KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

HİPERSPEKTRAL GÖRÜNTÜLERİN FARKLI UZAYLARDA SÜPERPİKSEL TABANLI SPEKTRAL SINIFLANDIRILMASI

SİNEM AYBÜKE ŞAKACI

KOCAELİ 2018

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

HİPERSPEKTRAL GÖRÜNTÜLERİN FARKLI UZAYLARDA SÜPERPİKSEL TABANLI SPEKTRAL SINIFLANDIRILMASI

SİNEM AYBÜKE ŞAKACI

Prof.Dr. Sarp ERTÜRK
Danışman, Kocaeli Üniv. .....

Doç.Dr. Behçet Uğur TÖREYİN
Jüri Üyesi, İstanbul Teknik Üniv. .....

Dr.Öğr.Üyesi Osman BÜYÜK
Jüri Üyesi, Kocaeli Üniv. .....

Tezin Savunulduğu Tarih: 21.06.2018

ÖNSÖZ VE TEŞEKKÜR

Bu tez kapsamında, hiperspektral görüntülerde sınıflandırma başarımını arttırmak için çalışmalar yapılmıştır. Hiperspektral görüntülerin sınıflandırılması ile ilgili gerçekleştirdiğim çalışmanın gelecekte bu konu üzerinde çalışmak isteyen araştırmacılara ve öğrencilere faydalı olmasını temenni ederim.

Yüksek lisans bitirme tezi danışmanlığımı üstlenerek, bana yol gösteren, her konuda bilgi ve desteğini esirgemeyen saygıdeğer hocam Prof. Dr. Sarp Ertürk'e teşekkür ederim.

Tüm öğrenimim boyunca maddi ve manevi desteklerini esirgemeyen aileme ve yardımları için Türker Şentürk'e sonsuz teşekkürlerimi sunarım. İyi ki varsınız.

Haziran - 2018 Sinem Aybüke ŞAKACI

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR i
İÇİNDEKİLER ii
ŞEKİLLER DİZİNİ iv
TABLOLAR DİZİNİ v
SİMGELER VE KISALTMALAR DİZİNİ vi
ÖZET vii
ABSTRACT viii
GİRİŞ 1
1.HİPERSPEKTRAL GÖRÜNTÜLEME 3
1.1.Uzaktan Algılama 3
1.1.1.Uzamsal çözünürlük 3
1.1.2.Spektral çözünürlük 4
1.1.3.Zamansal çözünürlük 5
1.1.4.Radyometrik çözünürlük 6
1.1.Hiperspektral Görüntüleme 6
2.DESTEK VEKTÖR MAKİNELERİ (SUPPORT VECTOR MACHINE) 10
2.1.SVM Avantaj ve Dezavantajları 14
2.2.SVM Kütüphanesi 14
2.3.LIBSVM Parametreleri 14
3.SÜPERPİKSEL 17
3.1.Genel Bakış 17
3.2.SLIC Süperpiksel 17
3.2.1.K-Ortalama kümeleme ve Llyod algoritması 19
4.KULLANILAN ALT UZAYLAR OLARAK RENK VE PCA UZAYI 21
4.1.Renk Kavramı 21
4.2.Renk Uzayları 21
4.2.1.RGB renk uzayı 22
4.2.2.CMY renk uzayı 22
4.2.3.HSV renk uzayı 22
4.2.4.HSL renk uzayı 23
4.2.5.HSI renk uzayı 24
4.2.6.YCC renk uzayı 25
4.2.7.CIE LAB uzayı 25
4.2.8.CIE XYZ uzayı 26
4.3.Hiperspektral Görüntülerde Boyut Azaltımı 27
4.3.1.PCA uzayı 28
5.HİPERSPEKTRAL GÖRÜNTÜLERİN FARKLI UZAYLARDA SÜPERPİKSEL TEMELLİ SPEKTRAL SINIFLANDIRILMASI 31
5.1.Kullanılan Veri Setleri 31
5.1.1.AVIRIS Indian Pines veri seti 31
5.1.2.ROSIS Pavia University veri seti 33
5.2.Deneyler 35

5.2.1.Hiperspektral görüntülerde SVM 37
5.2.2.Hiperspektral görüntülerde RGB uzayı SLIC süperpiksel 37
5.2.3.Hiperspektral görüntülerde LAB uzayı SLIC süperpiksel 40
5.2.4.Hiperspektral görüntülerde PCA uzayı SLIC süperpiksel..... 42
5.2.5.Hiperspektral görüntülerde spektral uzay SLIC süperpiksel 44
5.3.Deney Sonuçları 45
5.4.Deney Sonuçlarının Değerlendirilmesi 56
6.SONUÇLAR VE ÖNERİLER 58
KAYNAKLAR 59
KİŞİSEL YAYINLAR VE ESERLER 63
ÖZGEÇMİŞ 64

ŞEKİLLER DİZİNİ

Şekil 1.1. Aynı bölgenin farklı uzamsal çözünürlüklerde görüntülenmesi (a) Bir pikselin fiziksel boyutları 0.5x0.5m, 1x1m, 2x2m olan görüntüsü (b) Bir pikselin fiziksel boyutları 5x5m, 10x10m, 20x20m olan görüntüsü 4
Şekil 1.2. Metosat 7 uydusuyla yarım saat sıklıkla alınmış görüntüler 6
Şekil 1.3. Aynı imgenin farklı radyometrik çözünürlüklerdeki görüntüsü (a) Gri değer skalası 4 (b) Gri değer skalası 16 (c) Gri değer skalası 256 6
Şekil 1.4. Hiperspektral görüntüleme düzeneği 7
Şekil 1.5. Hiperspektral imge küpü ve bir piksel spektrası 8
Şekil 1.6. AVIRIS Indian Pines veri seti dalga boylarına göre materyallerden gelen yansıma miktarının değişimi 9
Şekil 2.1. Doğrusal ayrılabilen veride destek vektörleri ve sınıflar 11
Şekil 2.2. Doğrusal ayrılamayan veride çekirdek fonksiyonu kullanımı 13
Şekil 3.1. SLIC algoritması kullanılarak 64, 256, 1024 pikselden oluşan süperpiksellere ayrılmış imgeler 18
Şekil 3.2. AVIRIS Indian Pines 100. bandının farklı parametrelerle süperpiksellere ayrılması (a) AVIRIS Indian Pines 100. bant Slic süperpiksel RS=5, R=0.05 (b) AVIRIS Indian Pines 100. bant Slic süperpiksel RS =8, R=0.01 19
Şekil 4.1. L*a*b Renk Uzayı 25
Şekil 4.2. PCA boyut azaltımı yöntemi 29
Şekil 5.1. 16 sınıftan oluşan AVIRIS Indian Pines mutlak doğru verisi 32
Şekil 5.2. AVIRIS Indian Pines 170. bant görüntüsü 32
Şekil 5.3. 9 sınıftan oluşan ROSIS Pavia University mutlak doğru verisi 34
Şekil 5.4. ROSIS Pavia University 50. bant görüntüsü 34
Şekil 5.5. Süperpiksel temelli spektral sınıflandırma 36
Şekil 5.6. Hiperspektral veri setinden RGB imge elde edilmesi 38
Şekil 5.7. RGB uzayı SLIC süperpiksel temelli spektral sınıflandırma 38
Şekil 5.8. AVIRIS Indian Pines RGB imgesi 39
Şekil 5.9. ROSIS Pavia University RGB imgesi 39
Şekil 5.10. LAB uzayı SLIC süperpiksel temelli spektral sınıflandırma 40
Şekil 5.11. AVIRIS Indian Pines LAB imgesi 41
Şekil 5.12. ROSIS Pavia University LAB imgesi 41
Şekil 5.13. PCA uzayı SLIC süperpiksel temelli spektral sınıflandırma 42
Şekil 5.14. AVIRIS Indian Pines PCA imgesi 43
Şekil 5.15. ROSIS Pavia University PCA imgesi 43
Şekil 5.16. Spektral uzay SLIC süperpiksel temelli spektral sınıflandırma 44
Şekil 5.17. AVIRIS Indian Pines verisi için alt uzaylara ait başarımlar 55
Şekil 5.18. ROSIS Pavia University verisi için alt uzaylara ait başarımlar 55

TABLOLAR DİZİNİ

Tablo 1.1. Landsat 8 Uydusunun OLI ve TIRS Sensörleriyle Toplanan 11 Bant Bilgisi 5
Tablo 5.1. AVIRIS Indian Pines Veri Kümesi Sınıf ve Örnek Sayısı 33
Tablo 5.2. ROSIS Pavia University Veri Kümesi Sınıf ve Örnek Sayısı 35
Tablo 5.3. Indian Pines %2 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 45
Tablo 5.4. Indian Pines %5 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 46
Tablo 5.5. Indian Pines %10 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 47
Tablo 5.6. Indian Pines %20 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 48
Tablo 5.7. Indian Pines %30 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 49
Tablo 5.8. Pavia University %2 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 50
Tablo 5.9. Pavia University %5 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 51
Tablo 5.10. Pavia University %10 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 52
Tablo 5.11. Pavia University %20 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 53
Tablo 5.12. Pavia University %30 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları 54

SİMGELER VE KISALTMALAR DİZİNİ

b : Bias
C : Ceza Parametresi
d : Kernel parametresi
Ds : Mesafe ölçümü
d_{lab} : Lab renk uzayı mesafesi
d_{xy} : XY koordinatı piksel mesafesi
f(x) : Sınıflandırma fonksiyonu
K() : Çekirdek fonksiyonu
M : Süperpiksel sıklık derecesi
φ() : Transfer fonksiyonu
S : Süperpiksel merkez değeri
w : Ağırlık vektörü
x_i : Eğitim setinin i. verisi
y_i : x_i verisinin sınıf bilgisi
γ : Kernel parametresi
μ_i : Ortalama değer
ε_i : Slack Variable (Yapay Değişken)

Kısaltmalar

CIE : International Commission On Illumination (Uluslararası Aydınlatma Komisyonu)
HSI : Hiperspectral Imaging (Hiperspektral Görüntüleme)
LDA : Linear Discriminant Analysis (Doğrusal Ayırtaç Analizi)
Lidar : Light Detection and Ranging (Işık Algılama ve Mesafelendirme)
OLI : Operational Land Imager (Operasyonel Arazi Görüntüleyici)
PCA : Principal Component Analysis (Temel Bileşen Analizi)
SLIC : Simple Linear İterative Clustering (Basit Doğrusal İterasyon Kümeleme)
SVM : Support Vector Machine (Destek Vektör Makineleri)
SMO : Sequential Minimal Optimization (Karesel Minimal Optimizasyon)
TIRS : Thermal Infrared Sensor (Termal Kızılötesi Sensör)
QP : Quadratic Programing (Karesel Programlama)

HİPERSPEKTRAL GÖRÜNTÜLERİN FARKLI UZAYLARDA SÜPERPİKSEL TABANLI SPEKTRAL SINIFLANDIRILMASI

ÖZET

Bu tez kapsamında, hiperspektral görüntüde süperpiksel tabanlı spektral sınıflandırma başarımı farklı uzaylar kullanılarak karşılaştırılmıştır. Geleneksel piksel tabanlı hiperspektral sınıflandırmada sadece piksele ait spektral bilgi kullanılmaktadır. Bunun aksine süperpiksel temelli hiperspektral sınıflandırma yaklaşımı hem piksele ait uzamsal bilgiyi hem de spektral bilgiyi içerir. Spektral ve uzamsal bilginin birlikte kullanımının sınıflandırma başarımını arttırdığı bilinmektedir. Bu tezde süperpiksel algoritmasına girdi olarak kullanılan farklı uzayların sınıflandırma başarımına etkisi üzerinde çalışılmıştır. Piksel temelli sınıflandırma için kullanılan veri setleri direkt olarak sınıflandırıcı girişine uygulanmıştır. Süperpiksel temelli sınıflandırma için RGB uzayı, LAB uzayı, PCA uzayı ve Spektral uzay kullanılmıştır. Sınıflandırma yöntemi olarak SVM kullanılmıştır. Süperpikselleri elde etmek için SLIC algoritması kullanılmıştır.

RGB uzayı, LAB uzayı, PCA uzayı ve Spektral alanı kullanan süperpiksel tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha yüksek sınıflandırma doğruluğu sağladığı görülmektedir. Yüksek sınıflandırma başarımı vermesi nedeniyle SLIC-LAB ve SLIC-PCA uzayları diğer uzaylara göre ön plana çıkmaktadır. SLIC-RGB ve SLIC-Spektral başarım sonuçları SLIC-LAB ve SLIC-PCA başarım sonuçlarına göre geride kalırken direkt SVM sonuçlarına göre ise başarım oranın arttığı görülmektedir.

Anahtar Kelimeler: Hiperspektral Görüntüleme, LAB Uzayı, PCA Uzayı, RGB Uzayı, Süperpiksel.

SUPERPİXEL BASED SPECTRAL CLASSIFICATION OF HYPERSPECTRAL IMAGES IN DIFFRENT SPACE

ABSTRACT

In this thesis, superpixel-based spectral classification performance in hyperspectral image is compared using different spaces. In conventional pixel-wise HSI classification systems use only spectral information of the pixel. On the contrary, the superpixel-based hyperspectral classification approach involves both spatial information and spectral information of the pixel. It is known that the combination of spectral and spatial information enhance the accuracy of classification. In this study, the effect of the changes of spaces used as input to the superpixel algorithm on the classification performance is studied. Data sets used are applied directly to the classifier input for pixel-based classification. RGB space, LAB space, PCA space and Spectral space are used for superpixel based classification. SVM is used as the classification method. SLIC algorithm is used to obtain superpixels.

It is observed that superpixel based classification using the RGB space, LAB space, PCA space, and Spectral space gives higher classification accuracy than pixel-wise classification Due to its high classification performance, SLIC-LAB and SLIC-PCA spaces dominate the other spaces. SLIC-RGB and SLIC-Spectral performance results fall behind SLIC-LAB and SLIC-PCA performance results. The SLIC-RGB and SLIC-Spectral performance results are inferior to the SLIC-LAB and SLIC-PCA performance results, but the classification performance is higher than the direct SVM results.

Keywords: Hyperspectral Imagery, LAB Space, PCA Space, RGB Space, Superpixel.

GİRİŞ

Uzaktan algılama genel anlamda çalışılan nesne ile herhangi bir fiziksel temas olmadan yapılan algılama işlemidir. Bu algılama işlemi sırasında alınan görüntülere göre üç grupta ele alınmaktadır. Bunlar: Pankromatik, multispektral ve hiperspektral görüntülerdir.

Hiperspektral görüntüleme uzaktan algılamanın oldukça önemli alt dallarından bir tanesidir. İnsan gözü elektromanyetik tayfın belirli bir kısmı olan 400 nm ile 700 nm dalga boyu arasındaki görüntüleri görebilir. Hiperspektral görüntüleme sistemleri ise insan gözünün algılayamayacağı geniş bir spektrumda ölçümler yapabilir. Bu görüntüleme sistemleri dar bant aralıkları ile yüzlerce görüntü alarak insan gözü tarafından algılanamayan detayları görünür kılmaktadır. Bu özellikleri sayesinde çok çeşitli kullanım alanları mevcuttur. Bu kullanım alanlarından bir tanesi sınıflandırmadır.

Sınıflandırma işlemi hiperspektral görüntülerin sahip olduğu zengin spektral bilgi sayesinde diğer görüntülere oranla daha kolay yapılmaktadır. Bu sebeple sınıflandırma ve tanımlama işlemlerinde hiperspektral görüntüler sıkça kullanılmaktadır. Bu tez kapsamında sınıflandırma problemini çözmek için denetimli sınıflandırma metodu olan SVM kullanılmaktadır.

Son yıllarda yapılan çalışmalarda özellikle hiperspektral görüntülerin sınıflandırma başarımının arttırılması oldukça önemli bir konu haline gelmiştir. Sınıflandırma yapılırken sınıflandırma işleminin daha yüksek doğrulukla sonuç vermesi için çeşitli yöntemler ve farklı uzaylar kullanılmaktadır. Bu tez kapsamında hiperspektral görüntülerin süperpiksel tabanlı spektral sınıflandırılması farklı uzaylar için incelenmiş ve sınıflandırma başarımları karşılaştırılmıştır. Uzaktan algılama ve hiperspektral görüntülemeye ait kavramlar genel hatlarıyla Bölüm 1'de verilmiştir. Sınıflandırma problemi çözümü için kullanılan SVM çalışma mantığı, SVM parametreleri ve SVM kullanımının avantaj ve dezavantajları Bölüm 2'de bahsedilmiştir. Bölüm 3'te imge bölütleme kısmına genel bir bakış atılmış ve bu tezde

kullanılan SLIC süperpiksel yapısı aktarılmış ve kullanılan algoritmadan bahsedilmiştir. Bölüm 4'te kullanılan alt uzaylar olarak renk kavramı, renk uzayları ve boyut azaltım yöntemi olan PCA'dan genel anlamda bahsedilmiştir. Bölüm 5'te tez kapsamında kullanılan veri setleri ve yapılan çalışmalar, elde edilen sonuçlar paylaşılmıştır. Bölüm 6'da sonuçlar değerlendirilmiş ve öneriler sunulmuştur.

1.HİPERSPEKTRAL GÖRÜNTÜLEME

1.1.Uzaktan Algılama

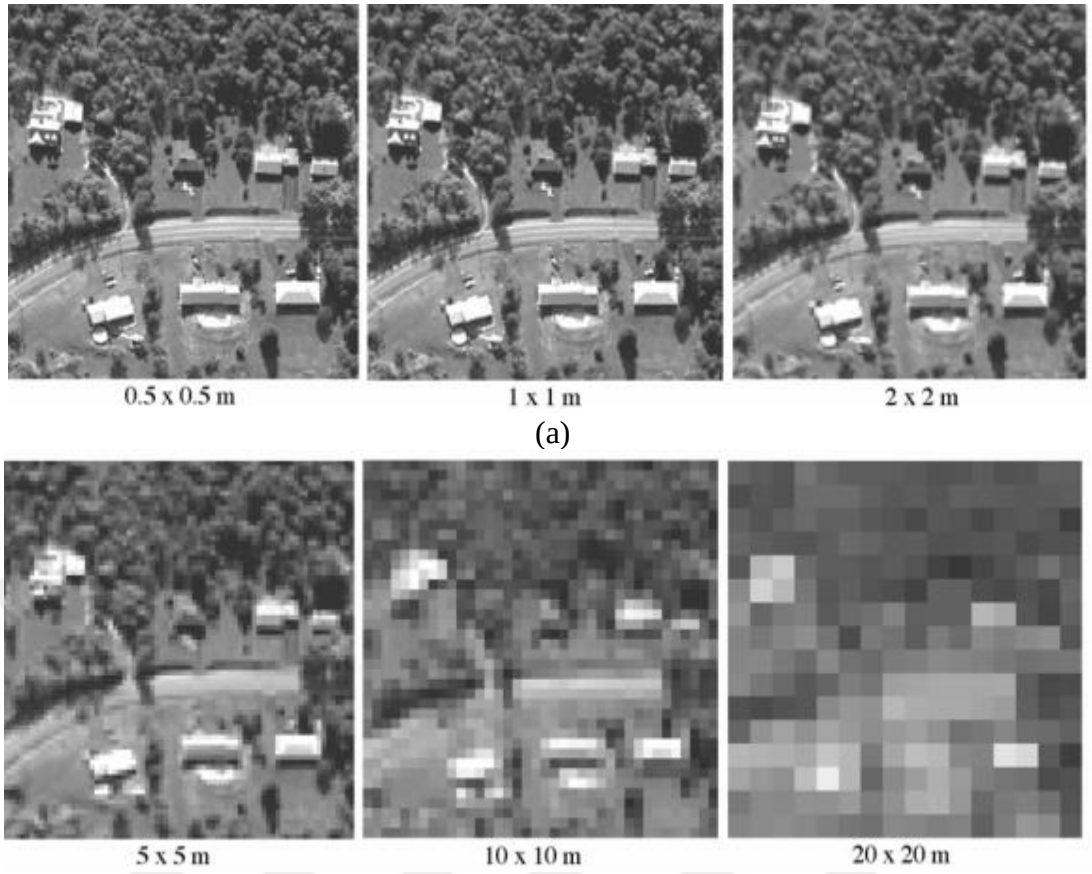
Uzaktan algılama, algılanacak hedef ile algılama işlemi için kullanılan cihaz arasında herhangi bir fiziksel bağlantı olmaksızın yapılan bilgi edinme işlemidir. Genellikle bir uçak ya da uydu yardımıyla yapılır [1]. Uzaktan algılama, günümüzde pek çok alanda kendine uygulama alanı bulmuş olup bunlardan bazıları: kirlilik ve kentleşme [2], maden [3], askeri amaçlar [4], tıbbi uygulamalar [5], tarım [6] vb.

Uzaktan algılamada kullanılan iki tip yöntem vardır: aktif ve pasif sensörler ile yapılan uzaktan algılama. Pasif algılamada kullanılan algılayıcılar hedef cisimden yansıyan veya emilen doğal enerjiyi kullanırlar. Doğal enerjiye örnek güneş ya da atmosfer olarak gösterilebilir. Aktif algılamada kullanılan algılayıcılar ise algılanacak cisim üzerine enerji göndermekte ve yansıyan veya emilen enerji algılayıcı tarafından kullanılmaktadır. Aktif algılamaya örnek olarak radar ya da Lidar olarak gösterilebilir. Uzaktan algılama sistemleri için dört çeşit çözünürlükten bahsedilebilir. Bunlar:

- Uzamsal çözünürlük
- Spektral çözünürlük
- Zamansal çözünürlük
- Radyometrik çözünürlük

1.1.1.Uzamsal çözünürlük

Uzaktan algılama sistemlerinde algılama için kullanılan sensörün ayrık bir nesne olarak görebileceği en küçük nesne boyutu uzamsal çözünürlüğü belirlediği bilinmektedir [7]. Uzaktan algılanan görüntüye ait uzamsal çözünürlük her bir pikselin kenar uzunluğunun yerel alanda karşılığını belirtmektedir. Uzaktan algılama sistemlerinde uzamsal çözünürlüğü atmosferik kırınım ve bozulmalar, odak noktasında kusur ve sapmalar etkilemektedir [8]. Şekil 1.1'de görüldüğü üzere uzamsal çözünürlük arttıkça görüntüdeki detaylar artmaktadır.



Şekil 1.1. Aynı bölgenin farklı uzamsal çözünürlüklerde görüntülenmesi [9]
(a) Bir pikselin fiziksel boyutları 0.5x0.5m, 1x1m, 2x2m olan görüntüsü
(b) Bir pikselin fiziksel boyutları 5x5m, 10x10m, 20x20m olan görüntüsü

1.1.2.Spektral çözünürlük

Uzaktan algılama sistemlerinde kullanılan sensörün farklı dalga boylarında görüntü alabilme kabiliyetidir. Spektrumun hangi bölgelerinden görüntü alındığının göstergesidir. Spektral çözünürlüklerine göre görüntüleri gruplandırabiliriz.

Pankromatik Görüntüler: Tek banttan oluşan görüntülerdir. Spektrumun görünen bölge ve yakın kızıl ötesi alanlarını kapsayan bölgedir. Elde edilen görüntü siyah-beyazdır.

Multispektral Görüntüler: Genellikle bant sayıları 3 ile 10 arasında değişen görüntülerdir. Hiperspektral görüntülerle kıyaslandığında bant sayıcı oldukça az ve kullanılan dalga boyları arasındaki mesafe fazladır. Hiperspektral görüntülerin aksine süreksizlik teşkil eder. Örneğin Landsat 8 uydusunun OLI ve TIRS sensörleriyle

toplanan 11 bant verisine sahip multispektral görüntü verileri Tablo1.1'de gösterilmektedir.

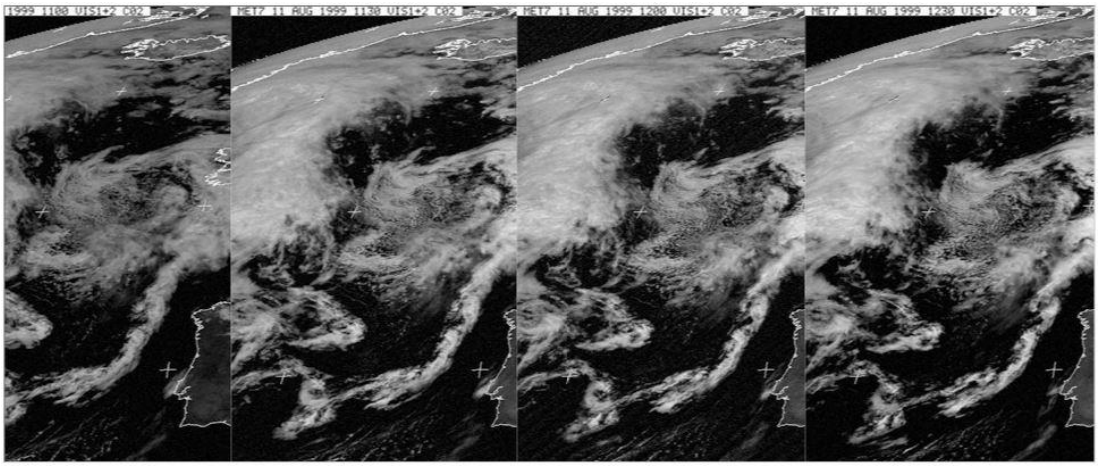
Hiperspektral Görüntüler: Yüzlerce ardışık dar bantlardan oluşan görüntülerdir. Örneğin; Indian Pines veri seti, Salinas veri seti, Pavia University veri seti vb.

Tablo 1.1. Landsat 8 Uydusunun OLI ve TIRS Sensörleriyle Toplanan 11 Bant Bilgisi [10]

Spektral Aralık	**Dalga Boyu (mikrometre)**	**Çözünürlük (metre)**
Bant 1- Kıyı / Aerosol	0,43-0,45	30
Bant 2- Mavi	0,45-0,51	30
Bant 3-Yeşil	0,53-0,59	30
Bant 4- Kırmızı	0,64-0,67	30
Bant 5- Yakın Kızılötesi	0,85-0,88	30
Bant 6- Kısa Dalga Kızılötesi	1,57-1,65	30
Bant 7- Kısa Dalga Kızılötesi	2,11-2,29	30
Bant 8- Pankromatik	0,50-0,68	15
Bant 9- Sirrus	1,36-1,38	30
Bant 10- Uzun Dalga Kızılötesi	10,60-11,19	100*(30)
Bant 11- Uzun Dalga Kızılötesi	11,50-12,51	100*(30)

1.1.3.Zamansal çözünürlük

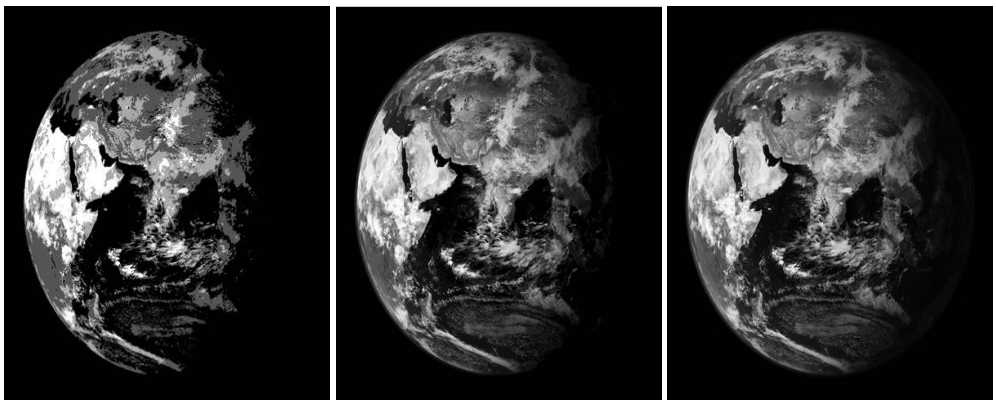
Aynı bölgenin aynı açıyla aynı donanımlar kullanılarak farklı zamanlarda görüntü alma sıklığını ifade etmektedir. Farklı zamanlarda alınan görüntüler (yıllık, aylık vb.) ile bitki örtüsünün mevsimsel değişiklikleri, yıldan yıla şehirlerin gözlenmesi, tropikal yağmur ormanlarında orman açıklık dokümantasyonu vb. konularında çalışılabilir. Şekil 1.2'de belirli zaman aralıklarla alınmış uydu görüntüleri gösterilmektedir.



Şekil 1.2. Metosat 7 uydusuyla yarım saat sıklıkla alınmış görüntüler [11]

1.1.4.Radyometrik çözünürlük

Uzaktan algılama sistemlerinde, farklı yoğunluktaki ışığın gri seviye farklı tonlarla ifade edilebilmesi ve ayırt edilebilme kabiliyeti olarak tanımlanır. Bir piksel için kullanılan bit sayısı büyüdükçe, ayırt edilebilme kabiliyeti o oranda artmaktadır. Şekil 1.3'te görüldüğü üzere gri değer skalası 256 olan imge diğer imgelere kıyasla daha fazla bilgi içerir.



(a) (b) (c)

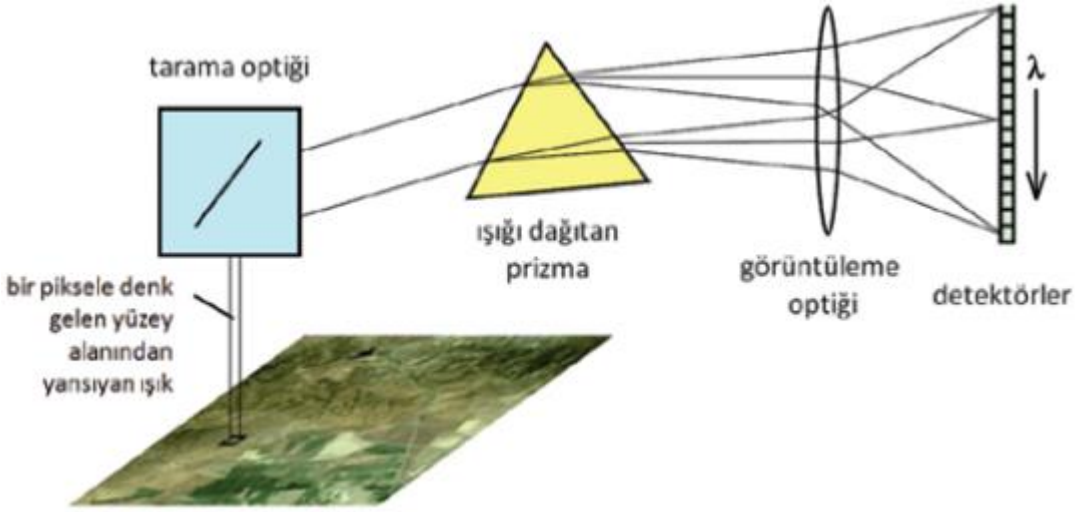
Şekil 1.3. Aynı imgenin farklı radyometrik çözünürlüklerdeki görüntüsü [11]
(a) Gri değer skalası 4 (b) Gri değer skalası 16 (c) Gri değer skalası 256

1.1. Hiperspektral Görüntüleme

Hiper kelimesinin sözlük karşılığı çok fazla sayıda olan anlamında olmakla birlikte hiperspektral kelimesinin anlamı ise çok fazla sayıda banttan oluşan anlamındadır. Hiperspektral görüntüleri pankromatik görüntülerden ve multispektral görüntülerden

ayıran özellik bant sayılarının fazla oluşu ve bu bantların aralıklarıdır. Hiperspektral görüntülerin en önemli özelliklerinden bir tanesi bu görüntülerin dar dalga boyu aralıklarıyla elde edilmeleridir. Dar aralıklarla elde edilen hiperspektral görüntüler süreklilik sağlar.

Spektrometreler elektromanyetik spektrumun belirli aralığında malzemeye ait ışığın yansımasını veya yayılmasını ölçerek malzemenin özelliklerini belirlemek için kullanılan araçlardır. Hiperspektral görüntülemede kullanılırlar. Bu araçlar ölçüm yapılmak istenen materyalden yansıyan ya da yayılan ışığı farklı dalga boylarında ölçerek materyal hakkında bilgi sağlarlar. Genel yapıları bir prizmaya benzer yapıdadır. Günümüz gelişmiş spektrometreleri ise prizmadan daha çok otomatik olarak kontrol edilen ızgaraya yapısındadır. Bu yapının temel amacı cihaza gelen ışığı dar ve çok sayıdaki dalga boyuna ayrıştırmaktır. Farklı dalga boylarında ölçüm yapabilmek için farklı detektörler kullanılmaktadır. Şekil 1.4'te örnek bir hiperspektral görüntüleme düzeneği görülmektedir.

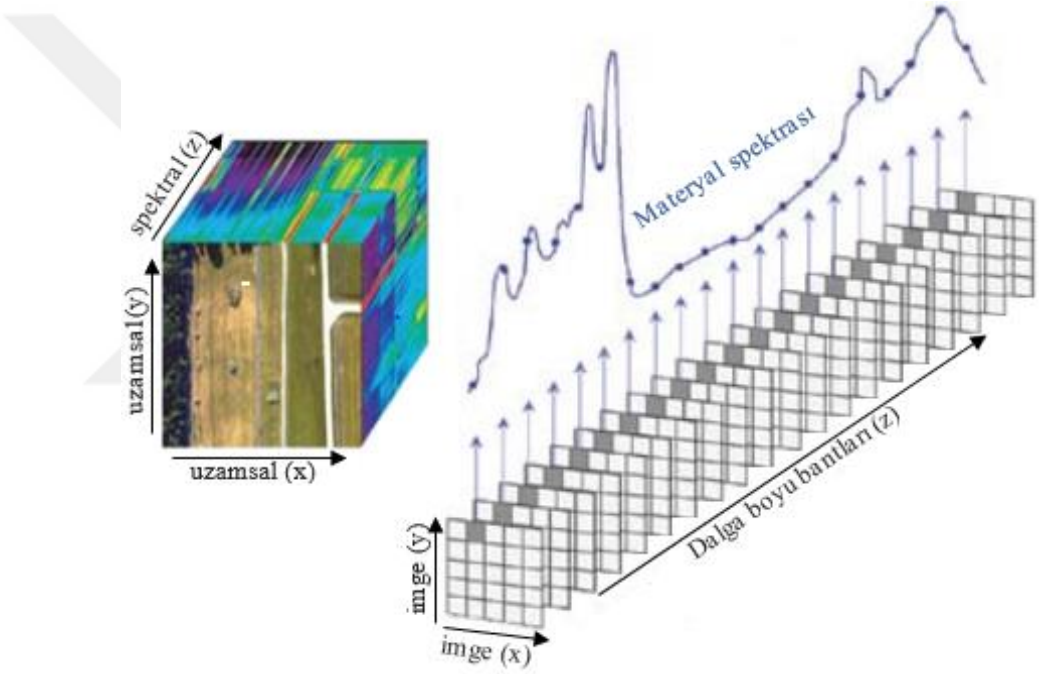


Şekil 1.4. Hiperspektral görüntüleme düzeneği [12]

Şekil 1.4'teki hiperspektral görüntüleme düzeneğine kısaca bakılacak olursa yüzeyden yansıyan veya yayılan ışığın bir tarama cihazı sayesinde alınması ve prizmaya benzeyen yapı ile alınan bu ışığın dar aralıklarla ve süreklilik oluşturacak şekilde (birbirini takip eden) dalga boylarına ayrıştırılması ilk adım olarak nitelendirilebilir. Daha sonraki adım da ise prizmaya benzeyen yapı sayesinde farklı dalga boylarına ayrıştırılan ışığın görüntüleme optiği yardımıyla algılayıcılara ulaştırılmasıdır.

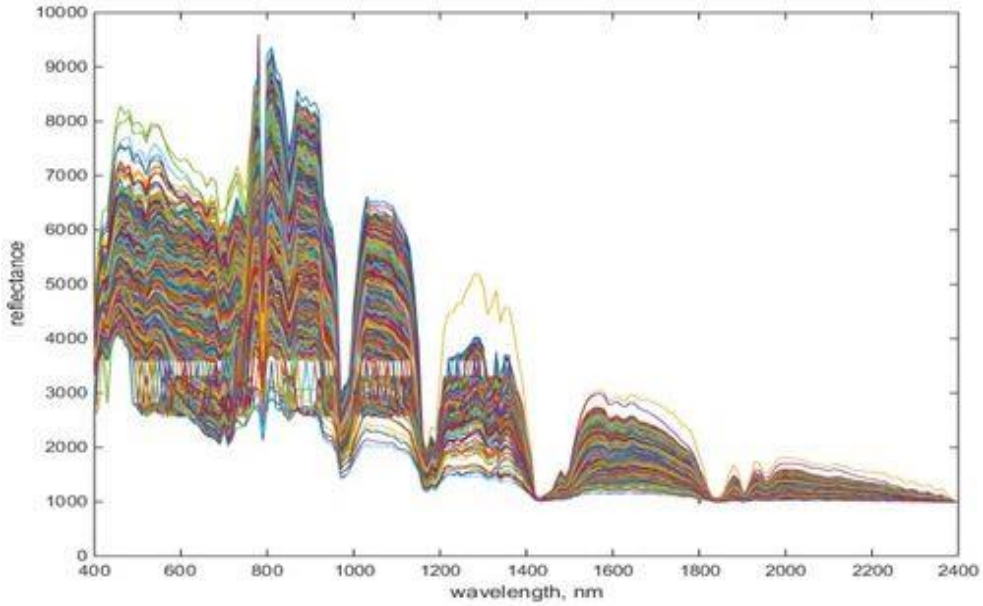
Algılayıcı sayısının artması daha dar aralıklarla ve daha geniş spektrumda ölçüm yapmayı mümkün kılmaktadır.

Spektral anlamda süreklilik özelliği gösteren hiperspektral imgeler bu özelliklerinden dolayı üç boyutlu olarak ele alınırlar. İlk iki boyut x ve y eksenleridir ve bu eksenlere uzamsal düzlem adı verilir. Üçüncü boyut spektral bilgiyi içeren boyuttur. Üç boyutlu yapıları nedeniyle hiperspektral görüntülere hiper küp adı verilmektedir. Şekil 1.5'te hiperspektral veri setinin üç boyutlu (uzamsal (x), uzamsal (y), spektral (z)) gösterimi ve hiperspektral verilerin spektral sürekliliği sağladığı için elde edilen materyal spektrası görülmektedir.



Şekil 1.5. Hiperspektral imge küpü ve bir piksel spektrası [12]

Farklı malzemelerin farklı dalga boylarında ışığı yansıtması ve ışığı emmesi farklı derecelerde olmaktadır. Bu ayırt edici özellik malzemelerin tanımlanmasında kullanılır. Malzemeye has bu özelliklere spektral imza adı verilmektedir. Örneğin; bitkiler, madenler, kimyasal karışımlar vb. materyallerin belirli dalga boyları için belirli reflektansları bulunmaktadır [13]. Malzemeye ait belirli dalga boyları için belirli reflektans değerlerinin tutulduğu kütüphaneler mevcut olup hiperspektral ve multispektral verilerin yorumlanması bu kütüphaneler sayesinde yapılmaktadır. Şekil 1.6'da Aviris Indian Pines veri setine ait dalga boyu ve yansıma miktarının değişimi görülmektedir.



Şekil 1.6. AVIRIS Indian Pines veri seti dalga boylarına göre materyallerden gelen yansıma miktarının değişimi

Dar ve sürekli bantlardan oluşan hiperspektral görüntüler multispektral verilere oranla daha fazla bant içerdikleri için daha fazla veri taşırlar ve spektral anlamda daha zengindirler. Bu nedenle yüksek spektral ayrımsama gücüne sahiptirler. Ancak yüksek spektral ayrımsama gücüne zıt olarak düşük uzamsal çözünürlüğe sahiptirler. Düşük uzamsal çözünürlüğe sahip oldukları için katışımlı (bir piksel içerisinde birden fazla malzemeye ait veri bulunduran) piksellere sahiptirler. Düşük uzamsal çözünürlüğe sahip olan hiperspektral görüntülerin uzamsal çözünürlüğünü arttırmak için çalışmalar yapılmaktadır. Örneğin; piksel altı yaklaşımlar ya da yüksek uzamsal çözünürlüğe sahip görüntüler ile hiperspektral görüntülerin birleştirilmesi gibi.

İnsan gözünün algılayabileceği bant aralığı 0,4 - 0,7 µm'dir. Multispektral görüntüler genellikle 0,4 - 0,9 µm aralığındadır. Hiperspektral görüntülemede bu aralık oldukça genişleyerek 0,4 - 2,5 µm aralığını kapsar. Daha geniş bir alanda çalışma imkânı sunan hiperspektral görüntülerde daha fazla materyal tanımlanmaktadır.

.

2.DESTEK VEKTÖR MAKİNELERİ (SUPPORT VECTOR MACHINE)

Sınıflandırma problemi için denetimli sınıflandırma ve denetimsiz sınıflandırma olmak üzere iki adet çözüm bulunmaktadır. Denetimli sınıflandırma eğitim sürecinde oluşturulan modele bağlı kalınarak yapılan sınıflandırmadır. Denetimsiz sınıflandırma ise verileri gruplanmasıyla oluşturulan sınıflandırma sürecidir.

SVM denetimli öğrenme olarak adlandırılmaktadır çünkü belirli bir giriş verisine göre bir harita oluşturarak çıkış değerinin ne olacağına karar verir. Yani eğitim verisinde öğrenme yaparak yeni veri üzerinde doğru tahmin yapmaya ve genelleştirmeye çalışan makine öğrenmesidir.

Doğrusal sınıflandırıcı için, etiket değeri y ve özellik değeri x olmak üzere ikili sınıflandırıcı için etiket değeri +1 veya -1 kullanılır. Sınıflandırma işlemi için Denklem (2.1)'deki formül kullanılır. Denklem (2.1)'de kullanılan w ağırlık vektörü, düzleme olan normaldir.

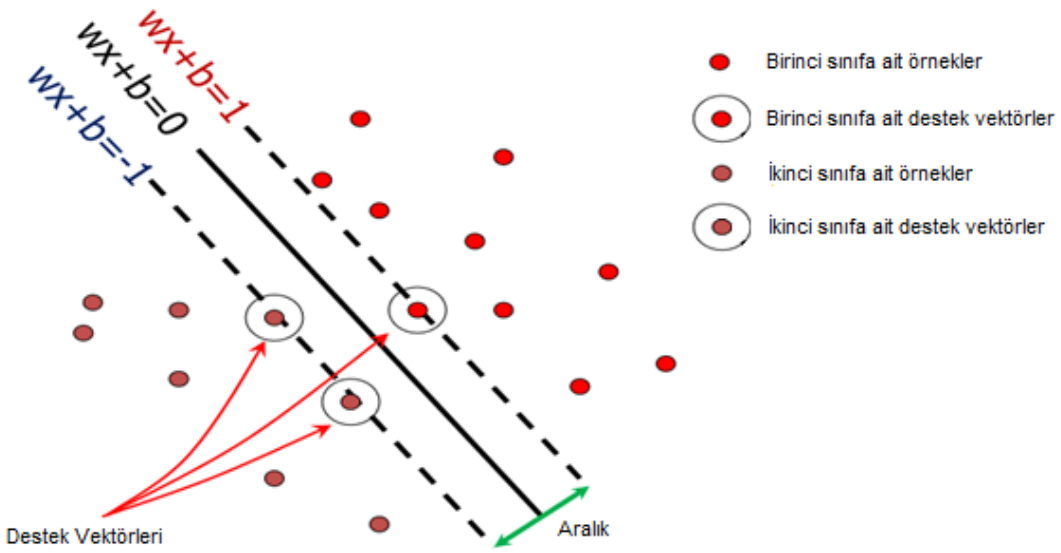
$$f(x)=wx+b \tag{2.1}$$

$$\text{x pozitif } (y=1):\ f(x) = wx+b \geq 1 \tag{2.2}$$

$$\text{x negatif } (y=-1):\ f(x) = wx+b \leq -1 \tag{2.3}$$

$$\text{Destek vektörleri: } wx+b = \pm 1 \tag{2.4}$$

Doğrusal sınıflandırılabilen veriler için kullanılan sınıflandırıcılarda pek çok karar düzlemi kullanılabilir. En iyi karar düzlemini bulmak için karar düzlemi destek vektörleri (karar düzlemine en yakın olan örnekler) arasındaki mesafeyi en büyükleyecek şekilde seçilir. Denklem (2.2) ve Denklem (2.3) doğrusal sınıflandırılabilen veriler için destek vektörlerinin sağında ve solunda kalan sınıf örneklerinin etiket değerlerini göstermektedir. Destek vektörleri ise Denklem (2.4) ile ifade edilir.



Şekil 2.1. Doğrusal ayrılabilen veride destek vektörleri ve sınıflar

Şekil 2.1'de doğrusal ayrılabilen veride destek vektörlerini ve sınıflar gösterilmektedir. Herhangi bir noktanın hiper düzleme olan uzaklığı Denklem (2.5) ile ifade edilir.

$$\frac{|wx_i + b|}{||w||} \tag{2.5}$$

Destek vektörlerinin hiper düzleme olan uzaklığı Denklem (2.6) ile ifade edilir.

$$\frac{|wx_i + b|}{||w||} = \frac{\pm 1}{||w||} \tag{2.6}$$

Böylece destek vektörleri arasındaki uygun mesafe Denklem (2.7) ile ifade edilir.

$$\left| \frac{1}{||w||} - \frac{-1}{||w||} \right| = \frac{2}{||w||} \tag{2.7}$$

Denklem (2.7) ile ifade edilen formülden anlaşılacağı üzere aralık değerini büyüklemek için ağırlık vektörünü küçüklemek gereklidir.

$$\text{Küçükle: } \frac{1}{2}\|w\|^2$$

$$\text{Sınırlamalar: } y_i(wx_i + b) \geq 1 \text{ , } i=1,2....N \tag{2.8}$$

Denklem (2.8) ile gösterilen küçükleme problemini yeniden yorumlayıp Denklem (2.9) ile büyükleme problemine dönüştürülmektedir.

$$\text{Büyükle: } \sum_{i=1}^{N} a_i - \frac{1}{2}\sum_{i=1}^{N}\sum_{j=1}^{N} a_i a_j y_i y_j (x_i x_j)$$

$$\text{Sınırlamalar: } \sum_{i=1}^{N} a_i y_i = 0 \text{ ve } a_i \geq 0 \text{ , } i=1,2,3....N \qquad (2.9)$$

Denklem (2.9)'da QP problemi elde edilmiştir. Bu problemin çözümü için QP algoritmaları kullanılabilir. QP algoritmalarına örnek olarak SMO verilebilir. SMO algoritması LIBSVM tarafından kullanılmaktadır [14].

Veri doğrusal olarak ayrılıyor ancak bazı değerler yanlış etiketlenebiliyorsa bu değerler için yapay değişken ε_i tanımlanır ve yanlış etiketlenen her değer için ceza parametresi C kullanılır. Eğer $\varepsilon_i = 0$ ise sınıflandırmada hata yapılmamıştır.

$$\text{Küçükle: } \frac{1}{2}\|w\|^2 + C\sum_{i=1}^{N} \varepsilon_i$$

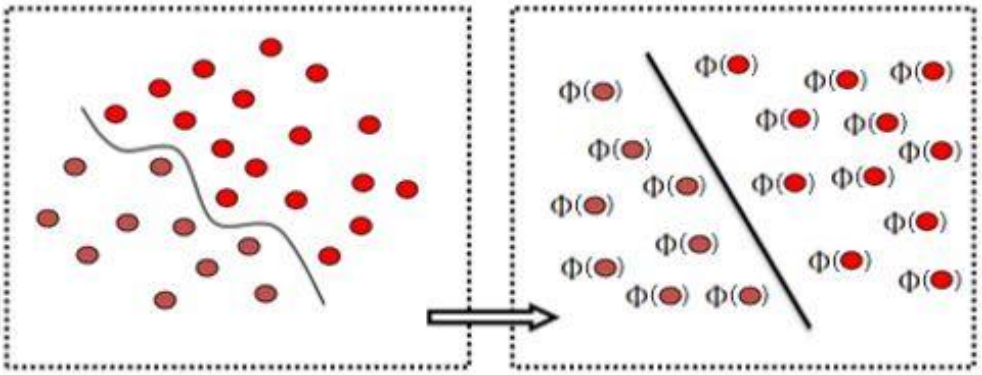
$$\text{Kısıtlamalar: } y_i(wx_i + b) \geq 1 - \varepsilon_i \text{ , } i=1,2....N, \ \varepsilon_i \geq 0 \qquad (2.10)$$

Ceza parametresi kullanıcı tarafından belirlenmesi gereken parametredir. Denklem (2.10)'daki en uygun şekle sokma problemindeki ilk terim doğrusal ayrılabilir durumdaki ile aynı ifadedir. İkinci terim ise yanlış sınıflandırma noktasını kontrol etmektedir [15].

Doğrusal olarak ayrılamayan verilerde φ() fonksiyonu kullanılarak orijinal giriş uzayından daha yüksek bir boyutlu bir uzaya taşınarak veriyi doğrusal ayrılabilir duruma getirmektedir. Kullanılan yüksek boyutlu uzay özellik uzayıdır. Denklem (2.11)'de özellik uzayında geçekleştirilen iç çarpım çekirdek fonksiyonu kullanılarak K() gerçeklenmektedir.

Büyükle: $\sum_{i=1}^{N} a_i - \frac{1}{2}\sum_{i=1}^{N}\sum_{j=1}^{N} a_i a_j y_i y_j K(x_i x_j)$

Sınırlamalar: $\sum_{i=1}^{N} a_i y_i = 0$ ve $0 \leq a_i \leq C$ i=1,2,3...N (2.11)



Şekil 2.2. Doğrusal ayrılamayan veride çekirdek fonksiyonu kullanımı

Şekil 2.2'de doğrusal ayrılamayan veride çekirdek fonksiyonu kullanılarak doğrusal ayrılabilir duruma geçişi gösterilmektedir. Yaygın olarak kullanılan üç adet çekirdek fonksiyonu Denklem (2.12), (2.13), (2.14)'te tanımlanmaktadır.

Doğrusal çekirdek fonksiyonu:

$$K(x_i, x_j) = x_i x_j^T \tag{2.12}$$

Çok terimli çekirdek fonksiyonu:

$$K(x_i, x_j) = \left(\gamma x_i x_j^T\right)^d \tag{2.13}$$

Radyal taban fonksiyonu (RTF):

$$K(x_i, x_j) = \exp\left(-\gamma \left\| x_i - x_j \right\|\right) \tag{2.14}$$

γ, d parametreleri kullanıcı girişlidir. Çekirdek tipi ve kullanılan parametrelere göre sınıflandırma başarımı değişmektedir. Sonuç olarak, karar fonksiyonu Denklem (2.15) ile ifade edilmektedir.

$$f(x)= \sum_{i=1}^{n} a_i y_i K(x_i,x)+b \quad (2.15)$$

2.1.SVM Avantaj ve Dezavantajları

SVM'in en önemli avantajı, sınıflandırma problemini karesel optimizasyon problemine dönüştürüp çözmesidir [16]. Karesel optimizasyon problemine dönüştürmesinden dolayı sınıflandırma performansı yüksek ve daha hızlı sonuç alınmaktadır. Ayrıca optimizasyon temelli olduğundan sınıflandırma performansı, hesaplama karmaşıklığı ve kullanışlılık açısından diğer tekniklere göre daha başarılıdır [17]. Doğrusal olarak ayrılamayan yüksek boyutlu verilerde kullanılabilen sınıflandırıcıdır. Dezavantajı ise yüksek sınıflandırma başarımı için çok sayıda parametrenin doğru ayarlanmasıdır. A sınıflandırma problemi için en iyi sonuçları veren parametreler, B sınıflandırma problemi için en kötü sonucu verebilir. Dolayısıyla her sınıflandırma problemi için farklı parametrelerin deneyerek en iyi sonucu veren parametre seti bulunmalıdır [18].

2.2.SVM Kütüphanesi

Pek çok sayıda SVM kütüphanesi bulunmaktadır. Yapılan uygulamada LIBSVM kütüphanesi kullanılmıştır. En çok kullanılan SVM kütüphaneleri sırayla LIBSVM, SVMLight, SVMTorch şeklindedir [19].

LIBSVM destek vektör sınıflandırması, bağlanım, dağılım tahmini için kullanılan entegre bir yazılımdır. Ayrıca çoklu sınıf problemleri için de kullanılabilir. LIBSVM farklı SVM formülleri, etkili çoklu sınıflandırma özelliği, olasılık kestirimi, çeşitli çekirdekleri desteklemesi, model seçimi için çapraz doğrulama ve birçok programlama dili (Python, R, MATLAB, Perl, Ruby, Weka, Common, Lısp, Clısp, Haskell, Ocaml, LabView ve PHP, C#.Net, Cuda) için ara yüze sahiptir [20].

2.3.LIBSVM Parametreleri

LIBSVM kütüphanesinin sınıflandırma problemini çözmek için ihtiyaç duyduğu, kullanıcı tarafından girilmesi gereken parametreler aşağıdaki gibidir [20].

SVM tipi:

‘s’ parametresi kullanılacak SVM tipini girmek için kullanılan parametredir (Varsayılan değer 0). C-SVC ve nu-SVC sınıflandırma işlemleri için kullanılır. Tek - sınıf SVM dağılım tahmini yapılan işlemlerde kullanılır. Epsilon-SVR ve nu-SVR bağlanım işlemleri için kullanılır.

Çekirdek tipi:

‘t’ parametresi kullanılacak olan çekirdek tipini girmek için kullanılan parametredir (Varsayılan değer 2). ‘t’ parametresi 0 ise doğrusal çekirdek tipi, 1 ise polinomal çekirdek tipi, 2 ise radyal tabanlı çekirdek tipi, 3 ise sigmoid çekirdek tipi seçilmiş olur.

Çekirdek derecesi:

‘d’ parametresi çekirdek fonksiyonu derecesini belirlemede kullanılan parametredir (Varsayılan değer 3).

Gamma:

Bu parametre çekirdek tipi ‘poly’, ‘rbf’ ya da ‘sigmoid’ seçildiğinde kullanılabilir. Gamma parametresi SVM model oluşumunda önemli bir parametredir. Gamma parametresinin değişimi SVM başarımını etkileyen bir faktör olduğundan en uygun gamma değerini bulmak için çapraz doğrulama yapılabilir.

Coef 0:

Coef 0 parametresi çekirdek tipini ‘poly’ ya da ‘sigmoid’ seçildiğinde kullanılması gereken bir parametredir.

Ceza:

Ceza parametresidir. Bu parametre ‘C-SVC’, ‘epsilon-SVR’ ya da ‘nu-SVR’ için kullanılabilir (Varsayılan değer 1).

Nu:

‘Nu-SVC’, ‘Tek-sınıf SVM’ ya da ‘nu-SVR’ için kullanılabilir (varsayılan değer 0.5).

Epsilon:

‘p’ parametresi SVM tipi ‘Epsilon-SVR’ için epsilon parametresi kayıp fonksiyonu olarak kullanılabilir.

Bellek boyutu:

‘m’ parametresi bellek boyutu belirlemek için kullanılır (varsayılan değer 100).

Epsilon:

‘e’ parametresi sınıflandırma ölçütünün toleransını belirlemek için kullanılır (Varsayılan değer 0.001).

Daraltma:

‘h’ parametresi daraltma yönteminin kullanılıp kullanılmayacağını belirler, değeri 0 ya da 1 olmalıdır (Varsayılan değer 1).

Olasılık tahmin parametresi:

‘b’ parametresi SVC ya da SVR model olasılık tahmini için kullanılmaktadır, değeri 0 ya da 1 olmalıdır (Varsayılan değer 0).

Ağırlık:

‘w’ parametresi uzman tanımlı bir parametredir. Belirtilmediyse tanımlı değeri 1 olarak alınır (Varsayılan değer 1).

3.SÜPERPİKSEL

3.1.Genel Bakış

İmge bölütleme, dijital imgeyi çoklu bölütlere ayırma işlemidir. Bölütleme işlemindeki amaç imgeyi basite indirgemek veya daha kolay analiz edilebilir ya da daha kolay anlaşılabilir hale getirmektir [21] [22]. İmge bölütleme aynı karakteristik özelliğe sahip olan her bir piksele aynı etiket değeri atayarak imgedeki bütün piksellerin belirli bir gruba (süperpiksele) ait olmasını sağlamaktır. İmge bölütlemenin sonucu olarak birçok bölütten oluşan bir imge oluşmaktadır. Her bir bölge içerisindeki pikseller renk, yoğunluk ya da yapısal özellikleri bakımından benzer özellikler gösterir. Komşu bölgeler aynı karakteristik özellik için farklı sonuçlar verir [23].

Hiperspektral imge analiz araştırmalarında süperpikseller farklı görevlerde kullanılırlar. Hiperspektral imgeler yüksek spektral çözünürlükten dolayı büyük boyutlu veriler olduğu için bu imgelerde yapılan çalışmalar hesaplama zamanı açısından sorun teşkil ederler [24]. Süperpikseller imgeyi daha kolay analiz edilebilir hale getirdikleri için hesaplama zamanı da azalmış olur [25]. Başka bir açıdan hiperspektral görüntüler kullanılan sensör ve sahne nedeniyle gürültü içerir. Her bir süperpiksel bitişik bir grup pikselden oluştuğu için süperpiksel kullanımı imgedeki gürültü etkisini azaltır [25]. Bu gözlemlere dayanarak hiperspektral imgenin birçok farklı uygulamada kullanıldığını söylemek mümkündür [24]. Örneğin gürültü etkisini azaltmak için [25] ya da sınıflandırma başarımını arttırma için [26] çalışılmıştır.

3.2.SLIC Süperpiksel

SLIC algoritması 5D uzayında CIELAB renk uzayının L, a, b değerlerini ve x, y piksel koordinatlarını kullanarak kümeleme yapar. SLIC algoritması piksel değerlerindeki renk benzerliğini ve imge düzlemindeki yakınlıklarına temel alarak sınıflandırma yapar. Bu işlem 5 boyutlu [Labxy] uzayında yapılmaktadır. [Lab] CIELAB renk uzayında piksel renk vektörünü tanımlarken, xy ise piksel pozisyonunu tanımlamaktadır.



Şekil 3.1. SLIC algoritması kullanılarak 64, 256, 1024 pikselden oluşan süperpiksellere ayrılmış imgeler [27]

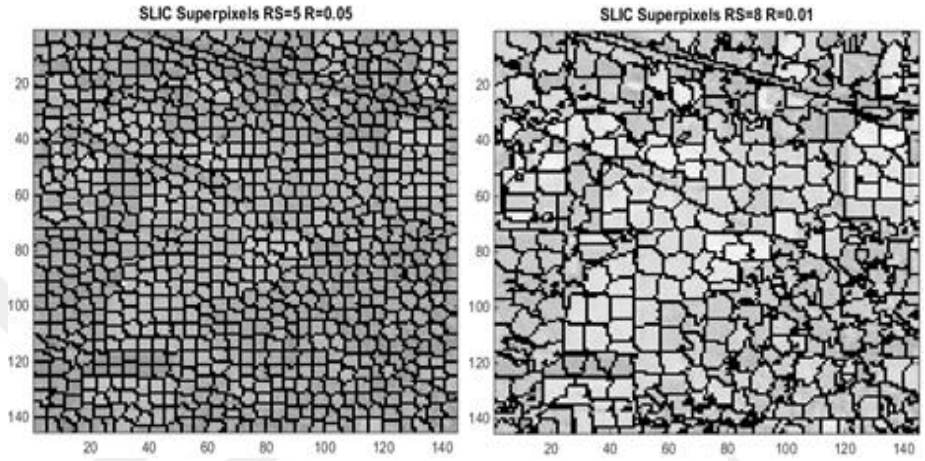
Şekil 3.1'de SLIC algoritması kullanılarak 64, 256 ve 1024 pikselden oluşan süperpiksellere ayrılmış örnek imgeler gösterilmektedir. 5D uzayında Öklid (Euclidean) uzaklığını kullanmak pek mümkün olmadığı için bu algoritmada yeni bir uzaklık ölçümü kullanılmıştır. CIELAB renk uzayında küçük uzaklıklar için Öklid uzaklığını kullanmak uygundur ancak eğer uzamsal piksel mesafesi oransal renk uzaklık limitini aşarsa, piksel renk benzerlikleri ağır basmaya başlar. Ds mesafesi kullanıldığında piksel mesafesi ve renk mesafesi yaklaşık olarak eşit ağırlıktadır. SLIC algoritmasında K adet süperpiksel merkezi $C_k=[l_k, a_k, b_k, x_k, y_k]$ ve k =[1, K] olmak üzere S süperpikselin çevresi olarak seçilir. Bu süperpikselin merkeziyle ilgili pikseller uzamsal uzayda (xy uzayı) 2S x 2S bir alanda bulunduğu varsayılabilir. d_{lab} renk uzayındaki uzaklık, d_{xy} uzamsal uzaklık, m parametresi süperpiksellerin sıklık derecesini ayarlamak için kullanılan parametre, S ise süperpikselin çevresi olarak tanımlanmak üzere Denklem (3.1), (3.2) Lab ve xy uzayları mesafe ölçümü hesaplamak için kullanılır. Denklem (3.3) ise D_s uzaklık ölçümü için kullanılır [27].

$$d_{lab}=\sqrt{(l_k-l_i)^2+ \quad (a_k-a_i)^2+ \quad (b_k-b_i)^2} \tag{3.1}$$

$$d_{xy}= \sqrt{(x_k-x_i)^2 + \quad (y_k-y_i)^2} \tag{3.2}$$

$$D_s= d_{lab}+ \frac{m}{S} d_{xy} \tag{3.3}$$

SLIC için kullanıcı tarafından girilmesi gereken iki parametre gereklidir. Bunlar: bölünmek istenen bölgenin boyutu ve uzamsal düzenleme parametreleridir. Öncelikle imge kullanıcı tarafından girilen bölge boyutlarına göre karelere ayrılır. Her bir karenin ortasındaki piksel değeri K-ortalama algoritmasına göre başlangıç değeri olarak atanır. K-ortalama sınıflandırması Lloyd algoritmasını kullanılarak sağlanır [28].



(a) (b)

Şekil 3.2. AVIRIS Indian Pines 100. bandının farklı parametrelerle süperpiksellere ayrılması (a)AVIRIS Indian Pines 100. bant Slic süperpiksel RS=5, R=0.05 (b)AVIRIS Indian Pines 100. bant Slic süperpiksel RS =8, R=0.01

Şekil 3.2'de AVIRIS Indian pines 100. bant imgesinin SLIC süperpiksel algoritması kullanılarak bölge boyutu (Region Size) ve düzenleyici (Regulazier) parametreleri değiştirilerek elde edilen imgeler örnek olarak gösterilmiştir.

3.2.1.K-Ortalama kümeleme ve Llyod algoritması

Kümeleme algoritmaları ya da kümeleme işlemi özellikleri aynı ya da benzer olan örnekleri aynı grup altında toplama, farklı özelliklere sahip olanları ise başka bir grup altında toplamayı amaçlayan algoritmalardır. Makine öğrenmesi, örüntü tanıma, imge analizi, veri sıkıştırma, biyoinformatik vb. alanlarında kullanılmaktadır [29].

K-ortalama kümeleme yöntemi n adet veriden oluşan bir kümeyi kullanıcı tarafından belirlenen sayıda K adet kümeye ayırmaktır. K-ortalama kümeleme problemi: n adet verilen veri noktasında karesel hatayı en aza indirgeyecek k adet merkez noktası

bulmaktır. K adet merkez noktası bulunurken amaç, kümeler arasındaki benzerliği en aza, küme içi benzerliği en fazlaya ötelemektir. Adım sırası şu şekildedir:

1.Adım: Rastgele K adet küme merkezi atanır.

2.Adım: n adet veriden oluşan imge için karesel hatayı en aza indirgeyecek küme merkezleri belirlenir ve her bir piksel en yakın olduğu kümeye atanır.

3.Adım: Küme merkezleri yeni değerlere göre güncellenir.

4.Adım: Önceki küme merkezi ile yeni küme merkezi arasındaki fark belirli bir eşik değeri altında kalıncaya kadar işlem 2. Adımdan itibaren tekrarlanır.

Formülize edilecek olursa;

$$\mu_i = \frac{1}{|S_j|} \sum_{x_i \in S_j} x_i \tag{3.4}$$

N boyutlu veri kümesi $\{x_1, x_2, \ldots x_N\}$ karesel hatayı en aza indirgeyecek K adet $\{S_1, S_2 \ldots S_K\}$ kümeye bölünmek üzere μ_i kümelerdeki ortalama değer,

$$\underset{S}{\operatorname{argmin}} \sum_{i=1}^{k} \sum_{x \in S_i} \|x - \mu_i\|^2 \tag{3.5}$$

Denklem (3.4) ve Denklem (3.5) kullanılır.

Lloyd K-ortalama kümeleme algoritması genellikle gen analizlerinde iyi çözümler sunan bir yaklaşımdır [30]. Llyod algoritmasına göre kullanıcı tarafından K sayıda küme oluşturulur. Algoritma her bir küme içerisinde merkez olarak rastgele bir nokta seçer ve her yeni iterasyonda seçilen bu nokta kümenin gerçek merkezine (ağırlık merkezine) ötelenir ve ötelenen merkez noktasına göre yeni bir küme oluşturulur. Bu işlem artık merkez nokta sabit bir yerde kalıncaya kadar tekrarlanır.

4.KULLANILAN ALT UZAYLAR OLARAK RENK VE PCA UZAYI

4.1.Renk Kavramı

Renk kavramı ile ilgili yaygın ve kabul gören tanım 1940 yılında Amerika Optik Derneği Renkmetri Komitesi'nin yaptığı şu tanımdır: "Renk mekânsal veya geçici ışık özelliklerini içerir. Işık, gözün retinasının uyarılmasından kaynaklanan ve görsel algılamalar aracılığıyla bir gözlemcinin farkına vardığı ışıksal enerjidir." [31]

Elektromanyetik dalgaların insan gözü tarafından algılanabilmesi için 380 nm ile 780 nm arasında olmalıdır. Bu iki dalga boyu arasında kalan dalga boylarına "görülebilir ışık" adı verilir. Görülebilen ışığın en küçük dalga boyu 380 nm (mor) ve en büyük dalga boyu 780 nm (kırmızı) dir. Kısaca göz bu aralıktaki ışınları, mor ötesi (ultraviole) ve kızıl ötesi (infrared) ışınları arasını, ayırt edebilmektedir. Göz tarafından algılanan farklı dalga boylarındaki farklı enerjiye sahip ışınlar renk kavramını oluşturur.

Renk görüsü herhangi bir cisim tarafından yansıtılan, emilen veya iletilen ışığın bir organizma ya da makine tarafından algılanmasıdır. Aynı ışıklandırılmış nesne ya da aynı ışık kaynağı farklı kişiler tarafından farklı algılanabilir. Bunun nedeni insan retinasında bulunan konik ve çubuk algılayıcılarıdır. Renge karşı hassas olmayan çubuk algılayıcılar sadece ışık şiddetine karşı hassastır. Koniler ise renge karşı hassas olan hücrelerdir ve renkli görmeyi sağlarlar. Bu iki algılayıcı sayesinde görme işlemi gerçekleşir.

4.2.Renk Uzayları

Renkleri tanımlamak için kullanılan sistemlere renk uzayı adı verilmektedir. Renk uzayları, bütün renkleri kapsayacak şekilde üç boyutlu olarak tasarlanırlar. Bunun nedeni ise bir rengi tanımlamak için birbirinden farklı üç değişkene ihtiyaç duyulmasıdır. Renk uzayları arasında dönüşüm mevcuttur. Renk uzayları iki grupta toplanır. Bunlar: cihaz bağımlı renk uzayları ve cihaz bağımsız renk uzaylarıdır. Cihaz bağımsız renk uzayları CIE tarafından geliştirilmiştir.

CIE tarafından geliştirilen cihaz bağımsız renk uzayları renk ölçümleri için kullanılan uzaylardır. Cihaz bağımlı renk uzayları kullanılan cihaz özelliklerine göre değişkenlik gösteren uzaylardır. Cihaz bağımsız renk uzayları: CIE Lab, CIE XYZ, vb. Cihaz bağımlı renk uzayları: RGB, CMY, HSV, HSL, HSI, YCC vb.

4.2.1.RGB renk uzayı

RGB renk uzayında kırmızı yeşil ve mavi renkleri üç boyutlu renk uzayı küpünün ana renkleridir. Diğer bütün renkler bu renklerin belirli oranlarda karışımıyla elde edilir. Bu üç ana rengin %100 oranında karıştırılmasıyla beyaz renk, %0 oranında karıştırılmasıyla siyah renk elde edilir.

4.2.2.CMY renk uzayı

CMY renk uzayında cyan, magenta ve sarı üç boyutlu renk uzayı küpünün ana renkleridir. RGB renk uzayını tamamlayan bir renk uzayıdır. Bunun anlamı CMY renk uzayında bulunan iki bileşenin karışımıyla RGB renk uzayında tek bileşen elde edilebilmesidir. Örneğin; cyan ve sarı karışımı yeşili oluşturur. Magenta ve sarının karışımıyla kırmızı oluşur. RGB renk uzayının tersi şekilde bütün renklerin %100 oranında karışımı ile siyah renk, %0 oranında karışımıyla beyaz renk oluşur. CMYK uzayının çıkış noktası ise CMY ile saf siyah elde edilememektedir. Renkli yazıcılarda kullanılan saf siyah CMYK uzayı sayesinde mümkün olmuştur. RGB renk uzayından CMY renk uzayına geçiş Denklem (4.1) kullanılarak yapılabilir.

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{4.1}$$

4.2.3.HSV renk uzayı

Bileşenleri Hue (Renk), Saturation (Doygunluk), Value (Canlılık)dir. Renk 0-360 derece arası değer alır. Doygunluk renk içerisindeki grilik miktarıdır. 0-%100 arası değer alır. 0 gri tonlarını 100 ise yoğun renk anlamına gelir. Canlılık parametresi görüntünün içerisindeki aydınlığı yani ışığın oranını belirtmektedir. HSV uzayı HSB uzayı olarak da bilinir. RGB renk uzayından HSV renk uzayına geçiş için kullanılan denklemler aşağıda verilmiştir. Öncelikle R, G, B değerleri [0-1] aralığına normalize

edilir. Denklem (4.2), (4.3), (4.4), (4.5), (4.6), (4.7), (4.8) ve (4.9) kullanılarak HSV uzayına geçiş yapılabilir [32].

$$V = \max(R,G,B) \tag{4.2}$$

$$\max(R,G,B) = 0 \text{ ise } S = \infty \tag{4.3}$$

$$\max(R,G,B) \neq 0 \text{ ise } S = \frac{\max(R,G,B) - \min(R,G,B)}{\max(R,G,B)} \tag{4.4}$$

$$\text{Eğer } R = \max(R,G,B),\ H = \frac{G - B}{\max(R,G,B) - \min(R,G,B)} \tag{4.5}$$

$$\text{Eğer } G = \max(R,G,B),\ H = 2 + \frac{B - R}{\max(R,G,B) - \min(R,G,B)} \tag{4.6}$$

$$\text{Eğer } B = \max(R,G,B),\ H = 4 + \frac{R - G}{\max(R,G,B) - \min(R,G,B)} \tag{4.7}$$

$$H = 60H \tag{4.8}$$

$$H < 0 \text{ ise } H = H+360 \tag{4.9}$$

4.2.4.HSL renk uzayı

Bileşenleri Hue (Renk), Saturation (Doygunluk), Lightness (Parlaklık)'dır. Renk HSV uzayındaki ile aynı parametredir. Doygunluk parametresi HSV dekinden farklı tanımlanmıştır. Çünkü temel aldıkları parametre parlaklık ve canlılık farklılık gösterir. Farklı olarak parlaklık parametresi farklılık gösterir. Bu parametre bir renk tonunun içerisindeki beyaz miktarının değerini tanımlamaktadır. RGB renk uzayından HSL renk uzayına geçiş için kullanılan denklemler aşağıda verilmiştir. Öncelikle R,G,B değerleri [0-1] aralığına normalize edilir. RGB renk uzayından HSL renk uzayına Denklem (4.10), (4.11), (4.12), (4.13), (4.14), (4.15), (4.16), (4.17) ve (4.18) kullanılarak geçilebilir [32].

$$L = 0{,}5(\max(R,G,B) + \min(R,G,B)) \tag{4.10}$$

$$\text{Eğer } \max(R,G,B) = \min(R,G,B) \text{ ise } S = 0 \text{ ve } H = \infty \tag{4.11}$$

$$\text{Eğer } L \leq 0{,}5 \text{ ise } S = \frac{\max(R,G,B) - \min(R,G,B)}{\max(R,G,B) + \min(R,G,B)} \tag{4.12}$$

$$\text{Değilse } S = \frac{\max(R,G,B) - \min(R,G,B)}{2 - \max(R,G,B) - \min(R,G,B)} \tag{4.13}$$

$$\text{Eğer } R=\max(R, G, B),\ H = \frac{G - B}{\max(R,G,B) - \min(R,G,B)} \tag{4.14}$$

$$\text{Eğer } G = \max(R, G, B),\ H = 2 + \frac{B - R}{\max(R,G,B) - \min(R,G,B)} \tag{4.15}$$

$$\text{Eğer } B = \max(R, G, B),\ H = 4 + \frac{R - G}{\max(R,G,B) - \min(R,G,B)} \tag{4.16}$$

$$H = 60H \tag{4.17}$$

$$H < 0 \text{ ise } H = H + 360 \tag{4.18}$$

4.2.5.HSI renk uzayı

HSI renk uzayının bileşenleri Hue (Renk), Saturation (Doygunluk), Intensity (Şiddet) tur. Renk açısal olarak 0-360 derece aralığında ifade edilir. Doygunluk saf rengin içerisindeki beyaz miktarı, şiddet ise ışık miktarıdır. RGB renk uzayından HSI renk uzayına geçmek için Denklem (4.19), (4.20), (4.21), (4.22), (4.23) kullanılabilir [33].

$$H = \cos^{-1}\left\{\frac{0{,}5\left[(R - G)+(R - B)\right]}{\left[(R - G)^2 + (R - B)(G - B)\right]^{1/2}}\right\} \tag{4.19}$$

Eğer S = 0 ise H değeri anlam ifade etmez. (4.20)

Eğer (B/I) > (G/I) ise H = 360 – H'dır. (4.21)

Elde edilen sonuç derecedir ve normalize edilerek [0-1] aralığı elde edilir.

$$S = 1 - \frac{3}{(R + G + B)}\ [\min(R, G, B)] \tag{4.22}$$

$$I = \frac{1}{3}(R + G + B) \tag{4.23}$$

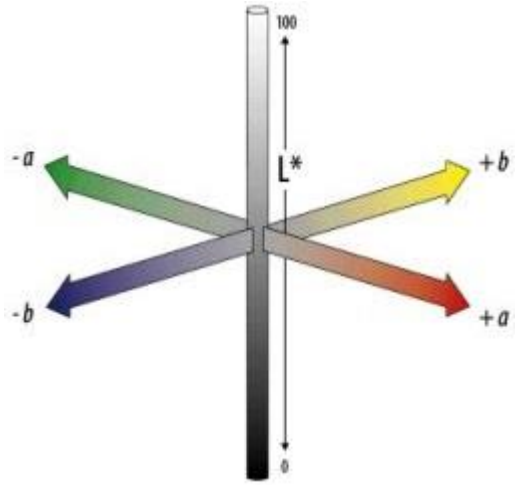
4.2.6.YCC renk uzayı

YCC renk uzayının bileşenleri Y (Luminance – Parlaklık), CC (Chrominance – Renk) bilgilerini barındırır. Bu renk uzayının geliştirilmesindeki video standardı oluşturulma çabasıdır. YCC renk uzayının TV uygulamaları (SDTV), (HDTV) için ve JPEG uygulamaları için renk uzayı dönüşümünde farklı katsayıları mevcuttur. Denklem (4.24) tam aralık renk dönüşümü JPEG imgeler için kullanılmaktadır. Denklemler kullanılarak elde edilen R/G/B ve $Y/C_b/C_r$ değeri [0-255] aralığındadır [34].

$$\begin{bmatrix} Y \\ C_b \\ C_r \end{bmatrix} = \begin{bmatrix} 0 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ -0,169 & -0,331 & 0,500 \\ 0,500 & -0,419 & -0,081 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{4.24}$$

4.2.7.CIE LAB uzayı

1976 yılında görsel medya için belirli bir standart oluşturmak adına kullanılmaya başlanmıştır. Algılayıcı tarafından algılanan renk uzayı değişiminin düzgün olması en önemli özelliğidir ve cihaz bağımsızdır.



Şekil 4.1. L*a*b Renk Uzayı [35]

Şekil 4.1'de LAB renk uzayının bileşenleri gösterilmektedir. L parametresi (Lightness: Parlaklık) A ve B parametreleri rengi tanımlamaktadır. L parlaklık parametresi 0 ile 100 arasında değerler almaktadır. Siyah rengin değeri 0, beyaz rengin değeri 100'dür. A ekseni yeşilden kırmıza doğru renk skalasını ifade etmekte olup –a yeşil rengi +a

kırmızı rengi gösterir. B ekseni maviden sarıya doğru renk skalasını ifade etmekte olup -b mavi rengi, +b sarı rengi ifade etmektedir. CIE XYZ uzayından CIE LAB uzayına geçiş için Denklem (4.25), (4.26), (4.27), (4.28) kullanılabilir [32].

$$L = 116\, f\left(\frac{Y}{Y_w}\right) - 16 \tag{4.25}$$

$$a = 500\,(f\left(\frac{X}{X_w}\right) - f\left(\frac{Y}{Y_w}\right) \tag{4.26}$$

$$b = 200\,(f\left(\frac{Y}{Y_w}\right) - f\left(\frac{X}{X_w}\right)) \tag{4.27}$$

$$f(a) = \begin{cases} a^{1/3}, & a \geq 0{,}008856 \\ 7{,}787a + \frac{16}{116}, & a < 0{,}008856 \end{cases} \tag{4.28}$$

4.2.8.CIE XYZ uzayı

X, Y, Z parametreleri kırmızı, yeşil ve mavi renklerin beyin tarafından algılanmasını sağlayan algılayıcılar olarak sembolize edilir. Üç rengin beyin tarafından algılanma oranı rengi sembolize eden parametrenin üç rengin sembollerin toplamına oranıyla bulunur.

Kırmızı rengin algısı;

$$x = \frac{X}{X+Y+Z} \tag{4.29}$$

Yeşil rengin algısı;

$$y = \frac{Y}{X+Y+Z} \tag{4.30}$$

Mavi rengin algısı;

$$z = \frac{Z}{X+Y+Z} \tag{4.31}$$

Renk algıları Denklem (4.29), (4.30) ve (4.31) şeklinde formüle edilir. Bu renk algılarının toplamı Denklem (4.32)'te gösterildiği gibi 1 eşittir.

$$x+y+z = 1 \tag{4.32}$$

Bu parametrelerin eşit oranda katılmasıyla beyaz renk elde edilir.

RGB uzayından XYZ uzayına geçmek için Denklem (4.33)'deki yapı kullanılabilir. M dönüşüm matrisi katsayıları kullanılan beyaz renk referansına ve görüş açısına bağlı olarak değişmektedir. Dönüşüm öncesinde RGB değerleri normalize edilmelidir [36].

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = [M] \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{4.33}$$

Normalize edilen R, G, B değerlerine gama düzenlemesi uygulanarak insan görme sistemine uygun olacak şekilde bant genişliğini maksimum verimle kullanılmış olur. Denklem (4.34), (4.35), (4.36) kullanılarak yapı doğrusal hale getirilir.

$$R = \begin{cases} ((R+0,55)/1,055)^{2,4}, & \text{eğer } R > 0,4045 \\ R/12,92, & \text{değilse} \end{cases} \tag{4.34}$$

$$G = \begin{cases} ((G+0,55)/1,055)^{2,4}, & \text{eğer } G > 0,4045 \\ G/12,92, & \text{değilse} \end{cases} \tag{4.35}$$

$$B = \begin{cases} ((B+0,55)/1,055)^{2,4}, & \text{eğer } B > 0,4045 \\ B/12,92, & \text{değilse} \end{cases} \tag{4.36}$$

Doğrusal yapı elde edildikten sonra CIE standartlarına göre 2 derecelik görüş açısına ve D65 aydınlatıcısına göre elde edilen katsayılar kullanılarak X,Y,Z değerleri Denklem (4.37) kullanılarak elde edilir [36].

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,4124 & 0,3576 & 0,1805 \\ 0,2126 & 0,7152 & 0,0722 \\ 0,0193 & 0,1192 & 0,9505 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{4.37}$$

4.3.Hiperspektral Görüntülerde Boyut Azaltımı

Hiperspektral görüntüler birçok banttan oluşan sayısal hesap yükü fazla olan, analizi zor yapılardır. Yüzlerce banttan oluşan hiperspektral görüntülerdeki bilgi miktarı oldukça fazladır bu nedenle kapladıkları alan fazla olmakta ve makine öğrenmesi imgedeki veriler arttıkça zorlaşmaktadır [37]. Boyut indirgeme yöntemlerindeki temel amaç orijinal verinin temel özellikleri kullanılarak bant sayısını küçültmektir. Bu

sayede daha kısa sürede sınıflandırma başarımının daha yüksek olduğu sonuçlar elde edilmektedir.

Boyut azaltmada kullanılan yöntemler temel olarak iki grupta kategorize edilmektedir. Bunlar: özellik seçimi ve özellik çıkarımıdır.

Özellik seçimi yaklaşımları orijinal bantlar üzerinde bir değişiklik yapmadan en çok bilgi taşıyan bantları seçmeyi amaçlar. Aynı şekilde en az bilgi taşıyan bantlar, gürültü içeren bantlar çıkarılır. Mevcut bantlar arasından seçilen bantlarla yeni bir veri alt kümesi oluşturulur. Birçok farklı özellik seçimi yaklaşımı bulunmaktadır. Bunlardan bazıları: ileri arama, geri arama, kayan arama vb. Özellik çıkarımında ise hiperspektral verinin tamamının birleşiminden oluşan ve giriş verisini en iyi şekilde temsil eden daha küçük boyutlu veri seti bulmak temel amaçtır. Oluşturulan yeni bantlar orijinal bantlardan farklıdır. Daha az sayıda ve daha çok bilgi taşımaları amacıyla oluşturulurlar. Özellik çıkarma algoritmaları için birçok çalışma yapılmıştır. PCA özellik çıkarma yöntemlerinden çokça kullanılanlarından bir tanesidir. LDA diğer bir özellik çıkarım yöntemidir.

4.3.1.PCA uzayı

Bir öznitelik ya da bant çıkarımı yaklaşımı olan temel bileşen analizi bir iz düşüm yöntemidir. Yüksek boyuttan düşük boyuta en az veri kaybıyla geçiş yapmayı sağlayan yöntemdir. PCA birbirleriyle ilgili verileri aralarındaki bağıntıyı yok ederek tamamen birbirleriyle ilgisiz veriler elde etmeye çalışan ve bu işlemi yaparken ortagonal dönüşümü kullanan istatiksel bir prosedürdür.

PCA hesaplanırken şu adımlar izlenir: İlk olarak orijinal veride ortalama değer matrisi hesaplanır. Ortalama değer matrisi hesaplanırken veri kümesine ait elemanların değerleri toplanarak eleman sayısına bölünmesiyle bulunur. Z_j veri kümesine ait j. eleman, J de bu veri kümesine ait eleman sayısını temsil etmek üzere ortalama vektör Denklem (4.38)'te görüldüğü gibi hesaplanır.

$$\mu_Z = \frac{1}{J}\sum_{j=1}^{J} Z_j \tag{4.38}$$

İkinci olarak orijinal veride kovaryans matrisi hesaplanır. Kovaryans matrisi hesaplanırken Denklem (4.39)'daki denklem kullanılır.

$$\sum_Z = \frac{1}{J}\sum_{j=1}^{J}(Z_j-\mu_z)(Z_j-\mu_z)^T \tag{4.39}$$

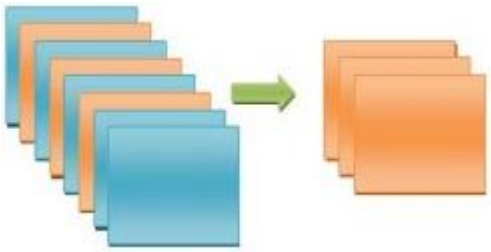
Kovaryans matrisi iki ya da daha fazla boyut için geçerlidir. Boyutlar arasındaki ilişkinin tespiti için kullanılır. Kovaryans değeri pozitif bir değer ise iki değerin iki boyutta da artmış olduğunu gösterir. Kovaryans değeri negatif bir değer ise bir değerin artarken diğerinin azaltmakta olduğunu gösterir. Eğer iki değer birbirlerinden bağımsız ise kovaryans değeri sıfır olmaktadır. Sonraki aşamada öz değerler ve özvektörler hesaplanır. Öz değerler Denklem (4.40) kullanılarak hesaplanır. Öz değerler, öz vektörler, öz uzaylar bir matrisin özellikleridir ve matris hakkında önemli bilgiler vermektedir. Öz vektörler ancak kare matrislerden elde edilebilir. Bu nedenle bir öz değer ve öz vektör elde etmek için kovaryans matrisler kullanılmaktadır [38].

$$P^T\sum_Z P = \Lambda_Z \tag{4.40}$$

Son olarak hesaplanan öz vektörler kullanılarak temel bileşen dönüşümü yapılır. Temel bileşen dönüşümü için Denklem (4.41) kullanılabilir.

$$X_j = P^T(Z_j-\mu_z) \tag{4.41}$$

Öz değerler, veriler o öz değere karşılık gelen öz vektöre iz düşüm yapıldığındaki verinin varyansıdır. En büyük varyansa sahip olmak en fazla değişimi göstermek olduğundan öz değerlerin en büyükleri seçilerek işlem gerçekleştirilir. Şekil 4.2'de PCA boyut azaltım yöntemi gösterilmektedir.



Şekil 4.2. PCA boyut azaltımı yöntemi [39]

PCA ilk temel bileşeni varyansı en büyükleyen en büyük öz değere karşılık gelen vektördür. İkinci temel bileşen ilk bileşene dik olan ve kalan verilerin değişintisinin ikinci olarak büyükleyen vektördür. Üçüncü temel bileşen önceki eksenlere dik olan ve verilerin değişintisini üçüncü olarak büyükleyen vektördür. Böylelikle kaç adet temel bileşen seçilecekse bu sistematik devam eder ve oluşturulan vektörler her zaman kalan verilerdeki değişintiyi en büyükleyen yön seçilir. Özetle, temel bileşenler analizi boyut azaltmada kullanılan ve boyut azaltma yaparken de orijinal veriler için dik olan en büyük varyans yönleri bulup orijinal verileri bu koordinat sisteminde gösteren bir yöntemdir.

5.HİPERSPEKTRAL GÖRÜNTÜLERİN FARKLI UZAYLARDA SÜPERPİKSEL TEMELLİ SPEKTRAL SINIFLANDIRILMASI

Yapılan çalışmada hiperspektral sınıflandırma problemini çözmek için SVM, denetimli öğrenme yöntemi tercih edilmiştir. Kullanılan veri setleri için %2, %5, %10, %20, %30 rastgele seçilen eğitim verisi ile SVM sınıflandırıcı eğitilmiştir ve eğitim verisine göre oluşturulan model kalan veriler ile test edilmiştir. Deney sonuçları Bölüm 5.3'te paylaşılmıştır. Her deney 50 kez tekrar edilmiş olup sınıf bazlı sınıflandırma başarımı, ortalama sınıflandırma başarımı ve standart sapma değerleri hesaplanmıştır. Ceza parametresi C = {10^ (-1)... 10^ (7)} aralığında sistemi en iyileyecek şekilde seçilmiştir. SVM'de kullanılan parametreler için en iyi sonuç veren değeri elde etmek için çapraz doğrulama kullanılmıştır. SVM sınıflandırıcı için polinomal çekirdek kullanılmıştır. Sınıflandırma işlemi için AVIRIS Indian Pines düzeltilmiş (104-108, 150-163, 220 bantları çıkartılmış 200 banttan oluşan) veri seti ve ROSIS Pavia University veri seti kullanılmıştır. Yapılan bütün deneyler için LIBSVM kütüphanesi kullanılmıştır.

5.1.Kullanılan Veri Setleri

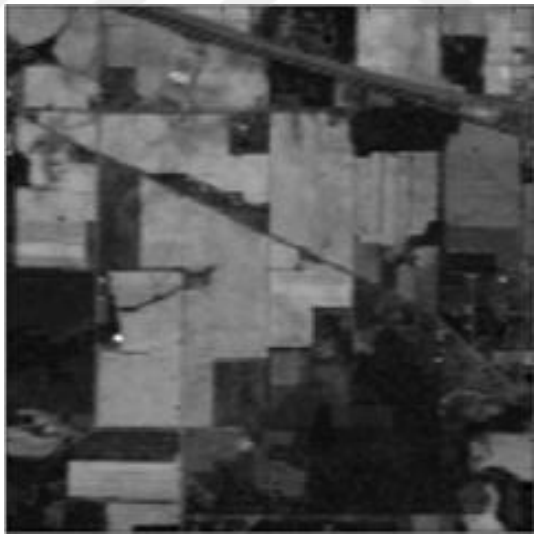
5.1.1.AVIRIS Indian Pines veri seti

Deneylerde kullanılan veri seti 1992 yılında kuzeybatı Indiana bölgesinden Indian Pines bölge üzerinde AVIRIS sensörleri tarafından toplanmıştır. Her bir bantta 145 x 145 boyutunda tarım / orman alanı üzerinden erken büyüme döneminde alınmış görüntülerden oluşur. Dalga boyu aralığı 0,4 – 2,5 μm, dalga boyu çözünürlüğü 10 nm olan 220 spektral banttan oluşur. Gürültülü bantlar ve su soğurma bantları (104-108, 150-163, 220 bantları) çıkarıldığı zaman 200 bant kalmaktadır. Deneyde gürültülü bantlar çıkartılmış 200 banttan oluşan veri seti kullanılmıştır. Veri seti 16 sınıftan ve 10249 örnekten oluşmaktadır. Mutlak doğru (Groundtruth) verisi sınıflandırma algoritmalarında sınıflandırma başarımını ölçmek için kullanılmaktadır [40].



Şekil 5.1. 16 sınıftan oluşan AVIRIS Indian Pines mutlak doğru verisi [41]

Şekil 5.1'de Aviris Indian Pines mutlak doğru verisine ait görüntü, Şekil 5.2'de Aviris Indian Pines veri setinin 170. bandına ait görüntü gösterilmektedir



Şekil 5.2. AVIRIS Indian Pines 170. bant görüntüsü

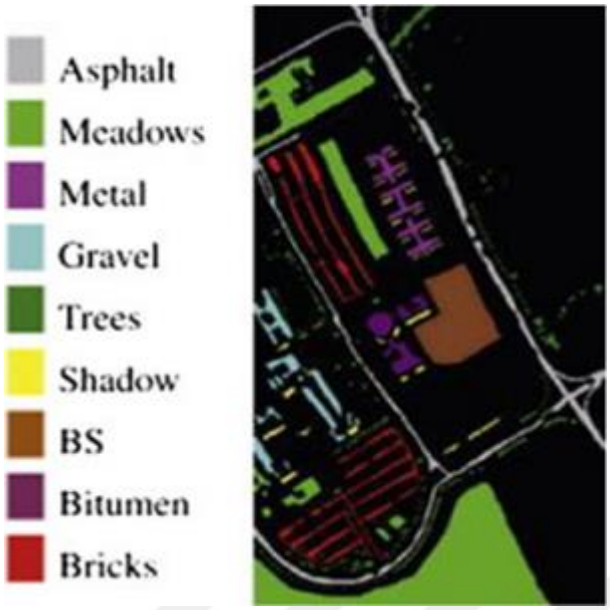
Tablo 5.1'de Aviris Indian Pines veri setine ait 16 sınıf ve 10249 etiketli örnek sayısı gösterilmektedir. Aviris Indian Pines veri setini kullanarak elde edilen sınıflandırma başarım sonuçları Bölüm5.3'te Tablo 5.3, 5.4, 5.5, 5.6, 5.7'de gösterilmektedir.

Tablo 5.1. AVIRIS Indian Pines Veri Kümesi Sınıf ve Örnek Sayısı [40]

Sınıf	**Etiketli Örnek Sayısı**
1.Alfafa	46
2.Corn-notill	1428
3.Corn-mintill	830
4.Corn	237
5.Grass-pasture	483
6.Grass-trees	730
7.Grass-pasture-mowed	28
8.Hay-windrowed	478
9.Oats	20
10.Soybean-notill	972
11.Soybean-mintill	2455
12.Soybean-clean	593
13.Wheat	205
14.Woods	1265
15.Buildings-Grass-Trees-Drives	386
16.Stone-Steel-Towers	93

5.1.2.ROSIS Pavia University veri seti

Pavia University verileri ROSIS sensörleri kullanılarak kuzey İtalya'da Pavia üzerindeki bir uçuş sırasında elde edilmiştir. Veri seti 103 spektral banttan oluşmaktadır. Pavia University veri seti normalde 610*610 pikselden oluşan imgelerden oluşmaktadır ancak bazı pikseller hiçbir bilgi taşımadığı için çıkartılmıştır. Kullanılan veri seti 610*340 pikselden oluşmaktadır. Geometrik çözünürlük 1.3 metredir. Mutlak doğru verisi 9 sınıf ve 42776 örnekten oluşmaktadır [40]. ROSIS veri seti dalga boyu 0,43 – 0,86 μm aralığını kapsar. Rosis Pavia University veri setini kullanarak elde edilen sınıflandırma başarım sonuçları Bölüm5.3'te Tablo 5.8, 5.9, 5.10, 5.11, 5.12'de gösterilmektedir.



Şekil 5.3. 9 sınıftan oluşan ROSIS Pavia University mutlak doğru verisi [42]

Şekil 5.3'te Rosis Pavia University mutlak doğru verisine ait görüntü, Şekil 5.4'te Rosis Pavia University veri setinin 50. bandına ait görüntü gösterilmektedir.



Şekil 5.4. ROSIS Pavia University 50. bant görüntüsü

Tablo 5.2'de Rosis Pavia University veri setine ait 9 sınıf ve 42776 etiketli örnek sayısı gösterilmektedir.

Tablo 5.2. ROSIS Pavia University Veri Kümesi Sınıf ve Örnek Sayısı [40]

Sınıf	**Etiketli 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

5.2.Deneyler

Yapılan çalışma 5 aşamalı olarak gerçekleştirilmiştir. Bu adımlar aşağıdaki gibidir.

1.Adım: Veri setinin direkt olarak SVM girişine uygulanması

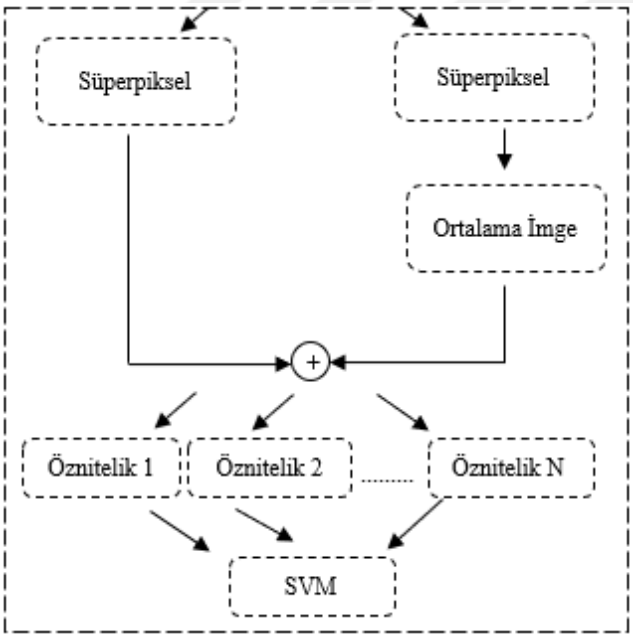
2.Adım: RGB uzayında SLIC süperpiksellerin elde edilmesi ve SVM girişine uygulanması

3.Adım: LAB uzayında SLIC süperpiksellerin elde edilmesi ve SVM girişine uygulanması

4.Adım: PCA uzayında SLIC süperpiksellerin elde edilmesi ve SVM girişine uygulanması

5.Adım: Spektral uzayda SLIC süperpiksellerin elde edilmesi ve SVM girişine uygulanması

Adım 2, 3, 4, 5 için süperpiksellerin elde edildiği uzay farklılık göstermektedir. Adım 2'de RGB imgeden SLIC süperpikseller elde edilirken, adım 3'te LAB imgeden, adım 4'te PCA imgeden, adım 5'te doğrudan hiperspektral imgeden süperpikseller elde edilmiştir. Şekil 5.5'te bu yapının genel ifadesi yer almaktadır. Kullanılan alt uzay farklılık göstersede süperpiksel temelli spektral sınıflandırma kısmı bütün uzaylar için aynıdır. Şekil 5.5'te görülmekte olan yapı kullanılan alt uzayların SLIC süperpiksel algoritması kullanılarak elde edilen spektral özniteliklerin SVM girişine uygulanmasını göstermektedir. Bu kısım kullanılan bütün alt uzaylar için aynı olup Şekil 5.7, Şekil 5.10, Şekil 5.13 ve Şekil 5.16'daki şekillerde süperpiksel temelli spektral sınıflandırma olarak adlandırılacaktır.



Şekil 5.5. Süperpiksel temelli spektral sınıflandırma

Ortalama imgeyi elde ederken kullanılan SLIC süperpiksel parametreleri Aviris Indian Pines veri seti için bölge boyutu = 8, düzenleyici = 0.01, Rosis Pavia University veri seti için bölge boyutu = 3, düzenleyici = 0.01'dir. Her bir süperpiksel için ortalama değer hesaplanır ve süperpiksellerin içi bu ortalama değer ile doldurulur ve bu işlem sonucunda ortalama değer imgesi elde edilir. Spektral öznitelikler elde edilirken ise kullanılan SLIC süperpiksel parametreleri Aviris Indian Pines veri seti için bölge boyutu = 1, düzenleyici = 0.01, Rosis Pavia University veri seti için bölge boyutu = 2, düzenleyici = 0.01'dir. İkinci kez süperpiksel hesaplamada kullanılan SLIC

parametrelerinin birinciden farklı olmasının sebebi veri ve etiket oluşturmak için kullanılan süperpikselin boyutunun ne kadar küçük ise o oranda hata yapma riskinin azalmasıdır.

Mutlak doğru imgesi de süperpiksellere göre sınıflandırılır. Bunun nedeni artık piksel temelli bir sınıflandırma değil süperpiksel temelli bir sınıflandırma yapılmaktadır. Süperpiksel temelli yaklaşım piksel temelli bir yaklaşıma göre yapılan hesaplamalar daha kolay ve hızlı olmaktadır.

5.2.1.Hiperspektral görüntülerde SVM

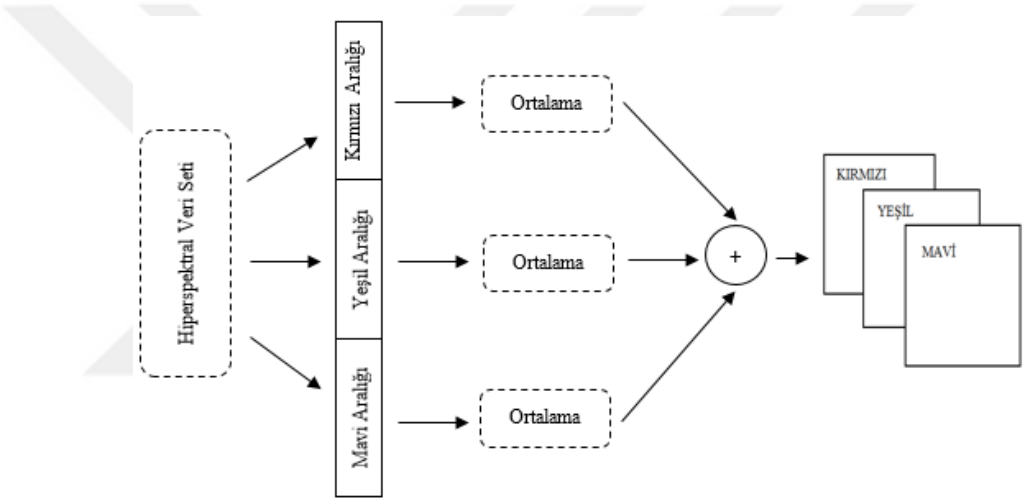
Klasik piksel temelli hiperspektral görüntü sınıflandırma yaklaşımlarında uzamsal komşuluk ilişkileri dikkate alınmadan sadece piksele ait spektral bilgi kullanılmaktadır. Süperpiksel temelli hiperspektral görüntü sınıflandırma yaklaşımı ise hem uzamsal bilgi hem de spektral bilgiyi kullanmaktadır. Uzamsal ve spektral bilginin birlikte kullanılmasının HSI sınıflandırma başarımını arttırdığı bilinmektedir [43], [44]. Uzamsal olarak aynı yerel bölgeye ait olan piksellerin benzer spektral karakteristiklere sahip olmaları gerektiği bilgisi temel alınarak uzamsal ve spektral bilginin birlikte kullanılmasının sınıflandırma başarımını olumlu yönde etkileyeceği üzerine [43]'da çalışılmıştır. İlk adım olarak klasik piksel temelli hiperspektral görüntü sınıflandırma çalışması yapılmıştır. Kullanılan veri setleri direkt olarak SVM girişine uygulanmıştır. Elde edilen sonuçlar Bölüm 5.3'teki tablolarda SVM sütunu altında paylaşılmıştır.

5.2.2.Hiperspektral görüntülerde RGB uzayı SLIC süperpiksel

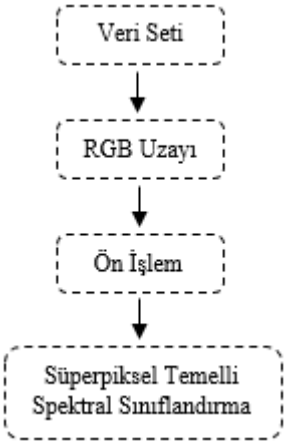
İnsan gözü tarafından algılanabilen renkli imgeyi elektromanyetik spektrumun görülebilir dalga boyu aralığından seçilen üç bandın birleşimi oluşturur. Mavi renk spektrumu 400 - 510 nm aralığı, yeşil renk spektrumu 490 - 650 nm aralığı, kırmızı renk spektrumu 590 - 750 nm aralığındadır.

Hiperspektral imgeler çok bantlı yapılardır ve çok bantlı yapıları gereği direkt olarak görüntülenemezler. Hiperspektral imgelerin görselleştirilmesi için [45], [46], [47] gibi birçok çalışma yapılmıştır. Orijinal hiperspektral imgelerin RGB imgelerini elde ederken ya hiperspektral imgelerden üç bant direkt olarak seçilebilir ya da orijinal

bantların birleşimi şeklinde RGB bantları elde edilir. Ancak belirtilen her iki yöntemde de veri kaybı oluşmaktadır [45]. RGB uzayı cihaz bağımlı, uniform olmayan bir yapıya sahiptir. Dolayısıyla hem elde edilirken uğradığı veri kaybı hem de barındırdıkları dezavantajları SLIC-RGB sınıflandırma sonuçlarının neden SLIC-LAB ve SLIC-PCA'dan daha düşük olduğunu açıklamaktadır. Yapılan çalışmada hiperspektral veriden RGB imge elde edilirken görünür bölgenin kırmızı, yeşil ve mavi bant aralıklarının ortalaması alınarak 3 bantlı renkli imge elde edilir. Kullanılan veri setleri Şekil 5.6'daki genel yapı kullanılarak RGB uzayına dönüştürülmüş ve renkli görüntü verisi elde edilmiştir. Elde edilen RGB imgesi SLIC süperpiksel algoritmasının girdisidir.



Şekil 5.6. Hiperspektral veri setinden RGB imge elde edilmesi



Şekil 5.7. RGB uzayı SLIC süperpiksel temelli spektral sınıflandırma

Renkli imge ön işlemden geçirilerek gürültü etkisi azaltılmış olur. Kullanılan şemanın genel yapısı Şekil 5.7'de verilmiştir. Ön işlemden geçirilmiş RGB uzayındaki imge SLIC ile süperpiksellere ayrılır. Süperpiksellerin elde edilmesi ve özniteliklerin çıkartılıp SVM girişine uygulanması Şekil 5.5'de detaylı olarak gösterilmekte olup Şekil 5.7'de süperpiksel temelli spektral sınıflandırma olarak adlandırılmaktadır.



Şekil 5.8. AVIRIS Indian Pines RGB imgesi

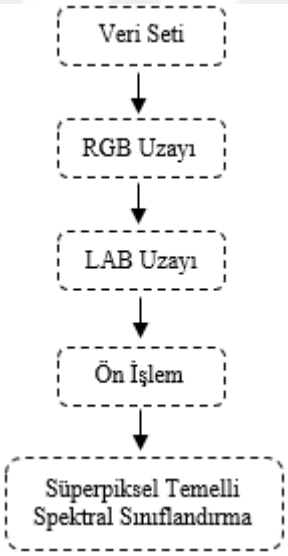


Şekil 5.9. ROSIS Pavia University RGB imgesi

Sonuçlar Bölüm 5.3'teki tablolarda SLIC-RGB sütunu altında paylaşılmıştır. Şekil 5.8'de Aviris Indian Pines RGB imgesi ve Şekil 5.9'da Rosis Pavia University RGB imgesi gösterilmektedir.

5.2.3.Hiperspektral görüntülerde LAB uzayı SLIC süperpiksel

LAB renk uzayı algılayıcı tarafından algılanan renk uzayı değişiminin düzgün olması, cihaz bağımsız olması, insan görüş algısına benzer olması gibi önemli avantajlara sahiptir. Dolayısıyla LAB renk uzayının sağladığı avantajlar sınıflandırma başarımlarına yansımış ve SLIC-RGB ve SLIC-Spektral'a göre sınıflandırma başarımlarının daha yüksek olduğu Bölüm 5.3'te gözlemlenmiştir. Renk uzayları arasında geçiş mümkündür. Böylece veri setleri öncelikle RGB uzayına dönüştürülmüş daha sonra LAB uzayına geçiş yapılmıştır. Kullanılan renk uzaylarından ve renk uzayları arasındaki geçişlerden Bölüm 4.2'de bahsedilmiştir.



Şekil 5.10. LAB uzayı SLIC süperpiksel temelli spektral sınıflandırma

Kullanılan şemanın genel yapısı Şekil 5.10'da verilmiştir. LAB uzayındaki imge ön işlemden geçirilerek gürültü etkisi azaltılmış olur. Ön işlemden geçirilmiş LAB uzayındaki imge SLIC ile süperpiksellere ayrılır. Süperpiksellerin elde edilmesi ve özniteliklerin çıkartılıp SVM girişine uygulanması Şekil 5.5'de detaylı olarak gösterilmekte olup Şekil 5.10'da süperpiksel temelli spektral sınıflandırma olarak adlandırılmaktadır.



Şekil 5.11. AVIRIS Indian Pines LAB imgesi

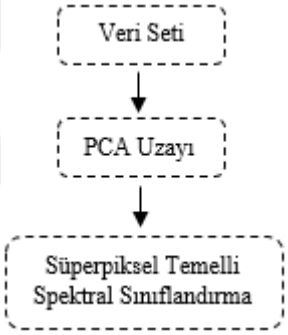


Şekil 5.12. ROSIS Pavia University LAB imgesi

Şekil 5.11’de Aviris Indian Pines LAB imgesi ve Şekil 5.12’de Rosis Pavia University elde edilen LAB imgeleri gösterilmektedir. Elde edilen sonuçlar Bölüm 5.3’teki tablolarda SLIC-LAB sütunu altında paylaşılmıştır.

5.2.4.Hiperspektral görüntülerde PCA uzayı SLIC süperpiksel

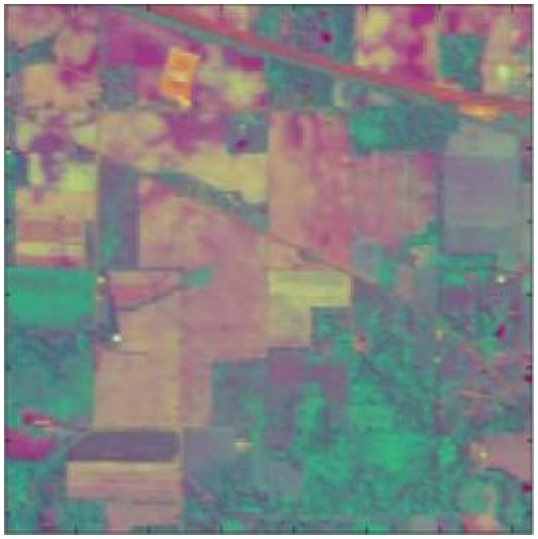
Hiperspektral görüntüler birçok banttan oluşan sayısal hesap yükü fazla olan, analizi zor yapılar oldukları için boyut indirgeme yöntemleri kullanılmaktadır Büyük boyutlu veri setlerinde yapılan işlemler oldukça uzun süreler almaktadır. Bu veri setleri için kullanılan uzaylar daha karmaşık ve parametreler daha fazladır. Veri boyutunu küçülterek bu işlemler için kullanılan zaman azaltılmış olur. Daha az parametre ve basit bir şekilde daha rahat anlaşılabilen çözümlere gidilebilir. Küçük veri setlerinde daha iyi çalışabilen yapılar elde edilebilir. Aynı zamanda veri boyutunun azaltılması sırasında bazı veriler de kaybolur. PCA kullanımındaki asıl amaç veri boyutunu küçültürken varyansı yüksek tutarak veri kaybını minimuma düşürmektir. Süperpiksel yaklaşımından önce ön işlem adımı olarak hiperspektral görüntülere PCA uygulanması [43], [44]'da çalışılmıştır.



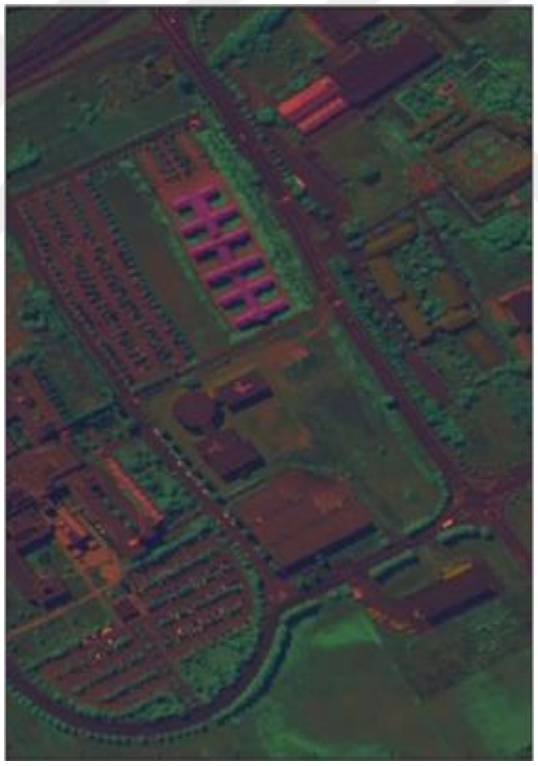
Şekil 5.13. PCA uzayı SLIC süperpiksel temelli spektral sınıflandırma

Bir öznitelik çıkartım yöntemi olan PCA temel bileşen dönüşümünü kullanarak orijinal hiperspektral imge içerisinde birbirinin doğrusal birleşimi olan yeni bantlar oluşturur. Yapılan çalışmada ilk üç bileşen kullanılmıştır.

Yapılan çalışmaya ait genel şema Şekil 5.13'de verilmiştir. PCA uzayındaki imge SLIC ile süperpiksellere ayrılır. Süperpiksellerin elde edilmesi ve özniteliklerin çıkartılıp SVM girişine uygulanması Şekil 5.5'de detaylı olarak gösterilmekte olup Şekil 5.13'de süperpiksel temelli spektral sınıflandırma olarak adlandırılmaktadır.



Şekil 5.14. AVIRIS Indian Pines PCA imgesi

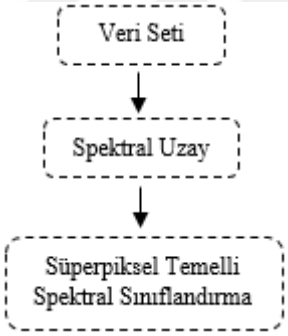


Şekil 5.15. ROSIS Pavia University PCA imgesi

Şekil 5.14’de Aviris Indian Pines PCA imgesi, Şekil 5.15’de Rosis Pavia University elde edilen PCA imgeleri gösterilmektedir. Elde edilen sonuçlar Bölüm 5.3’teki tablolarda SLIC-PCA sütunu altında paylaşılmıştır.

5.2.5.Hiperspektral görüntülerde spektral uzay SLIC süperpiksel

Hiperspektral veri setleri dar dalga boyu aralıklarıyla elde edilmiş ve sürekli yüzlerce banttan oluşmaktadır. Bu süreklilik sebebiyle hiperspektral veri setleri hiper küpler olarak da adlandırılırlar. Hiperspektral görüntüleme Bölüm 1.2'de detaylı olarak incelenmiştir. Yüzlerce banttan oluşan veri setlerine direkt olarak SLIC süperpiksel algoritması uygulanır. Bölüm 3.2'de detaylı şekilde bahsedilen SLIC algoritması süperpikselleri hesaplarken piksellerin konum (x, y) ve renk değerlerini (L, a, b) kullanmaktadır. Hesaplamada kullanılan konum değerleri ile komşu piksellerin uzamsal ilişkileri de hesaplanmış olmaktadır. Kullanılan yapıya ait genel şema Şekil 5.16'da verilmiştir. Süperpiksel algoritması uygulandıktan sonra yapılan aşamalar RGB, LAB ve PCA uzayları için kullanılan yapının aynısıdır. Spektral uzaydaki imge SLIC ile süperpiksellere ayrılır. Süperpiksellerin elde edilmesi ve özniteliklerin çıkartılıp SVM girişine uygulanması Şekil 5.5'de detaylı olarak gösterilmekte olup Şekil 5.16'de süperpiksel temelli spektral sınıflandırma olarak adlandırılmaktadır.



Şekil 5.16. Spektral uzay SLIC süperpiksel temelli spektral sınıflandırma

Elde edilen sonuçlar Bölüm 5.3'teki tablolarda SLIC-Spektral sütunu altında paylaşılmıştır. Bölüm 6'da deney sonuçları değerlendirilmiştir. Tablo 5.3, 5.4, 5.5, 5.6, 5.7'de Indian Pines veri setinde farklı eğitim ve test verileri için alınan sınıflandırma başarımları, Tablo 5.8, 5.9, 5.10, 5.11, 5.12'de Pavia University veri setinde farklı eğitim ve test verileri için alınan sınıflandırma başarımları gösterilmektedir.

5.3.Deney Sonuçları

Tablo 5.3'de Indian Pines veri seti için %2 eğitim verisi kullanılarak direkt veri setinin SVM'e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.3. Indian Pines %2 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	23,91	93,66	86,6	93,77	80,20
Sınıf 2	52,08	78,85	77,87	81,15	74,01
Sınıf 3	45,55	79,53	77,32	80,03	69,48
Sınıf 4	32,32	55,01	55,91	63,43	62,53
Sınıf 5	77,53	85,77	85,32	84,68	79,78
Sınıf 6	88,65	89,75	93,43	91,86	92,51
Sınıf 7	54,37	96,00	95,64	83,81	74,47
Sınıf 8	94,16	90,50	97,42	92,38	94,59
Sınıf 9	27,47	45,00	38,12	83,55	88,59
Sınıf 10	45,97	74,62	78,57	76,62	67,13
Sınıf 11	71,79	87,51	87,09	86,98	80,89
Sınıf 12	30,45	67,70	66,81	65,82	60,22
Sınıf 13	89,16	95,51	98,71	96,73	92,06
Sınıf 14	90,07	97,78	98,30	97,41	96,88
Sınıf 15	31,13	76,80	84,61	81,29	76,39
Sınıf 16	85,15	94,5	94,43	97,63	93,09
Ortalama	64,53	83,92	84,75	84,70	79,50
S.Sapma	0,0163	0,0221	0,0214	0,0226	0,0255

Tablo 5.4‘de Indian Pines veri seti için %5 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.4. Indian Pines %5 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	52,79	97,64	90,21	97,71	87,47
Sınıf 2	67,67	88,68	89,44	89,99	85,30
Sınıf 3	62,30	90,22	91,31	89,16	78,39
Sınıf 4	43,045	73,15	74,40	74,46	80,22
Sınıf 5	87,82	91,31	90,39	91,14	88,24
Sınıf 6	93,08	95,49	97,04	96,59	97,11
Sınıf 7	69,08	100,00	95,81	95,40	56,94
Sınıf 8	94,55	96,63	99,35	96,77	97,26
Sınıf 9	22,00	18,87	14,35	68,22	84,00
Sınıf 10	58,04	82,32	86,86	89,93	77,76
Sınıf 11	74,55	93,94	95,02	93,96	91,22
Sınıf 12	56,01	83,80	86,01	84,94	80,63
Sınıf 13	94,65	96,00	98,74	96,80	93,94
Sınıf 14	91,29	99,43	99,27	99,15	99,08
Sınıf 15	47,66	90,16	94,54	92,50	90,02
Sınıf 16	87,89	94,88	94,48	96,90	93,45
Ortalama	73,47	91,38	92,71	92,42	88,57
S.Sapma	0,0100	0,0121	0,0097	0,0106	0,0123

Tablo 5.5‘de Indian Pines veri seti için %10 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.5. Indian Pines %10 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	58,00	97,46	90,39	97,69	88,06
Sınıf 2	74,21	91,50	91,59	92,91	87,95
Sınıf 3	68,65	92,33	92,51	91,13	80,20
Sınıf 4	54,30	78,70	78,12	79,77	88,32
Sınıf 5	91,13	92,83	92,57	93,63	91,72
Sınıf 6	94,26	97,82	98,15	97,74	98,60
Sınıf 7	73,04	100,00	96,70	95,68	84,75
Sınıf 8	96,98	98,86	99,40	98,98	98,14
Sınıf 9	42,33	19,07	25,01	81,65	92,12
Sınıf 10	67,94	89,21	90,96	93,19	83,85
Sınıf 11	78,81	96,51	97,39	96,57	94,50
Sınıf 12	71,99	88,58	94,17	89,93	85,90
Sınıf 13	96,31	97,66	98,67	97,80	95,95
Sınıf 14	93,04	99,50	99,52	99,79	99,45
Sınıf 15	55,20	93,70	96,23	95,27	95,72
Sınıf 16	91,06	94,79	94,39	97,66	93,11
Ortalama	78,95	93,90	94,91	94,90	91,66
S.Sapma	0,0075	0,0055	0,0038	0,0069	0,0085

Tablo 5.6‘de Indian Pines veri seti için %20 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.6. Indian Pines %20 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	71,94	97,76	90,31	97,66	88,06
Sınıf 2	79,93	91,81	92,19	93,27	90,27
Sınıf 3	74,71	92,66	93,16	91,91	80,52
Sınıf 4	64,15	79,78	79,57	82,89	93,25
Sınıf 5	93,16	94,21	94,02	95,43	93,22
Sınıf 6	96,05	98,96	98,46	98,23	99,31
Sınıf 7	75,27	100,00	96,11	95,65	88,86
Sınıf 8	97,72	99,76	99,43	99,42	98,81
Sınıf 9	62,75	10,62	24,14	92,27	91,43
Sınıf 10	73,61	90,91	92,69	95,68	85,97
Sınıf 11	82,91	97,58	98,61	97,52	95,73
Sınıf 12	80,76	92,33	95,09	91,23	88,68
Sınıf 13	97,66	98,21	98,70	98,86	97,50
Sınıf 14	94,44	99,70	99,63	99,82	99,80
Sınıf 15	64,62	94,560	96,34	97,16	97,52
Sınıf 16	93,78	94,82	94,73	97,79	93,75
Ortalama	83,52	95,08	95,71	95,91	93,09
S.Sapma	0,0063	0,0038	0,0030	0,0033	0,0036

Tablo 5.7‘de Indian Pines veri seti için %30 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.7. Indian Pines %30 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	77,37	97,45	90,71	97,73	87,21
Sınıf 2	81,99	91,80	92,59	93,79	90,51
Sınıf 3	78,23	92,68	92,80	91,95	81,12
Sınıf 4	70,86	79,34	81,17	81,91	95,16
Sınıf 5	94,16	95,03	94,64	95,87	93,87
Sınıf 6	96,64	99,25	98,54	98,25	99,35
Sınıf 7	79,68	100,00	95,75	95,33	89,17
Sınıf 8	98,39	100,00	99,58	99,66	99,17
Sınıf 9	66,14	7,09	24,33	95,84	94,33
Sınıf 10	73,26	92,06	93,25	96,69	85,71
Sınıf 11	84,89	98,09	98,77	97,69	96,04
Sınıf 12	84,56	93,29	95,65	93,14	89,27
Sınıf 13	98,17	98,68	98,90	99,67	98,18
Sınıf 14	94,97	99,82	99,71	99,88	99,83
Sınıf 15	68,98	94,70	96,97	97,6	97,91
Sınıf 16	93,78	94,73	95,88	97,73	93,55
Ortalama	85,70	95,45	95,98	96,29	93,38
S.Sapma	0,0043	0,0019	0,0025	0,0022	0,0034

Tablo 5.8‘de Pavia University veri seti için %2 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.8. Pavia University %2 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	86,10	88,53	90,45	89,93	86,81
Sınıf 2	95,90	97,26	97,54	96,97	96,42
Sınıf 3	66,89	77,51	74,95	79,75	76,55
Sınıf 4	89,22	84,34	89,34	91,20	88,49
Sınıf 5	99,28	99,06	98,87	99,00	98,16
Sınıf 6	65,07	72,30	74,65	75,63	70,38
Sınıf 7	72,70	88,54	87,69	92,35	90,07
Sınıf 8	80,33	84,10	87,07	87,48	85,09
Sınıf 9	95,51	94,98	95,90	95,76	96,16
Ortalama	86,89	89,70	90,88	91,14	89,29
S.Sapma	0,0065	0,0110	0,0077	0,0104	0,0118

Tablo 5.9‘da Pavia University veri seti için %5 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.9. Pavia University %5 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	**SVM**	**SLIC RGB**	**SLIC LAB**	**SLIC PCA**	**SLIC Spektral**
Sınıf 1	89,44	93,23	94,16	94,14	92,47
Sınıf 2	96,69	97,86	98,36	98,11	97,60
Sınıf 3	69,08	83,48	81,30	85,15	84,12
Sınıf 4	91,90	91,42	93,96	95,20	93,76
Sınıf 5	99,53	99,14	99,16	99,16	98,40
Sınıf 6	70,23	83,79	83,60	85,22	81,89
Sınıf 7	77,33	93,13	93,09	95,44	93,40
Sınıf 8	84,49	87,12	90,24	90,69	89,10
Sınıf 9	96,96	97,56	98,18	97,89	97,89
Ortalama	89,20	93,30	94,00	94,39	93,25
S.Sapma	0,0024	0,0063	0,0057	0,0066	0,0077

Tablo 5.10‘da Pavia University veri seti için %10 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.10. Pavia University %10 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	90,86	95,26	95,75	95,35	94,19
Sınıf 2	96,97	98,32	98,50	98,62	98,01
Sınıf 3	71,24	86,06	86,11	89,01	87,43
Sınıf 4	93,37	94,89	96,60	97,10	95,68
Sınıf 5	99,62	99,29	99,30	99,42	99,08
Sınıf 6	74,05	88,43	89,71	90,86	88,30
Sınıf 7	80,58	95,66	95,99	96,38	95,47
Sınıf 8	85,04	89,81	92,01	92,80	90,25
Sınıf 9	97,87	98,10	99,56	99,54	98,71
Ortalama	90,37	95,06	95,70	96,04	94,95
S.Sapma	0,0021	0,0043	0,0041	0,0030	0,0037

Tablo 5.11‘de Pavia University veri seti için %20 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

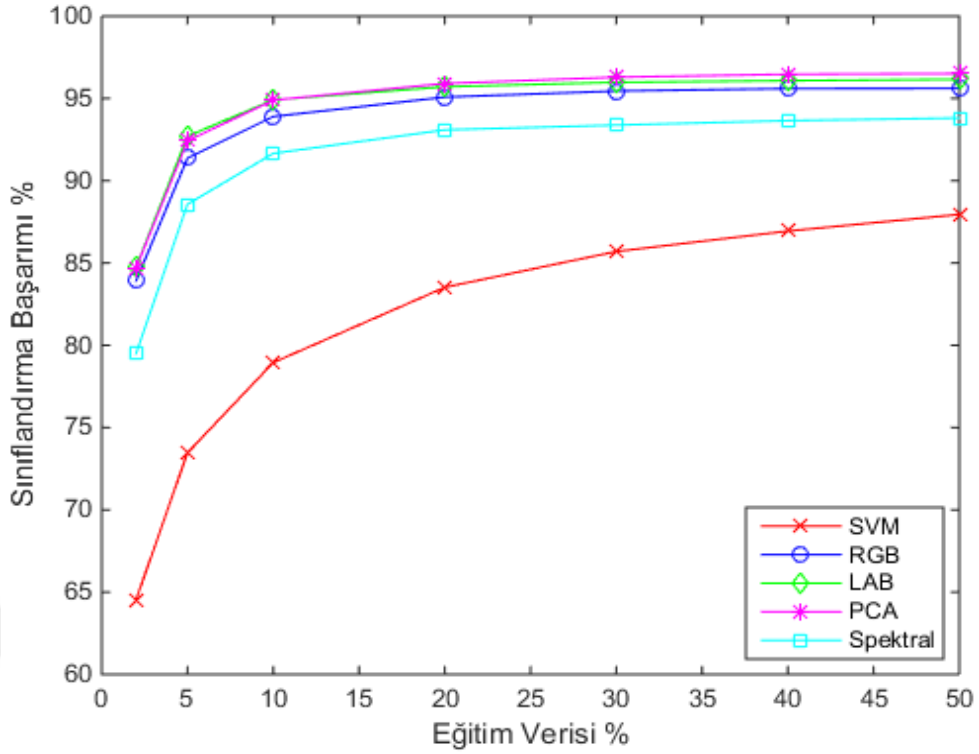
Tablo 5.11. Pavia University %20 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	91,63	96,48	97,00	96,75	95,86
Sınıf 2	96,69	98,83	98,97	99,11	98,49
Sınıf 3	71,77	88,21	88,26	91,19	89,39
Sınıf 4	95,02	96,29	97,77	98,18	96,86
Sınıf 5	99,91	99,53	99,62	99,69	99,21
Sınıf 6	80,54	91,40	92,30	93,76	91,431
Sınıf 7	82,5	96,90	97,00	97,05	96,27
Sınıf 8	85,47	91,69	94,14	94,38	91,87
Sınıf 9	98,28	98,95	99,89	99,84	99,62
Ortalama	91,18	96,25	96,83	97,18	96,14
S.Sapma	0,0016	0,0024	0,0020	0,0020	0,0039

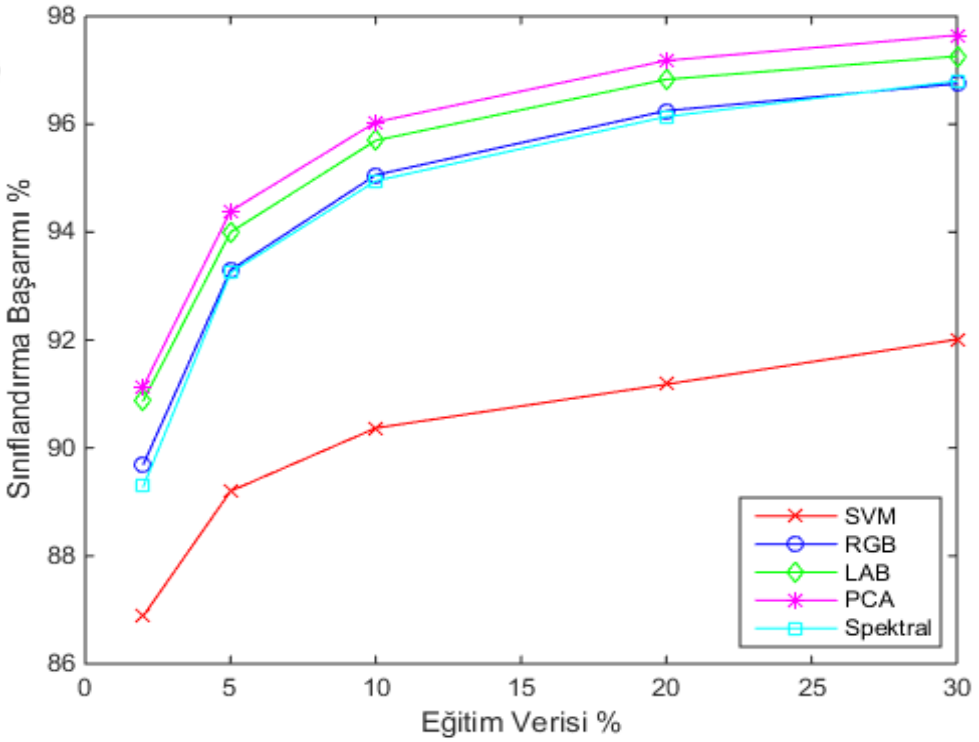
Tablo 5.12‘de Pavia University veri seti için %30 eğitim verisi kullanılarak direkt veri setinin SVM‘e uygulanması, RGB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, LAB uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma, PCA uzayında SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma ve Spektral uzayda SLIC süperpiksellerin elde edilmesi ile spektral sınıflandırma sonuçları gözlenmektedir.

Tablo 5.12. Pavia University %30 eğitim verisi için SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-SPEKTRAL metotları için sınıflandırma sonuçları

Sınıf	SVM	SLIC RGB	SLIC LAB	SLIC PCA	SLIC Spektral
Sınıf 1	92,50	97,08	97,52	97,44	96,53
Sınıf 2	97,11	98,91	99,11	99,31	98,66
Sınıf 3	73,81	89,54	89,26	92,06	91,01
Sınıf 4	94,86	97,01	98,12	98,46	97,79
Sınıf 5	99,81	99,57	99,71	99,75	99,40
Sınıf 6	81,47	93,35	93,63	95,14	93,46
Sınıf 7	84,20	97,75	97,31	97,35	96,41
Sınıf 8	85,94	92,11	94,67	94,90	92,75
Sınıf 9	98,81	99,11	99,97	99,96	99,94
Ortalama	92,01	96,75	97,26	97,65	96,80
S.Sapma	0,0017	0,0018	0,0017	0,0020	0,0017



Şekil 5.17. AVIRIS Indian Pines verisi için alt uzaylara ait başarımlar



Şekil 5.18. ROSIS Pavia University verisi için alt uzaylara ait başarımlar

Şekil 5.17'de AVIRIS Indian Pines verisi için ve 5.18'de ROSIS Pavia University verisi için alt uzaylara ait sınıflandırma başarımları paylaşılmıştır.

5.4.Deney Sonuçlarının Değerlendirilmesi

Bölüm 5.3'te yapılan deney sonuçlarına ait sınıflandırılma başarımları paylaşılmıştır. Yapılan deneyler Aviris Indian Pines ve Rosis Pavia University veri setleri kullanılarak farklı uzaylar için gerçekleştirilmiştir. SVM'de kullanılan parametreler için en iyi değeri elde etmek için 5 kat çapraz doğrulama kullanılmıştır. Ortalama değer ve standart sapma değerleri 50 koşum için hesaplanmıştır. SVM çekirdek parametresi olarak polinomal çekirdek kullanılmıştır. Ceza parametresi, C = {10 ^ (-1) ... 10 ^ (7)} aralığında ayarlanmıştır. Tablo 5.3, 5.4, 5.5, 5.6, 5.7'de paylaşılan sınıflandırma başarımları Aviris Indian Pines veri seti kullanılarak 50 koşum için %2, %5, %10, %20, %30 rastgele seçilen eğitim verileri ve geri kalan %98, %95, %90, %80, %70 test verileri için sınıf ortalama ve genel ortalama sınıflandırma başarımları elde edilmiştir. Tablo 5.8, 5.9, 5.10, 5.11, 5.12'de paylaşılan sınıflandırma başarımları Rosis Pavia University veri seti kullanılarak 50 koşum için %2, %5, %10, %20, %30 rastgele seçilen eğitim verileri ve geri kalan %98, %95, %90, %80, %70 test verileri için sınıf ortalama ve genel ortalama sınıflandırma başarımları elde edilmiştir.

Piksel temelli sınıflandırma (SVM) piksele ait komşuluk ilişkilerini göz ardı ederek sadece spektral bilgiyi içerir. Süperpiksel temelli spektral sınıflandırma piksel temelli sınıflandırmanın aksine hem uzamsal hem de spektral bilgiyi içerdiği için sınıflandırmanın daha yüksek doğrulukla yapılması sağlanmaktadır. Bölüm 5.3'te paylaşılan deney sonuçlarında da görüldüğü üzere SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-Spektral uzayları için süperpiksel temelli spektral sınıflandırma sonuçları bütün Tablolar için piksel temelli SVM den daha yüksek sınıflandırma başarımlarına sahiptir.

Yapılan çalışmada, süperpiksel temelli spektral sınıflandırmada süperpiksel algoritmasına girdi olarak kullanılan uzayların değişiminin sınıflandırma başarımlarına etkisi incelenmiştir. RGB, LAB, PCA ve Spektral uzaylar alt uzay olarak seçilmiştir. Minimum veri kaybıyla çok boyutlu veriden düşük boyuta geçmek için kullanılan bir öznitelik çıkartım yöntemi olan PCA uzayı için süperpiksel temelli spektral sınıflandırma sonuçları SLIC-RGB ve SLIC-Spektrala göre ön plana çıkmaktadır.

Kullanılan diğer bir alt uzay olarak LAB uzayı seçilmiştir. LAB uzayı insan gözüne en yakın renk sistemi olması, cihaz bağımsız olması, uniform yapıda olması gibi RGB renk uzayına göre pek çok avantaj içermektedir. Aynı zamanda hem parlaklık bilgisi hem renk bilgisi içerir. Dolayısıyla LAB renk uzayı için süperpiksel temelli spektral sınıflandırma sonuçları SLIC-RGB ve SLIC-Spektral uzaya göre ön plana çıktığı sınıflandırma sonuçlarından gözlemlenmiştir.

RGB renk uzayı alt uzay olarak kullanılmıştır. RGB uzayı elde edilirken spektrumun sadece görünür bölgesi kullanılmıştır. Diğer bilgilerin kullanılmaması veri kaybına neden olmaktadır. RGB uzayı cihaz bağımlı olması ve uniform olmayan yapısı nedeniyle SLIC-LAB ve SLIC-PCA için süperpiksel temelli spektral sınıflandırmanın başarım sonuçlarının gerisinde kaldığı sınıflandırma sonuçlarından gözlemlenmiştir.

Spektral uzayda direkt olarak veri seti SLIC süperpiksel algoritmasına girdi olarak işlenmiştir. Hiper küp çok sayıda bant içermesine karşın bazı bantlar gürültü içerir ve bazı bantlar da anlamlı bir bilgi içermez. Spektral uzay kullanılarak elde edilen süperpiksel tabanlı spektral sınıflandırma diğer uzayların gerisinde kalmaktadır.

Süperpiksel tabanlı spektral sınıflandırmanın sınıflandırma sonuçlarını iyileştirdiği Bölüm 5.3'te bulunan bütün tablolarda gözlemlenmiştir. Ortalama başarım değeri artar ancak bu artış bütün sınıflar için geçerli olmayabilir. Örneğin Tablo 5.4'te SLIC-Spektral uzay SLIC-uzayları içerisinde en düşük ortalama sınıflandırma başarımına sahipken ve LAB uzayı en yüksek ortalama sınıflandırma başarımına sahipken, sınıf bazında bakıldığında sınıf 9 sınıflandırma başarımının tam tersi bir durumda olduğu gözlemlenmiştir.

Süperpiksel temelli sınıflandırma hem spektral hem de uzamsal bilgiyi etkili bir şekilde kullandığı için sınıflandırma başarımı sadece spektral bilgiyi kullanan piksel temelli yaklaşıma göre sınıflandırma doğruluğu açısından daha iyi olduğu bilinmektedir. Deneysel sonuçlar dikkate alınarak yapılan karşılaştırmada süperpiksel temelli sınıflandırmada kullanılan uzaylar içerisinde SLIC-LAB ve SLIC-PCA uzayının ön plana çıktığı görülmektedir. Genel ortalama sınıflandırma başarısı dikkate alındığında LAB ve PCA alt uzayları birbirine oldukça yakın sonuçlar verdiği ve genel ortalama sınıflandırma başarımı açısından diğer uzaylara üstünlük sağladıkları görülmektedir.

6.SONUÇLAR VE ÖNERİLER

Bu tez kapsamında hiperspektral görüntülerin farklı uzaylarda SLIC süperpiksel algoritması kullanılarak spektral sınıflandırılması üzerinde çalışılmıştır. Bu çalışmada eğitimli sınıflandırma yöntemi olan SVM kullanılmış ve LIBSVM kütüphanesinden yararlanılmıştır. Süperpiksel algoritması olarak SLIC süperpiksel algoritması kullanılmıştır.

Hiperspektral görüntüleme ve uzaktan algılama kavramlarına genel hatlarıyla Bölüm 1'de incelenmiş, tez kapsamında çalışılan eğitimli sınıflandırma metodu olan SVM çalışma yapısına, LIBSVM kütüphanesine ve avantaj, dezavantajlarına Bölüm 2' de yer verilmiştir. Bölüm 3'te imge bölütleme yöntemi olarak süperpiksel, SLIC süperpiksel algoritması, hiperspektral imge analizinde süperpiksellerin kullanım amaçları genel hatlarıyla ele alınmıştır. Bölüm 4'te alt uzaylar olarak kullanılan renk uzayları, renk uzayları arasındaki geçişler ve boyut azaltım yöntemlerinden bir tanesi olan PCA uzayı genel olarak incelenmiştir. Bölüm 5'te yapılan çalışmada kullanılan veri setleri, yapılan çalışmanın aşamaları, elde edilen sonuçlar ve sonuçların değerlendirilmesi mevcuttur. Bu çalışmada farklı veri setleri kullanılarak direkt piksel temelli SVM, SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-Spektral uzayı süperpiksel temelli spektral sınıflandırılması ve sınıflandırma başarımlarının karşılaştırılması üzerine çalışılmıştır.

Farklı uzaylar kullanılarak iki farklı veri seti için süperpiksel tabanlı spektral sınıflandırma yapılmıştır. SVM sınıflandırma başarımları çıkartılmış ve deneysel sonuçlar paylaşılmıştır. SLIC-RGB, SLIC-LAB, SLIC-PCA, SLIC-Spektral uzayları için süperpiksel tabanlı spektral sınıflandırmanın direkt SVM sınıflandırmaya göre sınıflandırma başarımını arttırdığı görülmektedir. Yüksek sınıflandırma başarımı vermesi nedeniyle SLIC-LAB ve SLIC-PCA uzayları diğer uzaylara göre ön plana çıkmaktadır. SLIC-RGB ve SLIC-Spektral başarım sonuçları SLIC-LAB ve SLIC-PCA başarım sonuçlarına göre geride kalırken piksel temelli SVM sonuçlarına göre ise başarım oranın arttığı görülmektedir.

KAYNAKLAR

[1] http://oceanservice.noaa.gov/facts/remotesensing.html, (Ziyaret tarihi: 31 Ağustos 2016).

[2] Lim H. S., MatJafri M. Z., Abdullah K., Wong C. J., Air Pollution Determination Using Remote Sensing Technique, Editors: Jedlovec G., *Advances in Geoscience and Remote Sensing*, InTech, Rijeka, 71-92, 2010.

[3] Vincent R. K., *Fundamentals of Geological and Environmental Remote Sensing*, 1st Ed., Prentice Hall, New Jersey, 1997.

[4] Campbell J. B., Wynne R. H., *Introduction to Remote Sensing*, 5th. Ed., Guilford Press, New York, 2011.

[5] Suzuki S., Matsui T., Remote Sensing for Medical and Health Care Applications, Editors: Escalante B., *Remote Sensing-Applications*, InTech, Rijeka, 479-492, 2012.

[6] Steven M. D., Clark J. A., *Application of Remote Sensing in Agriculture*, 1st Ed., Butterworths, London, 1990.

[7] Karaca A. C., Stereo Hiperspektral Görüntüleme Sistemi ile Derinlik Çıkarımı, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 2014, 354561.

[8] https://en.wikipedia.org/wiki/Image_resolution, (Ziyaret tarihi: 31 Ağustos 2016).

[9] Jensen J. R., *Remote Sensing of the Environment: An Earth Resource Perspective*, 2nd Ed., Pearson Prentice Hall, Upper Saddle River, NJ, 2007.

[10] http://landsat.usgs.gov/band_designations_landsat_satellites.php, (Ziyaret tarihi: 20 Ekim 2016).

[11] http://www.seos-project.eu/modules/remotesensing/remotesensing-c03-p04.html, (Ziyaret tarihi: 01 Eylül 2016).

[12] Gerçek D., Çeşmeci D., Güllü M. K., Ertürk A., Ertürk S., Hiperspektral Görüntüleme ve Görüntü İşlemenin Bugünü, Yakın Geleceği ve Mevcut Araştırma Eğilimleri, *XYZ Dergi*, 2013, 18-25.

[13] Smith R. B., Introduction to hyperspectral imaging, Microimages, http://www.microimages.com/documentation/Tutorials/hyprspec.pdf, (Ziyaret tarihi: 05 Eylül 2016).

[14] Chang C.C., Lin C.J., LIBSVM: A Library for Support Vector Machines, *ACM Transactions on Intelligent Systems and Technology (TIST),* 2011, **2**(3), 27:1-27.

[15] Demir B., Ertürk S., Hiperspektral Görüntülerde Destek Vektör Makinaları ile Sınıflandırma Öncesi Dalgacık Uzayında Gürültü Giderimi, *15. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı,* Eskişehir, Türkiye, 11-13 Haziran 2007.

[16] Ayhan S., Erdoğmuş Ş., Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi, *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi,* 2014, **9**(1), 175 - 198.

[17] Nitze I., Schulthess U., Asche H., Comparison of Machine Learning Algorithms random Forest, Artificial Neural Network And Support Vector Machine to Maximum Likekihood for Supervised Crop Type Classification, *Proceedings of the 4th GEOBIA,* Rio de Janeiro, Brazil, 7-9 May 2012.

[18] http://www.nickgillian.com/wiki/pmwiki.php/GRT/SVM, (Ziyaret tarihi: 03 Eylül .2016).

[19] http://www.svms.org/software.html, (Ziyaret tarihi: 03 Eylül 2016).

[20] http://www.csie.ntu.edu.tw/~cjlin/libsvm/, (Ziyaret tarihi: 12 Ekim 2016).

[21] Shapiro L. G., Stockman G. C., *Computer Vision,* 1st Ed., Prentice-Hall, New Jersey, 279-325, 2001.

[22] Lauren B., Lee W. L., Perceptual information processing system, 2004, U.S. Patent Application 10/618, 543, *Paravue Inc.*

[23] https://en.wikipedia.org/wiki/Image_segmentation, (Ziyaret tarihi: 30 Eylül 2016)

[24] Çalışkan A., Koz A., Alatan A. A., Hyperspectral Superpixel Extraction Using Boundry Updates Based On Optimal Spectral Similarity Metric, *Geoscience and Remote Sensing Symposium (IGARSS 2015),* Milan, Italy, 26-31 July 2015

[25] Thompson D. R., Mandrake L., Gilmore M. S., Castano R. Superpixel endmember detection, *IEEE Transactions on Geoscience and Remote Sensing,* 2010, **48**(11), 4023-4033.

[26] Duan W., Li S., Fang L., Spectral-spatial hyperspectral image classification using superpixel and extreme learning machines, *Pattern Recognition,* 2014, **483,** 159-167.

[27] Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Süsstrunk S., SLIC Superpixels, *EPFL*, 149300, 1-15, 2010.

[28] http://www.vlfeat.org/api/slic.html, (Ziyaret tarihi: 30 Eylül 2016).

[29] https://en.wikipedia.org/wiki/Cluster analysis, (Ziyaret tarihi: 03 Ekim 2016).

[30] Jones N. C., Pevzner P. A., *Bioinformatics Algorithms*, 1st Ed., Bradford, London, 2004.

[31] Hardeberg J. Y., *Acquisition and Reproduction of Color Images: Colorimetric and Multispectral Approaches,* 2nd. Ed., Universal Publishers, Florida, 2001.

[32] Yılmaz İ., Güllü M., Baybura T., Erdoğan A., Renk Uzayları ve Renk Dönüşüm Programı (RDP), *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 2015, **2**(2), 19-35.

[33] Ford A., Roberts A., Colour space conversions, https://poynton.ca/PDFs/coloureq.pdf, (Ziyaret tarihi: 3 Eylül 2016).

[34] Hamilton E, JPEG File Interchange Format - Version 1.02., C-Cube Microsystems, https://www.w3.org/Graphics/JPEG/jfif3.pdf, (Ziyaret tarihi: 10 Eylül 2016).

[35] Bora D. J., Gupta A. K., Khan F. A., Comparing the performance of L*A*B* and HSV color spaces with respect to color image segmentation, *International Journal of Emerging Technology and Advanced Engineering,* 2015, **5**(2), 192-203.

[36] Başlar İ., Tüm Gökyüzü Kamerasından Alınan Görüntüler Kullanılarak Bulutluluk Ölçümü Yapılması, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu, http://www.tug.tubitak.gov.tr/dokumanlar/tez/bulutluluk_ib_tez.pdf, (Ziyaret tarihi: 14 Ekim 2016).

[37] Bajcsy P., Groves P., Methodology for Hyperspectral Band Selection, *Photogrammetric Engineering and Remote Sensing*, 2004, **70**(7), 793-802.

[38] Smith L. I., A tutorial on principal components analysis, *University of Otago,* OUCS-2002-12, 1-26, 2012.

[39] Koonsanit K., Jaruskulchai C., Eiumnoh A., Band selection for dimension reduction in hyperspectral image using integrated information gain and principal components analysis technique, *International Journal of Machine Learning and Computing,* 2012, **2**(3), 248-251.

[40] http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing Scenes, (Ziyaret tarihi: 15 Eylül 2016).

[41] Tadjudin S., Landgrebe D. A., Covariance estimation with limited training samples, *IEEE Transactions on Geoscience and Remote Sensing,* 1999, **37**(4), 2113-2118.

[42] Bigdeli B., Samadzadegan F., Reinartz P. A., Multiple SVM system for classification of hyperspectral remote sensing data, *Journal of the Indian Society of Remote Sensing,* 2013, **41**(4), 763-776.

[43] Fang L., Li S., Duan W., Ren J., Benediktsson J. A., Classification of hyperspectral images by exploiting spectral–spatial information of superpixel via multiple kernels, *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(12), 6663-6674.

[44] Chung H., Lu G., Tian Z., Wang D., Chen Z. G., Fei B., Superpixel-based spectral classification for the detection of head and neck cancer with hyperspectral imaging, *SPIE Medical Imaging 2016*, San Diego, United States, 27 February - 3 March 2016.

[45] Demir B., Celebi A., Erturk S., A low-complexity approach for the color display of hyperspectral remote-sensing images using one-bit-transform-based band selection, *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(1), 97-105.

[46] Du Q., Raksuntorn N., Cai S., Moorhead R. J., Color display for hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(6), 1858-1866.

[47] Cui M., Razdan A., Hu J., Wonka P., Interactive hyperspectral image visualization using convex optimization, *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(6), 1673-1684.

KİŞİSEL YAYINLAR VE ESERLER

[1] **Şakacı S. A.**, Ertürk S., Superpixel based spectral classification of hyperspectral images in different spaces, *5th International Conference on Electrical and Electronics Engineering (2018 ICEEE),* Istanbul, Turkey, 3-5 May 2018.

ÖZGEÇMİŞ

1988 yılında Çorum'da doğdu. İlköğretimini Aksaray Şehit Ali Er İlköğretim Okulunda, lise öğretimini Aksaray Hazım Kulak Anadolu Lisesinde tamamladı. 2010 yılında Kocaeli Üniversitesi Elektrik Mühendisliği, 2011 yılında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümünden mezun oldu. 2014 yılında Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Bölümünde yüksek lisansa başladı. 2018 yılında mezun olma durumundadır.