal öznitelik çıkarma yöntemleri olan YİÖ, YGH ve Gabor Filtresinin parametrelerinin en uygun değerlerini belirlemek için Tablo 4.1' deki gibi eğitim ve test için belirlenen sayıdaki veri DVM ile sınıflandırma yapılarak elde edilen sonuçlara göre parametrelerin en uygun değerleri belirlenmiştir. Uzamsal öznitelik çıkarma yöntemlerinde kullanılan parametrelerin sınıflandırma başarımına etkisi değerlendirilmiş ve en uygun parametre değerleri belirlenmiştir. Ayrıca spektral ve uzamsal özniteliklerin ayrı ayrı DVM ile sınıflandırma sonuçları paylaşılmış ve sonuçlar değerlendirilmiştir.

Tablo 4.1 'deki eğitim örnek sayıları tüm veri kümeleri için eğitim kümesindeki her bir sınıfa ait örnek sayısı en fazla 30 olacak şekilde her bir sınıfa ait toplam örnek sayısının %10'u alınmıştır. Indian Pines'dan eğitim için toplam 365 örnek, Pavia University'den eğitim için toplam 270 örnek, Salinas'dan eğitim için toplam 480 örnek alınmış geri kalan örnekler test için alınmıştır. TBA ile en ayırt edici ve bilgilendirici 7 bant çıkarımı yapılmıştır. Bu bölümdeki tüm sınıflandırma sonuçları ETK-1 örnek sayıları ve 7 bant kullanılarak elde edilen sonuçlardır.

Tablo 4.1: Eğitim Test Kümesi – 1 (ETK-1)


Veri Küm.	Indian Pines		Pavia U.		Salinas	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
1	5	41	30	6601	30	1979
2	30	1398	30	18619	30	3696
3	30	800	30	2069	30	1946
4	24	213	30	3034	30	1364
5	30	453	30	1315	30	2648
6	30	700	30	4999	30	3929
7	3	25	30	1300	30	3549
8	30	448	30	3652	30	11241
9	2	18	30	917	30	6173
10	30	942	-	-	30	3248
11	30	2425	-	-	30	1038
12	30	563	-	-	30	1897
13	21	184	-	-	30	886
14	30	1235	-	-	30	1040
15	30	356	-	-	30	7238
16	10	83	-	-	30	1777
Toplam	365	9884	270	42506	480	53649

4.1.1 Yerel İkili Örüntü Parametre Değerlerinin Belirlenmesi

HSG' den YİÖ özniteliklerin elde edilmesi için Eşitlik 2.5 'teki ilgili x_c merkez pikselden komşuluk piksel sayısı ve uzaklığını ifade eden (m,r) çifti incelenmiştir. Ayrıca elde edilecek öznitelikleri YİÖ histogramının elde edileceği x_c merkez pikselin çevresinden alınacak alt görüntü (pencere) boyutu etkilemektedir. YİÖ özniteliklerini elde etmek için (m,r) çifti başlangıçta $(8,1)$ sabit alınarak pencere boyutu belirlenmiştir. Pencere boyutu belirlendikten sonra farklı (m,r) çiftleri denenerek en iyi sınıflandırma doğruluğunu veren (m,r) çifti belirlenmiştir.

Şekil 4.1' de seçilen 17 farklı pencere boyutuna göre ETK-1 örneklerinin DVM ile sınıflandırma sonuçlarının tüm doğruluk değerleri gösterilmiştir. Pencere boyutları kare matris olmak üzere $[(3 \times 3), (5 \times 5), \dots, (35 \times 35)]$ boyutları alınarak x_c merkez piksele ait YİÖ öznitelikler bu alt pencere görüntülerinin YİÖ histogramları hesaplanarak elde edilmiştir. Grafikte görüldüğü üzere Indian Pines ve Pavia University veri kümeleri için en yüksek doğruluğu

(27x27) boyutu ile, Salinas veri kümesi için ise (25x25) boyutu ile en yüksek DVM sınıflandırma başarımı elde edildiği için bu değerler YİÖ öznelik elde etmedeki pencere boyutları olarak belirlenmiştir.



Şekil 4.1: YİÖ pencere boyutlarına göre DVM tüm doğruluk sonuçları.

Tablo 4.2' de Pavia University için farklı (m,r) çiftleri kullanarak ETK-1 örneklerinin DVM ile sınıflandırma doğruluk sonuçları verilmiştir. Pavia University için en yüksek sınıflandırma doğruluğunu (m = 8, r=1) çifti vermiştir.

Tablo 4.2: Pavia University için (m,r) çiftlerine göre DVM ile sınıflandırma doğruluk sonuçları.

	m = 4	m = 6	m = 8	m = 10
r = 1	82,31	86,03	87,01	87,18
r = 2	80,26	85,12	86,42	85,76
r = 3	76,68	84,88	84,60	85,32
Öznelik Sayısı	15	33	59	93

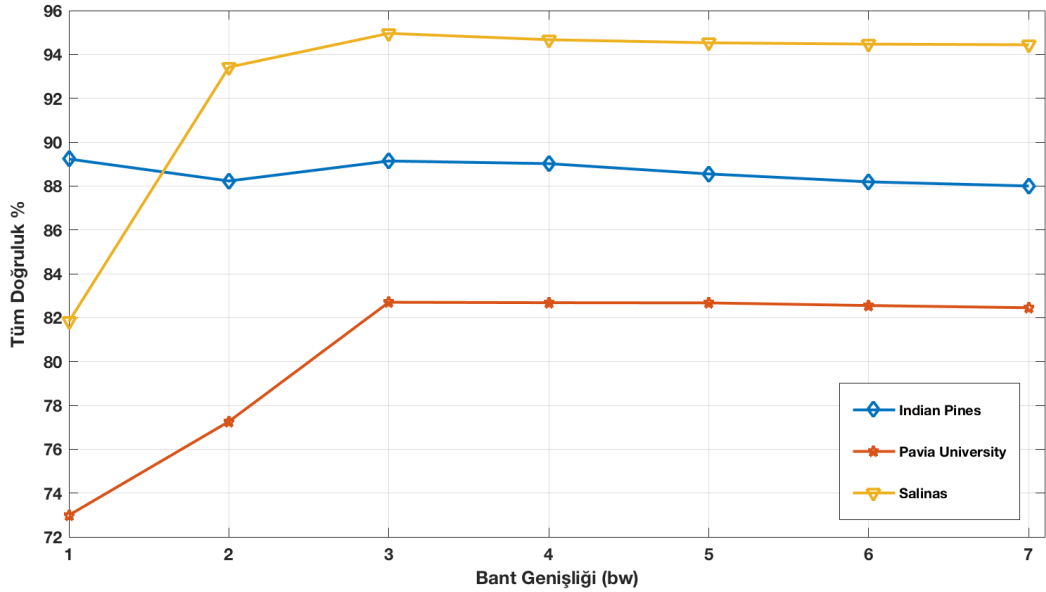
Tüm veri kümeleri için doğruluk sonuçlarına göre (m,r) çiftleri belirlenmiştir ve Tablo 4.3' te bu değerler gösterilmiştir.

Tablo 4.3: YİÖ özneliklerinin elde edilmesinde kullanılan parametreler ve değerleri.

	Indian Pines	Pavia University	Salinas
(m,r)	(6,1)	(8,1)	(8,1)
Pencere Boyutu	27x27	27x27	25x25
Öznelik Sayısı	33	59	59

4.1.2 Gabor Filtresi Parametre Değerlerinin Belirlenmesi

HSG' den Gabor özneliklerin elde edilmesinde Eşitlik 2.10 'daki bw bant genişliğinin etkisi incelenmiştir. θ yönelim açısı bütün veri kümeleri için $[0, \pi/8, \pi/4, 3\pi/8, \pi/2, 5\pi/8, 3\pi/4, 7\pi/8]$ açısal değerleri alınmıştır.



Şekil 4.2: Gabor Filtresi bant genişliğinin (bw) DVM ile sınıflandırma başarımına etkisi.

Şekil 4.2' deki grafikte bant genişliğinin (bw) ETK-1 örneklerinin DVM sınıflandırma başarımına etkisi tüm veri kümeleri için gösterilmiştir. Indian Pines veri kümesi için bw değeri 1 iken, Pavia University ve Salinas veri kümeleri ise için bw değeri 3 iken en yüksek doğruluk

sonucunu vermektedir. Bu nedenle Gabor Filtresi öznelikleri kullanılarak yapılan tüm sınıflandırmalar için en yüksek doğruluk sonucunu veren bw değerleri alınmıştır. Gabor Filtresi sonucu elde edilen öznelik sayısı 1 bant için θ yönelim açılarının sayısı kadardır. Tablo 4.4 'de tüm veri kümeleri için alınan bw değerleri ve 1 bant için elde edilen Gabor öznelik sayısı verilmiştir.

Tablo 4.4: Veri kümeleri için alınan Gabor Filtresi bant genişliği (bw) değerleri.


Veri Kümesi	Indian Pines	Pavia University	Salinas
bw	1	3	3
Öznelik Sayısı (1 bant)	8	8	8

4.1.3 Yönlü Gradyant Histogramı Parametre Değerlerinin Belirlenmesi

HSG' den YGH ile özneliklerin elde edilmesinde hücre boyutu, blok boyutu ve yönelim açılarının sayısı sınıflandırma başarımlarında önemli derecede etkili olmaktadır. Yönelim açıları bütün veri kümelerinde aynı olmak üzere, [0, 20, 40, 60, 80, 100, 120, 140, 160], 9 açı değeri alınmıştır. Ayrıca bütün veri kümeleri için blok boyutu 2x2 alınarak hücre boyutunun sınıflandırma başarımına etkisi incelenmiştir. Farklı hücre boyutları ile yapılan ETK-1 örneklerinin DVM ile sınıflandırma sonuçlarının grafiği Şekil 4.3' te gösterilmiştir. Bu grafikten de görüleceği üzere en yüksek doğruluk değerlerinin Indian Pines veri kümesi için hücre boyutunun 16x16 olduğu Pavia University ve Salinas veri kümeleri için ise 32x32 hücre boyutunun olduğu durumlarda elde edilmiştir.

Tablo 4.5: Veri kümeleri için alınan YGH hücre boyutları.

Veri Kümesi	Indian Pines	Pavia University	Salinas
Blok Boyutu	2x2	2x2	2x2
Hücre Boyutu	16x16	32x32	32x32
Öznelik Sayısı	36	36	36



Şekil 4.3: YGH hüce boyutunun DVM sınıflandırma başarımına etkisi

4.1.4 Spektral ve Uzamsal Sınıflandırma Sonuçları

Tablo 4.1' deki (ETK-1) eğitim ve test örnekleri ile 7 TB bantları DVM kullanılarak yapılan sınıflandırma sonuçları Indian Pines için Tablo 4.6' da, Pavia University için Tablo 4.7' de ve Salinas için Tablo 4.8' de verilmiştir.

Tablo 4.6' daki sınıflandırma sonuçları incelendiğinde Indian Pines veri kümesinde tüm bantlar kullanıldığında %67,02, 7 bant kullanıldığında %65,19 TD elde edilirken uzamsal öznitelikler kullanıldığında başarımları önemli oranda artış göstermiştir. YİÖ için %92,53, Gabor Filtresi için %89,23 ve YGH için %91,25 TD sonuçları elde edilmiştir. Aynı şekilde sınıflandırma güvenilirliğini belirten Kappa metriğinde yüksek bir artış görülmüştür. Çok az sayıdaki eğitim örnek sayılarına sahip 1., 7. ve 9. sınıfları uzamsal öznitelikler ile yapılan sınıflandırma ile yüksek başarımlar elde edilmiştir.

Tablo 4.6: ETK-1 örnekleri kullanılarak yapılan Indian Pines DVM sınıflandırma sonuçları.

Sınıf	Spektral (Tüm Bantlar)	Spektral (7 Bant)	YİÖ	Gabor	YGH
1	46,82	58,78	97,31	95,12	94,63
2	48,55	43,59	90,19	88,50	87,30
3	56,56	60,52	89,65	85,26	86,52
4	70,84	66,80	98,87	97,18	97,51
5	86,18	83,53	96,79	94,37	93,77
6	92,04	86,98	97,25	93,55	93,77
7	65,60	58,80	97,20	97,20	96,80
8	94,53	93,25	99,79	96,62	98,59
9	44,44	52,22	90,00	80,00	83,88
10	70,69	74,74	90,20	86,85	87,80
11	52,95	53,61	88,14	83,88	90,02
12	61,52	51,31	94,45	92,18	93,28
13	97,66	96,03	97,01	96,46	95,86
14	86,51	86,03	95,74	91,27	93,69
15	62,78	42,52	98,96	97,30	98,51
16	88,07	85,90	94,33	93,85	94,33
TD	67,02	65,19	92,53	89,23	91,25
Kappa	0,6287	0,6088	0,9149	0,8774	0,9001

Tablo 4.7’ de Pavia University veri kümesi için verilen DVM sınıflandırma sonuçları incelendiğinde tüm bantlar kullanıldığında %74,81, 7 bant kullanıldığında %73,80 TD elde edilirken uzamsal öznitelikler kullanıldığında başarımları YİÖ için %87,01, Gabor Filtresi için %82,70 ve YGH için %84,60 TD sonuçları elde edilmiştir. Sınıflandırma güvenilirliğini belirten Kappa metriği ile TD arasındaki fark fazla olduğu görülmüştür.

Tablo 4.8’ de Salinas veri kümesinin DVM ile sınıflandırma için tüm bantlar kullanıldığında %85,56, 7 bant kullanıldığında %84,70 TD elde edilmiştir. Uzamsal öznitelikler kullanıldığında başarımları YİÖ için %97,21, Gabor Filtresi için %94,96 ve YGH için %96,66 TD sonuçları elde edilmiştir. Sınıflandırma güvenilirliğini belirten Kappa metriği ile TD birbirleri ile uyumlu olduğu görülmektedir. Eğitim örnek sayıları 30 olup test örnek sayıları çok fazla olan 8. ve 15. sınıfların spektral öznitelik ile sınıflandırma başarımları %60-%67 iken YİÖ ve YGH öznitelikleri ile sınıflandırma başarımları ortalama %94 üstüne çıkmıştır.


Tablo 4.7: ETK-1 örnekleri kullanılarak yapılan Pavia University DVM sınıflandırma sonuçları.

Sınıf	Spektral (Tüm Bantlar)	Spektral (7 Bant)	YİÖ	Gabor	YGH
1	68,35	68,09	75,95	78,59	72,78
2	69,65	69,55	88,79	81,26	86,34
3	69,57	67,31	91,87	82,06	90,68
4	90,15	87,65	71,66	72,37	65,12
5	99,64	99,39	92,12	100,00	87,13
6	76,44	74,14	98,52	89,34	97,62
7	93,03	90,43	96,20	96,30	97,24
8	79,15	75,81	91,31	83,51	90,68
9	99,62	99,96	70,18	93,86	68,25
TD	74,81	73,80	87,01	82,70	84,60
Kappa	0,6825	0,6692	0,8317	0,7781	0,8007

Tablo 4.8: ETK-1 örnekleri kullanılarak yapılan Salinas DVM sınıflandırma sonuçları.

Sını	Spektral (Tüm Bantlar)	Spektral (7 Bant)	YİÖ	Gabor	YGH
1	98,58	98,29	99,32	99,95	99,05
2	99,15	99,09	99,04	99,71	99,82
3	96,73	94,95	99,86	99,41	99,91
4	98,99	98,89	98,65	99,20	97,85
5	96,47	96,06	95,66	98,85	93,85
6	99,45	99,45	95,77	99,96	96,12
7	99,41	99,37	96,60	99,17	95,75
8	60,45	59,15	96,09	86,27	95,52
9	98,64	98,13	99,73	98,26	99,14
10	88,51	85,65	97,72	97,30	95,94
11	94,89	93,19	98,89	99,38	98,74
12	99,49	99,08	96,58	99,69	94,84
13	97,99	97,93	97,91	99,89	97,83
14	93,97	93,15	97,30	99,33	98,34
15	67,37	66,13	94,87	88,44	94,37
16	96,38	95,77	99,90	99,29	98,43
TD	85,56	84,70	97,21	94,96	96,66
Kappa	0,8399	0,8304	0,9689	0,9440	0,9628

DVM ile sınıflandırma sonucu elde edilen yer doğruları Indian Pines için Tablo 4.9' da, Pavia University için Tablo 4.10'da ve Salinas için Tablo 4.11' de verilmiştir. Beyaz renkli pikseller yer doğrusunda sınıfı olmayan ve sınıflandırmaya dahil edilmeyen piksellerdir.

Tablo 4.9: ETK-1 örnekleri ile Indian Pines DVM sınıflandırma yer doğrusu sonuçları.

a) Yer doğrusu




b) Spektral Tüm (%67,02)



c) Spektral 7 bant (%65,19)



d) YIÖ (%92,53)




e) Gabor Filtresi (%89,23)




f) YGH (%91,25)

Tablo 4.10: ETK-1 örnekleri ile Pavia University DVM sınıflandırma yer doğrusu sonuçları.

a) Yer doğrusu




b) Spektral tüm (%74,81)




c) Spektral 7 bant (%73,80)



d) YIÖ (%87,01)




e) Gabor Filtresi (%82,70)




f) YGH (%84,60)

Tablo 4.11: ETK-1 örnekleri ile Salinas DVM sınıflandırma yer doğrusu sonuçları.


a) Yer doğrusu




b) Spektral tüm (%85,56)



c) Spektral 7 bant (%84,70)



d) YIÖ (%97,21)



e) Gabor Filtresi (%94,96)



f) YGH (%96,66)

4.2 ÖZNETELİK BİRLEŞTİRME VE KARAR BİRLEŞTİRME YÖNTEMLERİ İLE SINIFLANDIRMA

Uzamsal öznitelikler kullanılarak DVM ile sınıflandırma başarımlarının spektral öznitelikler kullanılarak DVM ile sınıflandırma başarımlarına göre daha iyi sonuçlar verdiği bir önceki bölümde gösterilmiştir. Bu bölümde ise spektral ve uzamsal özniteliklerin öznitelik birleştirme (ÖB) ve karar birleştirme yöntemleri ile sınıflandırma sonuçlarına yer verilmiştir.

ÖB yöntemi için spektral öznitelikler ile YİÖ, Gabor ve YGH uzamsal öznitelikler ikili ve üçlü olarak vektörel birleştirme yapılmıştır. İkili birleştirme olarak Spektral-YİÖ, Spektral-Gabor, Spektral-YGH, üçlü birleştirmede Spektral-YİÖ-Gabor ve Spektral-YİÖ-YGH ele alınmıştır. Elde edilen birleştirilmiş sonuç öznitelik vektörü DVM ve ESA ile ayrı ayrı sınıflandırılmıştır. Yapılan deneylerde sadece uzamsal öznitelikler kullanılarak yapılan ÖB sınıflandırmaların ayrı ayrı uzamsal öznitelik sınıflandırma sonuçlarına göre kayda değer bir artış olmamıştır.

KB yöntemi ise spektral öznitelikler ile YİÖ, Gabor ve YGH uzamsal öznitelikler ayrı ayrı sınıflandırıldıktan sonra LOGP karar birleştirme yöntemi ile sonuç yer doğrusu ve sınıflandırma başarımları elde edilmiştir. (Spektral, YİÖ, Gabor) ve (Spektral, YİÖ, YGH) sınıflandırmalarının sonuçları KB ile ayrı ayrı iki sonuç halinde verilmiştir. Yapılan deneylerde LOGP yönteminin çoğunluk oylaması, ağırlıklı çoğunluk oylaması ve LOP yöntemlerine göre daha iyi sonuçlar verdiği görülmüştür. Bu tez kapsamında KB olarak verilen sonuçlar LOGP ile elde edilen sonuçlardır.

KB ve ÖB birleştirme yöntemlerini uygulamak için uzamsal özniteliklerin çıkarılması gerekmektedir. Bant çıkarımı ile elde edilen bantlardan YİÖ, Gabor ve YGH yöntemleri ile her bir piksel için uzamsal öznitelikler çıkarılmaktadır. Bu yöntemleri ön işlem olarak değerlendirebiliriz. Ön işlem maliyetini azaltmak gerekir bu da bu yöntemleri mümkün olduğu kadar az HSG bandına uygulamak gerekir. Çünkü bu yöntemler bant çıkarımı ile elde edilen her bir banda ayrı ayrı uygulanmaktadır.

Uzamsal öznitelikleri çıkarmada kullanılacak bantları ve sayısını belirlemek için TBA ile elde edilen bantların kümülatif olarak varyasyonlarından faydalanılabilir. Tablo 3.4' de verilen her bir veri kümesi için ayrı ayrı olarak kümülatif TB varyasyonları incelendiğinde kullanılacak bant sayısı belirlenebilir. Bu tabloya bakıldığında bütün veri kümeleri için kümülatif olarak en az %95 varyasyonu sağlayacak bantlar alınmıştır. Bu nedenle Indian Pines veri kümesi için ilk

5 TB bandı, Pavia University veri kümesi için ilk 3 TB bileşen bandı ve Salinas veri kümesi için ilk 2 TB bandı alınmıştır. Eğitim ve test örnek sayıları Indian Pines veri kümesi için toplam örnek sayısının %10'u, Pavia University ve Salinas veri kümeleri için her sınıftan 200 örnek alınmıştır ve Tablo 4.9' da eğitim ve test için alınan örnek sayıları verilmiştir.

ÖB yönteminde spektral öznelik olarak alınan bantlar uzamsal öznelik çıkarmada kullanılan bantlar olarak alınmıştır. Bu durumda ÖB yönteminde Indian Pines için ilk 5 TB bandı, Pavia University için ilk 3 TB bandı ve Salinas için ilk 2 TB bandı spektral öznelik olarak alınmıştır. KB yönteminde ise veri kümelerindeki tüm bantlar spektral öznelikler olarak alınmıştır.


Tablo 4.12: Eğitim Test Kümesi – 2 (ETK-2)

Veri Küm.	Indian Pines		Pavia University		Salinas	
	Sınıf	Eğitim	Test	Eğitim	Test	Eğitim
1	5	41	200	6431	200	1809
2	143	1285	200	18449	200	3526
3	83	747	200	1899	200	1776
4	24	213	200	2864	200	1194
5	49	434	200	1145	200	2478
6	73	657	200	4829	200	3759
7	3	25	200	1130	200	3379
8	48	430	200	3482	200	11071
9	2	18	200	747	200	6003
10	98	874	-	-	200	3078
11	246	2209	-	-	200	868
12	60	533	-	-	200	1727
13	21	184	-	-	200	716
14	127	1138	-	-	200	870
15	39	347	-	-	200	7068
16	10	83	-	-	200	1607
Toplam	1031	9218	1800	40976	3200	50929



Tablo 4.13: Indian Pines ETK-2 örnek sayılarına göre sınıflandırma sonuçları.

	DVM		ESA	
	TD	Kappa	TD	Kappa
Spekt. Tüm Bantlar	79,78	0,7678	76,98	0,7360
Spekt-5 Bant	68,47	0,6349	66,37	0,6128
YİÖ	98,79	0,9862	98,09	0,9782
Gabor	97,50	0,9715	97,45	0,9709
YGH	98,08	0,9781	97,90	0,9761
ÖB (Spekt.-YİÖ)	99,07	0,9894	98,59	0,9839
ÖB (Spekt.-Gabor)	97,69	0,9736	98,30	0,9806
ÖB (Spekt.-YGH)	98,40	0,9817	98,29	0,9805
ÖB (Spekt.-YİÖ-Gabor)	99,16	0,9904	98,69	0,9851
ÖB (Spekt.-YİÖ-YGH)	99,09	0,9896	98,61	0,9841
KB (Spekt.,YİÖ,Gabor)	98,80	0,9863	98,89	0,9873
KB (Spekt.,YİÖ,YGH)	98,84	0,9868	98,98	0,9883

Tablo 4.13' de Indian Pines için hem DVM hem de ESA ile sınıflandırma sonuçları yer almaktadır. Genel olarak ESA ve DVM sınıflandırma sonuçları birbirlerine çok yakın olmakla beraber bazı durumlarda DVM daha iyi sonuç verirken bazı durumlarda ESA daha iyi sonuç verdiği görülmektedir. DVM ile sınıflandırmada en yüksek TD sonucu ÖB ile oluşturulan Spektral-YİÖ-Gabor öznelik vektörünün sınıflandırıldığı durum olmuştur. ESA ile sınıflandırmada en yüksek TD sonucu ise (Spektral,YİÖ,YGH) özneliklerinin sınıflandırıldıktan sonra sonucun KB yöntemi ile elde edildiği durum olmuştur.

Tablo 4.14: Indian Pines DVM ve ESA sınıflandırma yer doğrusu sonuçları.

a) Yer Doğrusu

b) DVM –
ÖB(Spekt.-YİÖ-Gabor)
(%99,16)c) ESA -
KB(Spekt.,YİÖ,YGH)
(%98,98)

Tablo 4.15: Pavia University ETK-2 örnek sayılarına göre sınıflandırma sonuçları.

	DVM		ESA	
	TD	Kappa	TD	Kappa
Spekt. Tüm Bantlar	89,32	0,8591	89,60	0,8626
Spekt-3 Bant	72,69	0,6527	71,10	0,6350
YİÖ	97,69	0,9690	96,74	0,9564
Gabor	86,71	0,8275	86,82	0,8287
YGH	97,48	0,9662	97,01	0,9600
ÖB (Spekt.-YİÖ)	99,50	0,9933	98,65	0,9819
ÖB (Spekt.-Gabor)	91,37	0,8860	92,79	0,9045
ÖB (Spekt.-YGH)	98,74	0,9831	99,03	0,9870
ÖB (Spekt.-YİÖ-Gabor)	99,68	0,9958	99,10	0,9879
ÖB (Spekt.-YİÖ-YGH)	99,63	0,9950	98,95	0,9859
KB (Spekt.,YİÖ,Gabor)	99,56	0,9941	99,47	0,9929
KB (Spekt.,YİÖ,YGH)	99,53	0,9938	99,53	0,9937

Pavia University veri kümesinin hem DVM hem de ESA ile sınıflandırma sonuçları Tablo 4.14' de verilmiştir. Spektral tüm bantların kullanıldığı sınıflandırmada ESA yaklaşık %3 gibi bir oranla DVM ile sınıflandırmadan daha yüksek başarımler elde edilmiştir. DVM ile sınıflandırmada en yüksek TD ÖB(Spekt.-YİÖ-Gabor) ile elde edilmiştir. ESA ile sınıflandırmada en yüksek TD ise Indian Pines veri kümesinde olduğu gibi KB yöntemi ile elde edilen sonuçlar olmuştur. ESA'nın sonuçları kendi içinde değerlendirildiğinde KB yöntemi ÖB birleştirme yönteminden daha iyi sonuçlar vermiştir.

Tablo 4.16: Pavia University DVM ve ESA sınıflandırma yer doğrusu sonuçları.

a) Yer Doğrusu

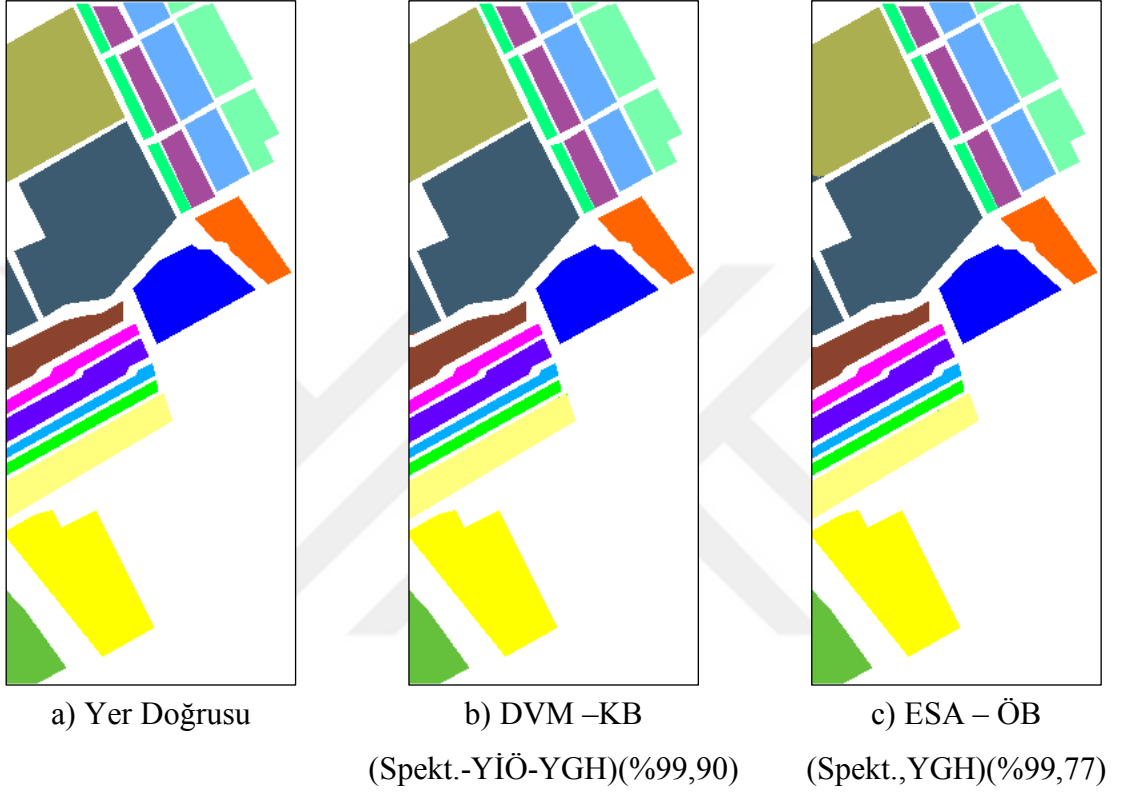
c) DVM – ÖB
(Spekt., YİÖ, Gabor)(%99,68)c) ESA – KB
(Spekt., YİÖ, Gabor)(%99,53)**Tablo 4.17:** Salinas ETK-2 örnek sayılarına göre sınıflandırma sonuçları.

	DVM		ESA	
	TD	Kappa	TD	Kappa
Spekt. Tüm Bantlar	91,02	0,8996	89,80	0,8861
Spekt-2 Bant	81,88	0,7980	79,29	0,7698
YİÖ	99,57	0,9952	99,20	0,9911
Gabor	94,03	0,9333	93,04	0,9223
YGH	99,75	0,9972	99,68	0,9964
ÖB (Spekt.-YİÖ)	99,57	0,9952	99,40	0,9933
ÖB (Spekt.-Gabor)	93,41	0,9264	94,70	0,9407
ÖB (Spekt.-YGH)	99,86	0,9984	99,77	0,9975
ÖB (Spekt.-YİÖ-Gabor)	99,62	0,9957	99,58	0,9953
ÖB (Spekt.-YİÖ-YGH)	99,59	0,9954	99,65	0,9960
KB (Spekt., YİÖ, Gabor)	99,61	0,9957	99,23	0,9914
KB (Spekt., YİÖ, YGH)	99,90	0,9989	99,74	0,9970

Salinas veri kümesine ait DVM ve ESA ile sınıflandırma sonuçlarına Tablo 4.15' de yer verilmiştir. DVM ile sınıflandırmada en yüksek başarımlar KB(Spekt., YİÖ, YGH) ile elde edilirken ESA ile sınıflandırmada en yüksek başarımlar ÖB(Spekt.-YGH) ile elde edilmiştir. Tek başına YGH öznelikleri kullanılıp hem DVM hem de ESA ile sınıflandırma yapıldığında oldukça iyi sonuçlar vermektedir. Hem ÖB hem de KB yöntemleri her iki sınıflandırma yöntemlerinde

de başarıyı artırmakla beraber YİÖ ve YGH öznitelikleri ile sınıflandırmalar %99,50' nin üzerinde TD sonuçları elde edilmiştir.

Tablo 4.18: Salinas DVM ve ESA sınıflandırma yer doğrusu sonuçları.



4.3 PERFORMANS DEĞERLENDİRMESİ

Hiperspektral görüntüleme uzamsal özniteliklerin elde edilmesi ön işlem olarak sınıflandırma maliyeti oluşturmaktadır. Ayrıca hem DVM hem de ESA ile sınıflandırmada sınıflandırıcıların eğitimleri için alınan örnek sayıları sınıflandırma başarımını etkilemektedir. Bu bölümde uzamsal özniteliklerin elde edilmesinde süre bakımından maliyetlerinin, sınıflandırma işlemlerinin eğitim ve test sürelerinin ve ESA için eğitim tur (epoch) etkisinin değerlendirilmeleri yer almaktadır.

Tablo 4.19: TBA ve uzamsal öznitelik yöntemlerinin 1 bant için saniye cinsinden süreleri.


Yöntem	Indian Pines	Pavia University	Salinas
TBA	0,158 sn	0,337 sn	0,341 sn
YİÖ	0,956 sn	3,597 sn	4,079 sn
Gabor	0,625 sn	0,827 sn	0,672 sn
YGH	7,160 sn	35,202 sn	44,380 sn

Tablo 4.19’ da çalışma kapsamında yapılan deneylerde kullanılan veri kümelerinde TBA ile bant çıkarımı için geçen süre ve çıkarılan 1 banttan uzamsal özniteliklerin elde edilmesi için geçen süreler yer almaktadır. TBA ile bant çıkarımı için geçen süre veri kümesinin büyüklüğüne göre en fazla Salinas veri kümesine en az ise Indian Pines veri kümesine ait olmaktadır. Uzamsal öznitelik çıkarım yöntemlerinden işlem ve süre bakımından en maliyetli olan yöntem YGH yöntemidir. YGH yönteminde sınıflandırılacak her bir piksel için lokal YHG uygulandığı için süre maliyeti diğer yöntemlere göre oldukça yüksek olmaktadır. En fazla örnek sayısı Salinas veri kümesinde olduğu için bir banttan YGH öznitelikleri için geçen süre 44 saniyeden fazla olduğu görülmektedir. YGH yönteminin sınıflandırma başarımı YİÖ’ ye yakın yüksek bir değer olduğu deneylerde görülmüştür.

Tablo 4.20: DVM ve ESA ile ÖB(Spekt.-YİÖ-Gabor) sınıflandırmada eğitim ve test süreleri.

		Indian Pines	Pavia University	Salinas
DVM	Eğitim	0,277 sn	0,368 sn	0,789 sn
	Test	1,532 sn	8,538 sn	11,155 sn
ESA	Eğitim	127,419 sn	224,818 sn	290,533 sn
	Test	1,494 sn	6,239 sn	5,754

Tablo 4.20’ de DVM ve ESA ile ÖB(Spekt.-YİÖ-Gabor) öznitelik vektörü kullanılarak yapılan sınıflandırmadaki eğitim ve test süreleri yer almaktadır. Bu süreler Tablo 4.12’deki ETK-2 eğitim ve test kümesine ait sonuçlardır. Indian Pines için 5 bant, Pavia University için 3 bant ve Salinas için 2 bant spektral-uzamsal öznitelikler kullanılarak sınıflandırma yapılmıştır. Tablo 4.20’ deki süreler incelendiğinde ESA ile sınıflandırmada eğitim için geçen süre DVM’ e göre çok yüksek olmaktadır ancak test süreleri DVM ile sınıflandırmaya göre daha az olduğu görülmektedir.



Şekil 4.4: ESA tur (epoch) sayımın doğruluk-hata grafiği.

Şekil 4.4 'de ESA ile Indian Pines veri kümesinin Tablo 4.12'deki eğitim ve test kümesinin 5 bant özniteliklerinin ÖB(Spekt.-YİÖ-Gabor) sınıflandırılmasında eğitim tur (epoch) sayısının doğruluk – hata grafiği yer almaktadır. Tur sayısı 10 olduğunda %95 civarında başarı sağlarken en iyi değer 300 olduğu yapılan deneylerde görülmüştür bu nedenle ESA ile yapılan tüm sınıflandırmalarda tur sayısı 300 olarak alınmıştır.

Bu bölümde son olarak DVM veya ESA ile sınıflandırma yapılırken alınan eğitim ve test için alınan oranların sınıflandırma başarılarına etkisi incelenmiştir. Sınıflandırmalar sonuçları ÖB(Spekt.-YİÖ-Gabor) ile alınan değerlerdir. Indian Pines veri kümesinde bazı sınıflara ait toplam örnek sayıları çok az olup sınıfların toplam örnek sayıları arasındaki fark çok fazladır. Bu nedenle Indian Pines veri kümesi için sınıflandırma deneylerinde eğitim kümesi toplam örnek kümesinin oranları olarak alınmıştır. Indian Pines' da eğitim için alın örnek sayısı her bir sınıfa ait toplam örnek sayısının %1, %5, %10, %15, %20, %30 ve %35'i olarak belirlenerek sınıflandırma başarımları incelenmiştir. Pavia University ve Salinas için ise her bir sınıftan eğitim için alınan örnek sayıları 5, 10, 20, 30, 50, 100, 200, 300 olarak alınmış ve eğitim için alınan örnek sayısının sınıflandırma başarımına etkisi değerlendirilmiştir.

Tablo 4.21: Indian Pines için alınan eğitim kümesi oranının sınıflandırma başarımına etkisi.

Eğitim Oranı (%)	DVM	ESA
1	88,45	83,09
5	97,74	95,94
10	99,16	98,57
15	99,53	99,28
20	99,66	99,55
25	99,76	99,76
30	99,82	99,82
35	99,87	99,89

Tablo 4.21' de Indian Pines için alınan eğitim kümesinin oranlarına göre DVM ve ESA ile sınıflandırma sonuçları yer almaktadır. Eğitim oranı %10 olarak alındığında DVM ve ESA iyi sonuçlar verirken eğitim için alınan oranın artması ESA sonuçlarını daha da başarılı hale getirdiği görülmektedir.

Tablo 4.22: Pavia University ve Salinas için alınan örnek sayılarına göre sonuçlar.

Eğitim Örnek Sayısı	Pavia University		Salinas	
	DVM	ESA	DVM	ESA
5	76,94	59,90	85,06	79,27
10	86,08	73,03	91,70	87,01
20	91,87	83,06	95,49	93,62
30	95,26	89,15	97,05	95,61
50	97,70	93,53	98,40	97,47
100	98,93	97,19	99,14	98,83
200	99,68	99,10	99,62	99,58
300	99,79	99,49	99,72	99,78

Tablo 4.22' de Pavia University ve Salinas için alınan eğitim örnek sayılarına göre DVM ve ESA ile sınıflandırma sonuçları yer almaktadır. Eğitim örnek sayısı 200 olarak alındığında DVM ve ESA iyi sonuçlar verirken eğitim örnek sayısının artması ESA sonuçlarını daha da başarılı hale getirdiği görülmektedir.

5. TARTIŞMA VE SONUÇ

Hiperspektral görüntüler içerdikleri nesnelere ait spektral imzalar sayesinde nesnelere ait ayırt edici özellik niteliği taşımaktadır. Spektral imza özelliğinden yararlanılarak hiperspektral görüntüleri sınıflandırılabilir. Spektral özniteliklerin yanında hiperspektral görüntüden elde edilecek uzamsal özniteliklerin kullanılması sınıflandırma başarımını artırmaktadır.

Bu tez çalışması kapsamında hiperspektral görüntülerin sınıflandırılmaları üzerinde çalışılmıştır. Hiperspektral görüntülerin içerdikleri spektral bilgilerin yanında bu görüntülerden elde edilecek uzamsal bilgiler kullanılarak eğitilmiş öğrenme yaklaşımı ile sınıflandırma yapılmıştır. Hiperspektral görüntüler çok sayıda banttandır oluştuğu için en ayırt edici bantların çıkarılması için Temel Bileşen Analizi yöntemi ile yapılmıştır. Bant çıkarımından sonra elde edilen bant görüntülerinden Yerel İkili Örüntü, Gabor Filtresi ve Yönlü Gradyant Histogramu yöntemleri ile uzamsal bilgiler elde edilmiştir. Elde edilen spektral ve uzamsal öznitelikler kullanılarak Destek Vektör Makineleri ve Evrimsel Sinir Ağları ile eğitilmiş sınıflandırma yaklaşımı ile hiperspektral görüntünün sınıflandırılması yapılmıştır. Sınıflandırma için öznitelik birleştirme ve karar birleştirme yöntemleri uygulanarak sınıflandırma başarımı artırılmıştır. Sınıflandırma deneyleri Indian Pines, Pavia University ve Salinas hiperspektral veri kümeleri kullanılarak yapılmıştır.

Spektral ve uzamsal öznitelikler ayrı ayrı sınıflandırıldığında genel olarak en yüksek tüm doğruluk oranları YİÖ ile elde edilmiştir. Yapılan literatür taramasında YGH ile uzamsal öznitelikler kullanılarak yapılan sınıflandırma çalışmasına rastlanmamıştır. Sadece YGH uzamsal öznitelikleri kullanarak yapılan sınıflandırmada Salinas veri kümesinde diğer uzamsal öznitelikler ile yapılan sınıflandırmalardan daha yüksek başarımler elde edilmiştir. Diğer veri kümelerinde ise YGH sonuçları YİÖ sonuçlarına çok yakın olmaktadır. Bu sonuçlardan da anlaşıldığı üzere YGH uzamsal öznitelikleri ile sınıflandırmada yüksek doğruluk sonuçları elde edilmiştir. Gabor Filtresi ile elde edilen uzamsal öznitelikler sınıflandırma başarımları YİÖ ve YGH kadar yüksek olmasa da öznitelik birleştirme ve karar birleştirme yöntemleri uygulandığında tüm doğruluk sonuçlarını daha da iyileştirdiği görülmüştür. Uzamsal özniteliklerin elde edilmesinde en az işlem süresi Gabor Filtresine, en yüksek işlem süresi ise YGH yöntemine ait olduğu işlem süresi maliyeti ölçümlerinde gösterilmiştir.

Indian Pines veri kümesinde en yüksek başarımlar oranı %99,16 tüm doğruluk oranı ile DVM ve Spektral, YİÖ ve Gabor Filtresi ile elde edilen özneliklerin birleştirilmesi yaklaşımı ile elde edilmiştir. ESA ile sınıflandırmada Spektral, YİÖ ve YGH özneliklerinin ayrı ayrı sınıflandırıldıktan sonra karar birleştirme yaklaşımı ile %98,98 tüm doğruluk oranı elde edilmiştir.

Pavia University veri kümesinde en yüksek başarımlar oranı DVM ve öznelik birleştirme ile %99,68 tüm doğruluk oranı elde edilmiştir. ESA ile sınıflandırmada Spektral, YİÖ ve Gabor özneliklerinin ayrı ayrı sınıflandırıldıktan sonra karar birleştirme yaklaşımı ile %99,53 tüm doğruluk oranı elde edilmiştir.

Son olarak Salinas veri kümesinde en yüksek başarımlar oranı DVM ve karar birleştirme ile %99,90 tüm doğruluk oranı elde edilmiştir. ESA ile sınıflandırmada Spektral, YİÖ ve Gabor özneliklerinin öznelik birleştirme yaklaşımı ile %99,77 tüm doğruluk oranı elde edilmiştir.

Çalışma kapsamında yapılan deneylerde spektral ve uzamsal özneliklerin kullanılarak sınıflandırmanın yapılması başarımlar oranını artırdığı verilen sonuçlardan görülmektedir. Öznelik birleştirme yaklaşımının özellikle daha düşük oranlarda eğitim kümesi alındığında tüm doğruluk sonucuna etkisinin daha yüksek olduğu yani sınıflandırma başarımlarını daha yüksek oranda artırdığı görülmüştür. Karar birleştirme yönteminin en iyi sonuç verdiği veri kümesi Salinas olmuştur. LOGP yöntemi kullanılarak karar birleştirme yaklaşımı çoğunluk oylaması, ağırlıklı çoğunluk oylaması, en büyük çıktı olasılığı veya LOP yöntemlerine göre daha yüksek başarımlar sonuçları yapılan deneyler ile gözlemlenmiştir.

DVM ve önerdiğimiz ESA ağlarında sınıflandırma başarımlarını arasında kıyaslama yaptığımızda ise yapılan deneylerde DVM ile daha yüksek tüm doğruluk değerleri elde edilmiştir. DVM az sayıda alınan eğitim örnek sayılarında daha yüksek başarımlar sağlamıştır. ESA ile sınıflandırmada ise alınan eğitim örnek sayıları fazla olduğu takdirde sınıflandırma sonuçlarının yüksek olduğu görülmüştür. DVM makinelerinin eğitim süresi tüm veri kümelerinde önerdiğimiz ESA eğitim süresinden çok daha az olduğu görülmekle birlikte test sürelerinin ESA ile yapılan sınıflandırmalarda daha az olduğu görülmüştür. Önerdiğimiz ESA eğitimi sırasında çalışma ortamımızdaki grafik işlemcilerinden faydalanılamaması eğitim süresinin biraz daha yüksek olmasına neden olmakla birlikte literatürdeki ESA veya diğer derin

öğrenme yöntemleri ile sınıflandırma çalışmalarına göre genel olarak düşük süre olduğunu belirtmek gerekir.

Tez çalışması kapsamında yaptığımız deneylerde az sayıda bant görüntüsü ve az sayıda eğitim örnek sayısı olarak yapılan sınıflandırmalarda yüksek başarımlar elde edilmiştir. Ayrıca öznelik birleştirme ve karar birleştirme yöntemlerini uygulayarak sınıflandırma başarımlarını artırdığımız sunduğumuz sonuçlardan anlaşılmaktadır. İlerleyen çalışmalarımızda günümüzde popüler olan derin öğrenme yöntemleri ile hiperspektral görüntü sınıflandırmada daha yüksek başarımların elde edilmesi üzerinde çalışılacaktır.



KAYNAKLAR

- [1]. Liew, S. C., 2001, *Optical Remote Sensing*, <https://crisp.nus.edu.sg/~research/tutorial/optical.htm>, [Ziyaret Tarihi: 3 Nisan 2018].
- [2]. Wikipedia, 2018, *Elektromanyetik tayf*, http://tr.wikipedia.org/wiki/Elektromanyetik_tayf, [Ziyaret Tarihi: 12 Nisan 2018].
- [3]. Gerçek, D., Çeşmeci, D., Güllü, M. K., Ertürk, A., Ertürk, S., 2013, Hiperspektral Görüntüleme ve Görüntü İşlemenin Bugünü, Yakın Geleceği ve Mevcut Araştırma Eğilimleri, *XYZ*.
- [4]. Randall B. S., 2012, "Introduction to Hyperspectral Imaging".
- [5]. *Hyperspectral Remote Sensing Scenes*, http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes, [Ziyaret Tarihi: 4 Mart 2018].
- [6]. Bilgin, G., 2009, *Hiperspektral Görüntülerin Eğitimsiz Bölütlenmesi*, Doktora, Yıldız Teknik Üniversitesi.
- [7]. Hughes, G.F., 1968, On the Mean Accuracy of Statistical Pattern Recognizers, *IEEE Transactions on Information Theory*, vol.14, no.1, 55-63.
- [8]. Demir, B., 2010, *Hiperspektral görüntülerin yüksek doğruluklu sınıflandırılması*, Doktora, Kocaeli Üniversitesi.
- [9]. Tan, K., Li, E., Du, E.Q. and Du, P., 2014, Hyperspectral Image Classification Using Band Selection and Morphological Profiles, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 1, pp. 40-48.
- [10]. Akyürek, Ö., 2012, *Hiperspektral Görüntülerde Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi*, Yüksek Lisans, Kocaeli Üniversitesi.
- [11]. KOZAL, A. Ö., 2014, *Hiperspektral Veri Sınıflandırma İçin Boyut İndirgeme Yöntemlerinin Başarımlarının Karşılaştırılması*, Yüksek Lisans, Ankara Üniversitesi.
- [12]. Rodarmel, C. and Shan, J., 2002, Principal Component Analysis for Hyperspectral image classification, *Surveying and Land Information Systems*, vol. 62, No. 2, pp.115-122.
- [13]. Ojala, T., Pietikainen, M., Maenpaa, T. T., 2002, Multiresolution grayscale and rotation invariant texture classification with local binary Patterns, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, pp. 971–987.
- [14]. Nabiyev, V. V. ve Günay, A., 2010, LBP yardımıyla görüntüdeki kişinin yaşının bulunması, *Çankaya University Journal of Science and Engineering*, 8(1).
- [15]. Nabiyev, V. V. ve Koçak, F., 2011, Yerel İkili Örneklerle Yüz Güzelliği Kararı, *Elektrik-Elektronik ve Bilgisayar Sempozyumu*.

- [16]. Li, W., Chen, C., Su, H.J. and Du, Q. 2015, Local binary patterns and extreme learning machine for hyperspectral image classification, *IEEE Trans. Geosci. Remote Sens.*, vol. 30, pp. 3681–3693, 2015.
- [17]. Claudi, D. A. and Jernigan, M. E., Nov. 2000, Designing Gabor filters for optimal texture separability, *Pattern Recognit.*, vol. 33, no. 11, pp. 1835–1849.
- [18] Dalal, N. and Triggs, B., 2005, Histograms of oriented gradients for human detection, 2005, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, CA, USA, vol. 1, pp. 886-893
- [19]. Boser, B. E., Guyon, I.M. and Vapnik, V., 1992, A training algorithm for optimal margin classifiers, *Proc. 5th Annu. ACM Workshop Comput. Learn. Theory*, pp. 144–152.
- [20]. Melgani, F. and Lorenzo, B., 2004, Classification of hyperspectral remote sensing images with support vector machines, *IEEE Trans. Geosci. Remote Sens.*, vol. 42, no. 8, pp. 1778–1790.
- [21]. Gualtieri, J. A. and Chettri, S., 2000, Support vector machines for classification of hyperspectral data, in *Proc. IEEE Geosci. Remote Sens. Symp. (IGARSS)*, Honolulu, HI, USA, pp. 813–815
- [22]. Fauvel, M., Benediktsson, J. A., Chanussot, J. and Sveinsson, J. R., 2008, Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles, *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 11, pp. 3804–3814.
- [23] Akin, B., 2017, *Yapay Sinir Ağlarıyla Konya Bölgesinde Kullanıcı Doğal Gaz Tüketim Öngörüsü*, Yüksek Lisans, İstanbul Teknik Üniversitesi.
- [24] Karpathy, A., *CS231n Convolutional Neural Networks for Visual Recognition*, <http://cs231n.github.io/convolutional-networks/> [Ziyaret Tarihi: 10 Mayıs 2018].
- [25]. LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324.
- [26]. Krizhevsky, A., Sutskever, I. and Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097-1105.
- [27]. Artificial intelligence, <https://leonardoaraujosantos.gitbooks.io/artificial-inteligence/content/>, [Ziyaret Tarihi: 11 Şubat 2018].
- [28]. Hu, W., Huang, Y., Wei, L., Zhang, F., and Li, H., 2015, Deep Convolutional Neural Networks for Hyperspectral Image Classification, *Journal of Sensors*, vol. 2015, Article ID 258619, 12 pages.
- [29]. Boureau, Y.-L., Ponce, J. and Lecun, Y., 2010, A theoretical analysis of feature pooling in visual recognition, *27. International Conference on Machine Learning*, Haifa, Israel.

- [30]. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958.
- [31]. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. R., 2012, Improving neural networks by preventing coadaptation of feature detectors, *Comput. Sci.*, vol. 3, no. 4, pp. 212–223.
- [32]. Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1988, Learning representations by backpropagating errors. *Cognitive modeling*, 5(3):1.
- [33]. Chen, Y., Jiang, H., Li, C., Jia, X. and Ghamisi, P., 2016, Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 6232-6251.
- [34]. Nair, V. and Hinton, G. E., 2010, Rectified Linear Units Improve Restricted Boltzmann Machines..., ICML.
- [35]. He, K., Zhang, X., Ren, S. and Sun, J., 2015, Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, *IEEE International Conference on Computer Vision (ICCV 2015)*.
- [36]. Sokolova, M., Lapalme, G., 2009, A systematic analysis of performance measures for classification tasks, *Information Processing & Management*, Volume 45, Issue 4, Pages 427-437, ISSN 0306-4573.
- [37]. Labatut, V. and Cherifi, H., 2011, Evaluation of Performance Measures for Classifiers Comparison.
- [38]. Cohen, J., 1960, A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, pages 37–46.
- [39]. Demir, B., Ertürk, S., 2007, Hyperspectral image classification using relevance vector machines, *IEEE Geoscience and Remote Sensing Letters*, 4, 586-590.
- [40]. Chen, C., Li, W., Su, H. and Liu, K., 2014, Spectral-Spatial Classification of Hyperspectral Image Based on Kernel Extreme Learning Machine, *Remote Sensing 6* : 5795-5814.
- [41]. Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J. and Calpe-Maravilla, J., 2006, Composite kernels for hyperspectral image classification, *IEEE Geoscience and Remote Sensing Letters*, vol. 3, no. 1, pp. 93-97.
- [42]. Benediktsson, J.A., Palmason J.A., Sveinsson, J.R., 2005, Classification of hyperspectral data from urban areas based on extended morphological profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 480-491.
- [43]. Li, S., 2009, Markov Random Field Modeling in Image Analysis. Berlin, Germany: Springer-Verlag.

- [44]. Eches, O., Benediktsson, J. A., Dobigeon, N. and Tourneret, J. Y., 2013, Adaptive Markov Random Fields for Joint Unmixing and Segmentation of Hyperspectral Images, *IEEE Transactions on Image Processing*, vol. 22, no. 1, pp. 5-16
- [45]. Tarabalka, Y., Fauvel, M., Chanussot, J. and Benediktsson, J. A., 2010, SVM and MRF-based method of accurate classification of hyperspectral images, *IEEE Geosci. Remote Sens. Lett.*, vol. 7, no. 4, pp. 736–740.
- [46]. Li, W., and Du, Q., 2014, Gabor-Filtering Based Nearest Regularized Subspace for Hyperspectral Image Classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 4, pp. 1012-1022.
- [47]. Zhang, L., Zhang, L., Tao, D., Huang, X., 2012, On combining multiple features for hyperspectral remote sensing image classification. *IEEE Trans. Geosci. Remote Sens.*, 50, 879–893.
- [48]. Li, W., Chen, C., Su, H.J. and Du, Q., 2015, Local binary patterns and extreme learning machine for hyperspectral image classification, *IEEE Trans. Geosci. Remote Sens.*, vol. 30, pp. 3681–3693.
- [49]. Kumar, B., and Dikshit, O., 2017, Hyperspectral image classification based on morphological profiles and decision fusion, *International Journal of Remote Sensing*, 38:20, 5830-5854.
- [50]. Ghamisi, P., Plaza, J., Chen, Y., Li, J. and Plaza, A. J., 2017, Advanced Spectral Classifiers for Hyperspectral Images: A review, *IEEE Geoscience and Remote Sensing Magazine*, vol. 5, no. 1, pp. 8-32.
- [51]. Chen, Y., Zhao, X. and 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*, vol. 8, no. 6, pp. 2381-2392.
- [52]. Mei, S., Ji, J., Hou, J., Li, X. and Du, Q., 2017, Learning Sensor-Specific Spatial-Spectral Features of Hyperspectral Images via Convolutional Neural Networks, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 8, pp. 4520-4533.
- [53]. Lee, H. and Kwon, H., 2017, Going Deeper With Contextual CNN for Hyperspectral Image Classification, *IEEE Transactions on Image Processing*, vol. 26, no. 10, pp. 4843-4855.
- [54]. Yu, S., Jia, S. and Xu, C., 2017, Convolutional neural networks for hyperspectral image classification, *Neurocomputing*, Volume 219, Pages 88-98, ISSN 0925-2312.
- [55]. Li, Y., Zhang, H. and Shen, Q., 2017, Spectral–Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network, *Remote Sensing*. 9. 67.
- [56]. Zhong, Z., Li, J., Luo, Z. and Chapman, M., 2018, Spectral–Spatial Residual Network for Hyperspectral Image Classification: A 3-D Deep Learning Framework, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 56, no. 2, pp. 847-858.

- [57]. Chen, Y., Zhu, L., Ghamisi, P., Jia, X., Li, G. and Tang, L., 2017, Hyperspectral Images Classification With Gabor Filtering and Convolutional Neural Network, *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 12, pp. 2355-2359.
- [58]. Zhou, Y., Peng, J. and Chen, C. L. P., 2015, Extreme Learning Machine With Composite Kernels for Hyperspectral Image Classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2351-2360.
- [59]. Li, W., Prasad, S. and Fowler, J. E., 2014, Decision Fusion in Kernel-Induced Spaces for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 6, pp. 3399-3411.
- [60]. Ye, Z., Bai, L. and Nian, Y., 2017, Decision fusion for hyperspectral image classification based on multiple features and locality-preserving analysis, *European Journal of Remote Sensing*, 50:1, 166-178.
- [61]. Ioffe, S. and Szegedy, C., 2015, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *Proceedings of the 32Nd International Conference on International Conference on Machine Learning*, Volume 37, pages 448-456.
- [62]. X. Cao and F. Zhou and L. Xu and D. Meng and Z. Xu and J. Paisley, 2018, Hyperspectral Image Classification With Markov Random Fields and a Convolutional Neural Network, *IEEE Transactions on Image Processing*, volume 27, number 5, pages 2354-2367.
- [63]. Chollet, F. and others, Keras, <https://keras.io>, [Ziyaret Tarihi: 4 Mayıs 2018].
- [64]. Bottou, L., 2010, Large-scale machine learning with stochastic gradient descent, *Proceedings of COMPSTAT'2010*, Eds. Physica-Verlag HD, pp. 177-186.
- [65]. Chang, C.C. and Lin, C.J., 2011, LIBSVM : a library for support vector machines, *ACM Transactions on Intelligent Systems and Technology*, 2:27:1-27:27.
- [66]. Pedregosa et al., 2011, Scikit-learn: Machine Learning in Python, *JMLR* 12, pp. 2825-2830.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Fatih Mehmet TEKCAN
Doğum Yeri	ELAZIĞ
Doğum Tarihi	08.01.1986
Uyruğu	<input checked="" type="checkbox"/> T.C. <input type="checkbox"/> Diğer:
Telefon	5076215699
E-Posta Adresi	fntekcan@hotmail.com
Web Adresi	https://www.linkedin.com/in/fatih-mehmet-tekcan-8341465a

Eğitim Bilgileri	
Lisans	
Üniversite	Karadeniz Teknik Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Bilgisayar Mühendisliği
Mezuniyet Yılı	22.01.2010

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Bilgisayar Mühendisliği Anabilim Dalı
Programı	Bilgisayar Mühendisliği Programı

Makale ve Bildiriler	
Tekcan, F.M., Ensari, T., Sertbaş, A., 2018, Hyperspectral Image Classification with Spectral-Spatial Feature Extraction Methods, <i>The Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT'2018)</i> , 18 – 19 April 2018 İstanbul, İstanbul Arel University.	