

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**SEYREKLİK TEMELLİ SINIFLANDIRMANIN HİPERSPEKTRAL
GÖRÜNTÜLERDE UYGULAMALARI**

YÜKSEK LİSANS TEZİ

Halil ÇAĞLAR

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

Haziran 2015

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**SEYREKLİK TEMELLİ SINIFLANDIRMANIN HİPERSPEKTRAL
GÖRÜNTÜLERDE UYGULAMALARI**

YÜKSEK LİSANS TEZİ

**Halil ÇAĞLAR
(504111349)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

Tez Danışmanı: Doç. Dr. Ender Mete Ekşioğlu

Haziran 2015

İTÜ, Fen Bilimleri Enstitüsü'nün 504111349 numaralı Yüksek Lisans Öğrencisi **Halil ÇAĞLAR** ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “**SEYREKLİK TEMELLİ SINIFLANDIRMANIN HİPERSPEKTRAL GÖRÜNTÜLERDE UYGULAMALARI**” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Ender Mete EKŞİOĞLU**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Ender Mete EKŞİOĞLU**
İstanbul Teknik Üniversitesi

Prof. Dr. Ahmet Hamdi KAYRAN
İstanbul Teknik Üniversitesi

Yrd. Doç. Dr. Ahmet Korhan TANÇ
Kırklareli Üniversitesi

Teslim Tarihi : **04 Mayıs 2015**
Savunma Tarihi : **08 Haziran 2015**

Aileme,

ÖNSÖZ

Sıkıştırılmış algılama ve seyreklik yaklaşımıyla tanışmamı sağlayan ve çalışmalarında bana yardımcı olup beni yönlendiren tez danışmanım Doç. Dr. Ender Mete Ekşioğlu'na değerli katkılarından dolayı teşekkürlerimi sunuyorum.

Ayrıca, çalışmalarım sırasında bilgisi ve tecrübesiyle her zaman yanımda olan eşim İlksen Çağlar'a yardımlarından dolayı teşekkürlerimi sunuyorum.

Mayıs 2015

Halil Çağlar
(Mühendis)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER	vii
KISALTMALAR	ix
ÇİZELGE LİSTESİ.....	xi
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xv
SUMMARY	xvii
1. GİRİŞ	1
2. HİPERSPEKTRAL GÖRÜNTÜLEME SİSTEMLERİ	3
2.1. Uzaktan Algılama.....	3
2.2. Uzaktan Algılanan Görüntüler	5
2.2.1. Pankromatik görüntüler.....	7
2.2.2. Multispektral görüntüler.....	8
2.2.3. Hiperspektral görüntüler	8
2.3. Hiperspektral Görüntü Veri Setleri	9
2.3.1. Indian pines veri seti	10
2.3.2. Salinas veri seti	11
2.3.3. Pavia ve pavia üniversitesi veri setleri	13
3. GÖRÜNTÜ SINIFLANDIRMA TEKNİKLERİ VE HİPERSPEKTRAL GÖRÜNTÜLERDE UYGULAMALARI	17
3.1. Giriş.....	17
3.2. Destek Vektör Makineleri Kullanarak Sınıflandırma	18
3.3. En Yakın K-Komşuluk Sınıflandırma.....	24
4. SEYREKLİK VE SEYREKLİK SINIFLANDIRMA	27
4.1. Sıkıştırılmış Algılama ve Seyreklik Yaklaşımı.....	27
4.2. Seyreklik Terimleri	29
4.2.1. Atom ve sözlük	29
4.2.2. Norm kavramı	30
4.3. Seyrekliğe Matematiksel Yaklaşım.....	30
4.3.1. Lasso yaklaşımı.....	33
4.3.2. OMP yaklaşımı	33
4.4. Seyreklik Tabanlı Sınıflandırma	34
4.5. Uzamsal Seyreklik Tabanlı Sınıflandırma	37
5. BENZETİM SONUÇLARI	43
5.1. Indian Pines Veri Seti Benzetimi	44
5.2. Salinas Veri Seti Benzetimi	49
5.3. Pavia Veri Seti Benzetimi	54
6. SONUÇ.....	65
KAYNAKLAR.....	67
ÖZGEÇMİŞ.....	69

KISALTMALAR

AVIRIS	: Airborne Visible/Infrared Imaging Spectrometer
BPDN	: Basis pursuit denoising
GIS	: Geographic Information Systems
Mbps	: Mega bits per second
OMP	: Orthogonal Matching Pursuit
SVM	: Support Vector Machines (Destek Vektör Makineleri)
SPAMS	: Sparse Modeling Software

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2-1: IKONOS uydusunun spektral bant bilgileri [9].	6
Çizelge 2-2: Worldview-2 uydusunun spektral bant bilgileri [9].	7
Çizelge 2-3: Indian Pines hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].	10
Çizelge 2-4: Salinas hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].	12
Çizelge 2-5: Pavia merkezi hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].	14
Çizelge 2-6: Pavia üniversitesi hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].	14
Çizelge 5-1: Indian Pines veri seti için ortalama başarımlar.	44
Çizelge 5-2: Sınıflandırma algoritmalarının Indian Pines veri seti için başarımlarının sınıflara göre dağılımı.	49
Çizelge 5-3: Salinas veri seti için ortalama başarımlar.	49
Çizelge 5-4: Salinas hiperspektral görüntüsünün algoritma sınıf başarımlar oranları... ..	54
Çizelge 5-5: Pavia veri seti için ortalama başarımlar.	54
Çizelge 5-6: Pavia hiperspektral görüntüsünün algoritma sınıf başarımlar oranları	59
Çizelge 5-7: Pavia üniversitesi veri seti için ortalama başarımlar.	59
Çizelge 5-8: Pavia üniversitesihiperspektral görüntüsünün algoritma sınıf başarımlar oranları	64
Çizelge 5-9: Sınıflandırma algoritmalarının veri setleri için çalışma süreleri.....	64

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2-1: Uzaktan algılama için aktif sensör [6].	4
Şekil 2-2: Uzaktan algılama için pasif sensör [6].	4
Şekil 2-3: Uzaktan algılamada ışığın yer ile etkileşimi [7].	5
Şekil 2-4: Elektromanyetik spektrum ve görünür ışık bölgesi [8].	6
Şekil 2-5: Pankromatik görüntü SPOT 2.5 metre, Toulouse, Fransa, 2002.	8
Şekil 2-6: Multispektral görüntü Multispektral IKONOS, Pekin, Çin.	8
Şekil 2-7: Hiperspektral görüntüleme sistemi.	9
Şekil 2-8: Örnek bir hiperspektral veri seti görüntüsü.	9
Şekil 2-9: Indian Pines pankromatik görüntüsü [11].	11
Şekil 2-10: Indian Pines doğruluk haritası [11].	11
Şekil 2-11: Salinas pankromatik görüntüsü [11].	13
Şekil 2-12: Salinas doğruluk haritası [11].	13
Şekil 2-13: Pavia merkez pankromatik görüntüsü [11].	15
Şekil 2-14: Pavia merkez doğruluk haritası [11].	15
Şekil 2-15: Pavia üniversitesi pankromatik görüntüsü [11].	16
Şekil 2-16: Pavia üniversitesi doğruluk haritası [11].	16
Şekil 3-1: Doğrusal iki sınıf sınıflandırma problemi ve olası hiper-düzlemler.	19
Şekil 3-2: Destek vektörleri ve marjin.	19
Şekil 3-3: Doğrusal sınıflandırıcı [13].	20
Şekil 3-4: Üç boyutta sınıflandırıcı düzleme dönüşmekte [13].	21
Şekil 3-5: Destek vektörleri, marjin ve doğrusal sınıflandırıcı.	21
Şekil 3-6: Doğrusal olarak birbirinden ayrılmayan veri kümeleri [13].	23
Şekil 3-7: Yüksek boyutta çıkartılan veri kümesi.	23
Şekil 3-8: En yakın komşuluk hesaplama ile ilgili bir gösterim.	25
Şekil 4-1: Varolan depolama alanı ile küresel üretilen veri eksabayt cinsinden [15].	27
Şekil 4-2: Sol tarafta analitik DCT aşırı tam sözlüğü, sağ tarafta eğitilmiş bir sözlük.	29
Şekil 4-3: Seyrek gösterim.	31
Şekil 4-4: Örnek bir aşırı tam sözlük.	32
Şekil 4-5: Komşuluğu alınan örnek bir piksel bağlamı [4].	40
Şekil 4-6: Uzamsal Seyreklik Sınıflandırma Tekniği [5].	41
Şekil 5-1: Matlab kullanıcı arayüz tasarımı.	44
Şekil 5-2: Destek vektör makineleri ile sınıflandırılmış Indian Pines hiperspektral görüntüsü.	45
Şekil 5-3: En yakın komşuluk algoritması ile sınıflandırılmış Indian Pines hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	46
Şekil 5-4: Seyreklik yaklaşımı ile sınıflandırılmış Indian Pines hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	47

Şekil 5-5: Uzamsal seyreklik yaklaşımı ile sınıflandırılmış Indian Pines hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	48
Şekil 5-6: Destek vektör makineleri ile sınıflandırılmış Salinas hiperspektral görüntüsü için kullanıcı arayüz çıktısı.	50
Şekil 5-7: En yakın komşuluk algoritması ile sınıflandırılmış Salinas hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	51
Şekil 5-8: Seyreklik yaklaşımı ile sınıflandırılmış Salinas hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	52
Şekil 5-9: Uzamsal Seyreklik yaklaşımı ile sınıflandırılmış Salinas hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	53
Şekil 5-10: Destek vektör makineleri ile sınıflandırılmış Pavia hiperspektral görüntüsü	55
Şekil 5-11: En yakın komşuluk algoritması ile sınıflandırılmış Pavia hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	56
Şekil 5-12: Seyreklik yaklaşımı ile sınıflandırılmış Pavia hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	57
Şekil 5-13: Uzamsal Seyreklik yaklaşımı ile sınıflandırılmış Pavia hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	58
Şekil 5-14: Destek vektör makineleri ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü	60
Şekil 5-15: En yakın komşuluk algoritması ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	61
Şekil 5-16: Seyreklik yaklaşımı ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	62
Şekil 5-17: Uzamsal Seyreklik yaklaşımı ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.	63

SEYREKLİK TEMELLİ SINIFLANDIRMANIN HİPERSPEKTRAL GÖRÜNTÜLERDE UYGULAMALARI

ÖZET

Teknolojinin gelişmesine paralel olarak sayısal algılamada kullanılan sensörler de gelişmektedir. Ölçülen ve üretilen verilerin kullanılabilmesi için aynı oranda iletim hızının ve saklama kapasitesinin artması beklenmektedir. Ancak sensör teknolojileri hızla ilerlerlerken aynı kapasitede bu iki teknoloji gelişmemektedir. Her yıl bir önceki yıldan yüzde 58 daha fazla veri üretilmektedir. Sıkıştırılmış algılama bu sorunu çözmek için geliştirilmiştir. Sıkıştırılmış algılama sinyalin elde edilmesinde ve geri çatılmasında kullanılan etkili bir sinyal işleme tekniğidir. Sıkıştırılmış algılama günümüzde önemli ve çok popüler bir sinyal işleme modeli olarak kullanılmaktadır.

Uzaktan algılamada yeryüzü yüzeyinden alınan görüntüler bant çözünürlüklerine göre sınıflandırılabilirler. Hiperspektral görüntüler yüzlerce dar banttandır ve çok yüksek miktarda spektral bilgi içerirler. Hiperspektral görüntülerde yer alan daha fazla spektral bilgi alındığı bölgenin daha iyi karakterizasyonu yansıtmaktadır. Arazi örtüsünün tanımlanmasında, ayırt edilmesinde ve sınıflandırmasında doğruluğu ve gübüzlüğü diğer görüntülere göre daha yüksektir. Sınıflandırma uzaktan algılanarak elde edilen görüntülerin yorumlanabilir haritalara çevrilmesini sağlayan geliştirme sürecidir. Ayrıca, sınıflandırma coğrafi bilgi biliminin görüntü işleme en önemli yönüdür.

Bu tez kapsamında hiperspektral görüntüler üzerine seyreklik tabanlı sınıflandırıcılar uygulanması üzerine çalışılmıştır. Hiperspektral görüntüler üzerinde seyreklik yaklaşımını kullanan iki farklı algoritma, destek vektör makineleri ve en yakın komşuluk algoritmaları koşturularak yüzey örtüleri sınıflandırılmıştır. Açık kaynak olarak sunulan dört farklı veri seti kullanılmıştır. Hiperspektral veri setleri içerisindeki her ayrı sınıftan yüzde 10 eğitim için seçilirken geriye kalan yüzde 90 veri seti ise test verisi olarak kullanılmıştır. Başarımlar, doğruluk haritalarına göre karşılaştırılarak; her sınıf için ayrı ayrı ve genel ortalamalarda hesaplanmıştır. Seyreklik yaklaşımını kullanan iki algoritma gerçekleştirilmiştir. Gerçeklenen algoritmalarından biri sadece seyreklik yaklaşımını kullanırken diğer algoritma seyreklik yaklaşımının yanında destek vektör makinelerini de (Support Vector Machines – SVM) kullanan hibrit bir tekniktir. Ayrıca, bu hibrit algoritmada spektral bilgiler yanında uzamsal bilgiler de kullanılarak sınıflandırma başarımları artırılmaya çalışılmıştır.

Klasik sayılabilecek destek vektör makineleri ve en yakın komşuluk yöntemlerinin başarımları ile seyreklik tabanlı sınıflandırıcıların başarımları karşılaştırılmıştır. Seyreklik tabanlı sınıflandırıcıların klasik yöntemlerden daha iyi sonuçlar verdiği gözlemlenmiştir. Seyreklik yaklaşımında uzamsal bilgilerin de kullanılmasıyla sınıflandırma başarımının daha da arttığı görülmektedir. Seyreklik tabanlı algoritmaların işlem karmaşıklığının yüksek oluşundan dolayı çalışma süreleri klasik algoritmalarından daha fazla olduğu gözlemlenmiştir.

SPARSITY BASED CLASSIFICATION APPLICATION OF HYPERSPECTRAL IMAGES

SUMMARY

In parallel to the development of technology, sensor technology used in digital detection is also advancing rapidly. In addition, similar to the development of sensor technology, there has been a constant increase in the detection frequency and data density. Huge amount of data, which has been acquired using these sensors must get transmitted and stored. Transmission and storage technology could not grow as fast as the development of sensors. These sensors produce data that is 58 percent more compared to the data from the previous year. That is a modern problem of technology. Compressed sensing can solve this problem.

Sampling theorem says that if the sampling rate of a signal is more than twice of the signal's highest frequency, then the signal can be recover perfectly. In compressed sensing, the signal can be recovered far fewer samples than required by the sampling theorem. Compressed sensing is an effective signal-processing tool for getting the signals and reconstruction of that signal. It is an important and popular signal processing module.

In remote sensing, images, which are collected from satellite, can be classified with respect to their spectral band resolution. These types are panchromatic, multispectral and hyperspectral images. Panchromatic images are composed only one narrow spectral band. Unlike Panchromatic images, Multispectral images are composed of tens of narrow spectral bands. Hyperspectral images are composed of hundreds of narrow spectral bands. Hyperspectral imaging systems look at objects using a huge portion of the electromagnetic spectrum. This system covers infrared, visible and ultraviolet area of the electromagnetic spectrum. Hyperspectral images contain huge amounts of information. Objects leave signature in the electromagnetic spectrum. This signature enables identification of the materials that make up a scanned object. Hyperspectral images reflect the characterization of the imaged area better than other imaging modalities. The rich spectral information in hyperspectral images allow them to be used in many field. These images can be used in identification and classification of land cover. The accuracy and robustness achieved using hyperspectral images is higher than other kind of image types.

Classification is the process, which translates and interprets a map from an image obtained using remote sensing. Land cover could be forested, urban, agricultural and other types of features. Additionally, the classification is one the most important applications of the geographical science.

There are two main image classification techniques. These techniques are supervised and unsupervised classification techniques. In supervised classification techniques, there is train data, which used to train the classifier and get the desired outputs whereas in unsupervised classification techniques no train datasets is provided. All data is clustered into different classes. Therefore, unsupervised classification techniques also known as clustering methods. In that thesis, implemented algorithms are supervised technique.

Four different sets of hyperspectral data sets are used. Data sets are Indian Pines, Salinas, Pavia and Pavia University, which are open source. All data sets are taken with using AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) sensors. AVIRIS is an optical sensor that takes spectral radiance in 224 contiguous spectral bands with wavelengths from 0.4 to 2.5 micrometers. The main objective of the AVIRIS project is to identify and monitor to the Earth's surface. These images are used to measure the performance of the implemented classification algorithms. Ten percent of hyperspectral image is randomly chosen for training data and remaining ninety percent of image is used for test data.

In this thesis, sparsity based classification methods have been applied to hyperspectral images. There are four algorithms, which are applied to hyperspectral images. Two of these methods are sparsity based while other methods are support vector machines and k-nearest neighbors algorithms.

There are two sparsity based algorithms implemented in this thesis. One of the implemented algorithms is based on only sparsity approach. First algorithm takes all the train data as an over-complete dictionary. Other algorithm, which named spatial-sparsity classification method, learns the over-complete dictionary from train data sets. In addition, this method uses a hybrid model that combine support vector machines with sparsity based approach. Additionally, this hybrid technique uses both spectral and spatial information. That approach tries to increase classification performance.

The accuracy and robustness of sparsity based classification methods are compared with support vector machine and k-nearest neighbors algorithms. The performance of sparsity based classification algorithms in hyperspectral images has been observed to be better than these classical algorithms. The sparsity based classification algorithms have high complexity but promising performance. This complexity causes to increase run time of the algorithm.

In chapter one, summary of the thesis and the literature review are included. In chapter two, basics of the remote sensing systems and hyperspectral imaginary systems are presented. Remote sensed images, which classified with respect to their spectral band resolution, are examined at this chapter. Additionally, data sets, which used at this thesis are represented. In chapter three, classification algorithms are presented. Supervised and unsupervised classification techniques briefly explained. Support vector machines and k-nearest neighbors classification algorithm are explained and mathematical description presented at this chapter. In chapter four, compressed sensing basics are presented. Sparsity basics and sparsity terms are explained. Two sparsity based algorithms are mathematically presented briefly. In chapter five, simulation results are given and accuracy of the implemented algorithms are presented. Additionally, graphical user interface, which is developed

by us, is explained. Ground truth map, classified map, error map and train data sets map can be seen on this user interface. In Addition, information about hyperspectral data set can be shown on labels. At last chapter, discussions of thesis results are given.

1. GİRİŞ

Bu tezin amacı, seyreklik yaklaşımı kullanarak, hiperspektral görüntü üzerindeki arazilerin birbirlerinden ayırt edilebilmesi için arazi örtülerine göre sınıflandırmanın gerçekleştirilmesidir. Yapılan bu çalışmada, makine öğrenme algoritmalarının en başarılılarından biri olan destek vektör makineleri algoritması ve en yaygın yöntemlerden biri olan En Yakın Komşuluk algoritması ile seyreklik tabanlı yaklaşımlar karşılaştırılmıştır. Seyreklik tabanlı yaklaşımlarda iki sınıflandırıcı algoritması kullanılmıştır. Bunlardan bir tanesinde sadece spektral bilgilerden yola çıkılarak hiperspektral görüntüler sınıflandırılmaya çalışılmaktadır. Diğer seyreklik yaklaşımlı sınıflandırmada ise uzamsal bilgilerde sınıflandırma algoritmasına sokulmaya çalışılmıştır. Yapılan bu çalışmada, seyreklik tabanlı sinyal işlemenin en başarılı sınıflandırma algoritmalarından biri sayılan destek vektör makinelerine göre dahi daha iyi sonuçlara ulaşabileceği gösterilmektedir.

Hiperspektral görüntüler yer gözlem uydularından ve buna benzer yer gözlem uçaklarından alınan yüzlerce art arda, dar, spektral bant içeren görüntülerdir. Bu görüntüler, yer arazisi hakkında detaylı bilgiler içermektedir. Bu bilgilerin, insan açısından faydalı olabilmesi için sınıflandırılmaları gerekmektedir. Görüntüde bulunan bu bilgilerin anlamlı olabilmesi için sınıflandırmak ve hangi bölgenin hangi araziye ait olduğunu tayin edebilmek için denetimli ve denetimsiz sınıflandırıcı algoritmalarından yararlanılmaktadır.

Literatürde, birçok başarıyı yüksek denetimli sınıflandırıcı vardır. Destek vektör Makineleri (SVM), sınıflandırma problemlerini çözmek için başarılı bir makine öğrenme algoritmasıdır. Bu algoritma istatistiksel öğrenme teorisine dayanmaktadır [1]. SVM tekniğinin temel mantığı en uygun şekilde sınıf ayırıcı düzlemi veri kümeleri arasında yerleştirmektir.

Seyrek örnekleme teorisine sıkıştırılmış algılama (Compressed Sensing), sıkıştırılmış örnekleme veya sıkıştırılan algılama denmektedir. Sıkıştırılmış algılama, sinyalin elde edilmesinde ve geri çatılmasında kullanılan etkili bir sinyal işleme tekniğidir.

Sıkıştırılmış algılama günümüzde önemli ve çok popüler bir sinyal işleme modülü olarak kullanılmaktadır. Seyrek gösterimli bir sinyal Shannon-Nyquist örnekleme teoreminden daha az örnek ile geri çatılabileceğiyle ilgili teorilerde 2006 yılında gelişmeler görülmektedir [2, 3].

Seyrek tabanlı sınıflandırmanın hiperspektral görüntüler üzerinde kullanılması Chen vd. [4] tarafından detaylıca ele alınmıştır. Bu çalışmada, sözlük öğrenilmeden kullanılmıştır, seyrek gösterim ile sınıflandırma yapılmaya çalışılmaktadır. Diğer bir yaklaşım olarak uzamsal bilgilerin kullanılabilmesi için Farani vd. tarafından uzamsal seyreklik tekniği önerilmiştir [5].


Bu tez kapsamında anlatılacak bölümlerden ikinci bölümde; uzaktan algılamaya genel giriş yapıp, sensörler hakkında bilgiler verilecektir. Bu sensörler aracılığıyla alınan farklı görüntülerin spektral çözünürlüklerine göre sınıflandırılması detaylı şekilde incelenecektir. Ayrıca bu çalışma kapsamında sınıflandırılmaya sokulacak veri setleri hakkında bilgiler yine ikinci bölümde verilecektir. Üçüncü bölümde ise sınıflandırma tekniklerine giriş yapılacaktır ve sınıflandırıcı farklılıklarına göre ayrılan denetimli ve denetimsiz sınıflandırıcılardan bahsedilecektir. Birer denetimli sınıflandırıcı örneği olan Destek Vektör Makineleri (Support Vector Machines-SVM) ve En Yakın Komşuluk algoritmaları bu bölümde ayrıntılı bir şekilde anlatılmıştır. Dördüncü bölümde; sıkıştırılmış algılama hakkında genel bilgiler verilmiştir. Seyrekliğin temelleri ve bu alanda kullanılan terimler bu bölümde anlatılmaktadır. Ayrıca bu bölümde seyreklik yaklaşımının hiperspektral görüntülere uygulamalarından iki adet algoritma incelenerek anlatılmıştır. Beşinci bölümde ise detaylı benzetim sonuçları sunulurken, hem doğruluk haritasına göre başarımlar hem de zaman olarak karşılaştırma tabloları verilmektedir. Altıncı bölümde ise tezin sonuçları tartışılmaktadır.

2. HİPERSPEKTRAL GÖRÜNTÜLEME SİSTEMLERİ


2.1. Uzaktan Algılama

Uzaktan algılama, fiziksel bir bağlantı kurmadan elektromanyetik radyasyonun dünya yüzeyinden yansıyan kısmını ölçme yöntemidir. Uzaktan algılama yöntemiyle tehlikeli ve ulaşılması zor alanlardan bilgi toplamak mümkün olmaktadır. Uzaktan algılamada kullanılan sensörler, yeryüzünden yansıyan enerjiyi algılayarak bilgi taşıyan veriyi toplarlar. Sensörler, elektromanyetik radyasyonu algılamada kullanılmaktadırlar. Bu sensörler uydulara veya uçaklara monte edilerek yeryüzünü algılamaktadırlar.

Uzaktan algılamada kullanılan sensörler pasif ya da aktif olarak iki ana gruba ayrılmaktadırlar. Pasif sensörler çevrede var olan enerjiyi algılamaya çalışmaktadırlar. Bu sensörlerin en büyük enerji kaynakları güneştir. Bunlar genellikle güneşten gelen radyasyonun, yeryüzü tarafından yansıtılan kısımlarını algılamaya çalışırlar. Bu nedenle, pasif sensörler, yalnızca gündüz saatlerinde veri toplamak için kullanılabilirler. Pasif görüntüleme sistemlerine bir örnek olarak kamera, termal tarayıcılar ve mikrodalga radyometreleri verilebilir. Buna karşılık, aktif sensörler, yeryüzünün hakkında veri toplamak için kendi enerjilerini kullanarak gözlem için aktif şekilde işaretler üretirler. Buna en bilinen örnek olarak flaşlı fotoğrafı gösterilebilir. Diğer örneklere ise radar (Radio Detection and Ranging) ve lidar (Light Detection and Ranging) verilebilir. Aktif sensörler, elektromanyetik radyasyon yayarak yeryüzü yüzeyinden yansıyan kısımlarını algılamaya çalışmaktadırlar. Örneğin, yeryüzüne aktif sensör tarafından bir lazer ışını gönderilir ve bu sensör yeryüzünden kendisine geri yansıyan işareti ölçerek yeryüzü hakkında uzaktan algılama bilgisi çıkarmaya çalışır.



Şekil 2-1:Uzaktan algılama için aktif sensör [6].



Şekil 2-2:Uzaktan algılama için pasif sensör [6].

Elektromanyetik enerji ile algılanacak ortam üç şekilde etkileşime geçer. Her madde, farklı şekillerde elektromanyetik enerjinin bir kısmını emer, bir kısmını yansıtır. Enerjinin emilmeyen veya yansıtılmayan kısmı maddenin içinden geçer. Bizim ilgi alanımız yansıyan kısımdan madde ile ilgili bilgi alabilmektir. Sensörler, yeryüzü üzerindeki maddelerin yansıttığı elektromanyetik radyasyonu ölçerler. Elektromanyetik radyasyonun yansıyan kısmı, elektromanyetik spektrumda o maddenin spektral imzası olarak bilinmektedir. Yeryüzü üzerindeki her mineral, bitki, toprak ve su benzersiz bir spektral yansıma imzası oluşturur. Bu ölçümlerim yardımıyla arazi örtülerinin, toprak ve su türlerinin ayırt edilmesi mümkün olmaktadır. Uzaktan algılanan görüntülerin geniş kullanım alanları vardır. Özellikle coğrafi bilimler ve sınır savunmasında uzaktan algılama görüntüleri sıklıkla kullanılmaktadırlar.




Şekil 2-3: Uzaktan algılamada ışığın yer ile etkileşimi [7].

2.2. Uzaktan Algılanan Görüntüler

Uzaktan algılamada, yeryüzü yüzeyinden alınan görüntüler bant çözünürlüklerine göre sınıflandırılabilirler. Her bant, farklı bir spektral bilgi içerir. Spektral bant, elektromanyetik spektrum üzerinde, ayırık bir aralık olarak tanımlanır. Örnek olarak dalga boyu 0.4 mikrometre ile 0.5 mikrometre arası bir bant olarak tanımlanabilir. Uzaktan algılanan görüntüler bant çözünürlüklerine göre Pankromatik, Multispektral ve Hiperspektral olmak üzere sınıflandırılabilirler. Şekil 2-4'de elektromanyetik spektrum görülmektedir. Görünür ışık bölgesinin dalga boyu 400nm ile 700nm arasında değişmektedir. Çeşitli renklerin spektrum bilgileri şöyledir;

- Kırmızı: 610-700 nm
- Turuncu: 590-610 nm
- Yeşil: 570-590 nm
- Mavi: 450-500 nm
- Mor: 400-430 nm



Şekil 2-4:Elektromanyetik spektrum ve görünür ışık bölgesi [8].

Yer gözlem uydularının en bilinenlerinden bir tanesi IKONOS uydusudur [9]. IKONOS pankromatik ve multispektral görüntüler alabilmektedir. DigitalGlobe firmasının ticari bir yer gözlem uydusu olan WorldView-2 uydusu 2009 yılında fırlatılmış olup, ilk yüksek çözünürlükte sekiz bant içeren multispektral görüntüler elde etmiştir [9]. Bu uydudan 46cm uzamsal çözünürlükte pankromatik görüntüler elde ederken, 1.85 metre uzamsal çözünürlükte multispektral görüntüler elde edebilmektedir. Bu iki uydunun spektral bilgileri aşağıdaki çizelgelerde (Çizelge 2.1-2.2) verilmiştir.

Çizelge 2-1: IKONOS uydusunun spektral bant bilgileri [9].

Bant	MerkezDalgaboyu (nm)	Alt Bant Kenarı Dalgaboyu (nm)	Yüksek Bant Kenarı Dalgaboyu (nm)
Pankromatik	729	409	1048
Mavi	480	421	539
Yeşil	552	480	624
Kırmızı	666	602	729
Yakın Kızılötesi	803	713	893

Çizelge 2-2:Worldview-2 uydusunun spektral bant bilgileri [9].

Bant	Merkez Dalgaboyu (nm)	Alt Bant Kenarı Dalgaboyu (nm)	Yüksek Bant Kenarı Dalgaboyu (nm)
Pankromatik	627	447	808
Kıyı Mavisi	427	396	458
Mavi	478	442	515
Yeşil	546	506	586
Sarı	608	584	632
Kırmızı	659	624	694
Yakın Kızılötesi-1	833	765	901
Yakın Kızılötesi-2	949	856	1043

2.2.1. Pankromatik görüntüler

Pankromatik görüntüler, genel olarak tek bant bilgi içerirler. Eğer pankromatik görüntülemeye kullanılan bant, görünür spektrumda ise insan gözü için anlamlı bilgi içerir. Renk bilgisini taşıyan spektral bantlar bu görüntüleme tekniğinde yoktur bu yüzden görüntüler sadece gri tonlama şeklindedirler. Pankromatik görüntü elde eden uydular yaklaşık olarak dalga boyu 400nm ile 1000nm arasında görüntü almaktadır. İnsan gözü 0.4mm ile 0.7mm arasındaki dalga boylarına duyarlıdır. Bu görüntülerde farklı nesneler gri tonlamaların farklılıklarından dolayı ayırt edilebilmektedirler. Ancak benzer renkteki nesnelerin ayırt edilmesi olabildiğince güçtür. Örnek vermek gerekirse; yeşil renkli farklı bitki örtüleri ayırt edilemez. Pankromatik görüntülerin spektral çözünürlüğü düşüktür. Diğer taraftan pankromatik görüntülerin uzamsal çözünürlüğü, daha fazla sayıda spektral bant içeren görüntülere göre genel olarak yüksektir.



Şekil 2-5: Pankromatik görüntü SPOT 2.5 metre, Toulouse, Fransa, 2002.

2.2.2. Multispektral görüntüler

Multispektral görüntülemelerde kullanılan sensörler çoklu bant algılayıcılıdır. Bu görüntüler birden fazla bant içerirler ve çok katmana sahiptirler. Her bir katman farklı dar dalga boyu bandı için elektromanyetik radyasyon bilgisi içerir. Genel olarak bu bantlar RGB ve kızılötesi spektrumlarından oluşmaktadır.




Şekil 2-6: Multispektral görüntü Multispektral IKONOS, Pekin, Çin.


2.2.3. Hiperspektral görüntüler

Hiperspektral görüntüler, yüzlerce dar banttan oluşurlar ve çok yüksek miktarda spektral bilgi içerirler. Hiperspektral görüntüleme sistemlerine, spektrometre görüntüleme de denmektedir. Bu görüntülerde yer alan daha fazla spektral bilgi, görüntünün alındığı yerin daha iyi karakterizasyonunu yansıtmaktadır. Bundan

dolayı bu görüntüler birçok alanda kullanılmaya imkân vermektedirler. Arazi örtüsünün tanımlanmasında, ayırt edilmesinde ve sınıflandırmasında hiperspektral görüntülerin doğruluğu, gürbüzlüğü ve başarımı diğer görüntü çeşitlerine göre daha yüksektir [4].



Şekil 2-7: Hiperspektral görüntüleme sistemi.



Şekil 2-8: Örnek bir hiperspektral veri seti görüntüsü.

2.3. Hiperspektral Görüntü Veri Setleri

Bu çalışmada kullanılan görüntüler; Indian Pines, Salinas, Pavia ve Pavia Üniversitesi bölgelerinden, hava gözlem uçakları üzerinde yer alan AVIRIS tipi

sensörlerle elde edilmiştir. AVIRIS (Airborne Visible/Infrared Imaging Spectrometer), havadan görünür ve kızılötesi spektrum görüntülemenin kısaltmasıdır. Bu görüntüleme sistemi 400 ile 2500 nanometre dalga boyları arasında 224 adet bitişik spektral bant görüntüsü, sunan bir optik sensördür. AVIRIS 4, uçak platformları üzerine yerleştirilerek, yer gözlemi gerçekleştirmektedir. AVIRIS, tüm Amerika, Kanada ve Avrupa üzerinde gözlemlerde bulunmaktadır (örneğin NASA-ER2, NASA-WB57 [6]).

2.3.1. Indian pines veri seti


Indian Pines hiperspektral görüntüsü, AVIRIS sensörüyle Amerika'nın bir eyaleti olan Indiana eyaletinin kuzey-batı bölgesindeki test alanından alınmıştır. Bitişik 224 adet spektrum bandından 145x145 pikselden oluşmaktadır. Bu hiperspektral görüntünün dalgaboyu aralığı 400 nanometre ile 2500 nanometre arasındadır. İlgili test alanının üçte ikisi tarım alanı, geriye kalan alanları ise orman ve doğal bitki örtüsünden oluşmaktadır. Şekil 2-8 ve 2-9'da Indian Pines veri kümesinin pankromatik görüntüsü ve sınıflarının gösterildiği doğruluk haritası görülmektedir. Doğruluk haritası on altı sınıftan oluşmaktadır ve her bir sınıf birbirinden tam olarak ayrılmamıştır. Doğruluk haritasındaki bu sınıflar ve örnek sayıları aşağıdaki Çizelge 2-3'de görülmektedir.

Çizelge 2-3: Indian Pines hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].

Sınıf Numarası	Sınıf Adı	Örnek Sayısı
1	Alfaalfa	54
2	Corn-notill	1434
3	Corn_mintill	234
4	Corn	237
5	Grass_pasture	497
6	Grass-trees	747
7	Grass_pasture_mowed	26
8	Hay-windrowed	489
9	Oats	20
10	Soybean-notill	968
11	Soybean-mintill	2468
12	Soybean-clean	614
13	Wheat	212
14	Woods	1294
15	Buildings_Grass_Trees_Drives	380
16	Stone-Steel-Towers	95



Şekil 2-9: Indian Pines pankromatik görüntüsü [11].



Şekil 2-10: Indian Pines doğruluk haritası [11].

2.3.2. Salinas veri seti


AVIRIS sensörleriyle alınan Salinas veri kümesi, 224 banttan oluşmaktadır. Amerikanın Kaliforniya eyaletinin Salinas vadisinden alınmıştır. Uzamsal çözünürlüğü 512x217 örneklemeden oluşmaktadır ve piksel başına 3,7 metredir. Bu hiperspektral görüntü bitki, boş toprak ve üzüm bağ tarlalarından oluşmaktadır. Salinas hiperspektral görüntüsü de Indian Pines veri kümesine benzer şekilde on altı

tane sınıf içermektedir. Çizelge 2-4’de Salinas hiperspektral görüntüsünün sınıf bilgileri verilmektedir.


Çizelge 2-4: Salinas hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].

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

Salinas hiperspektral görüntüsünün pankromatik bileşeni Şekil 2-10’da, doğruluk haritası Şekil 2-11’de görülmektedir.



Şekil 2-11: Salinas pankromatik görüntüsü [11].



Şekil 2-12: Salinas doğruluk haritası [11].

2.3.3. Pavia ve pavia üniversitesi veri setleri

En son veri kümesi, kuzey İtalya'nın Pavia arazisi üzerinden alınmış hiperspektral görüntülerdir. Pavia Merkezi'nden alınmış görüntü 102 banttan oluşmaktadır. Pavia üniversitesi üzerinden alınan görüntü ise 103 banttan oluşmaktadır. Pavia merkezi görüntüsünde uzamsal çözünürlük 1096x1096 piksel iken, Pavia üniversitesi

görüntüsünde uzamsal çözünürlük 610x610 piksel boyutlarındadır. Her iki görüntü de 9 sınıftan oluşmaktadır. Ayrıca, bu hiperspektral görüntülerin belirli bölgeleri bilgi taşımadığından çıkartılmıştır. Çizelge 2-5 ve 2-6'da Pavia merkezi ve Pavia üniversitesi görüntülerinin sınıf bilgileri verilmektedir.


Çizelge 2-5: Pavia merkezi hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].

Sınıf Numarası	Sınıf Adı	Örnek Sayısı
1	Water	824
2	Trees	820
3	Asphalt	816
4	Self_Blocking_Bricks	808
5	Bitumen	808
6	Tiles	1260
7	Shadows	476
8	Meadows	824
9	Bare Soil	820


Çizelge 2-6: Pavia üniversitesi hiperspektral görüntüsünün sınıf bilgileri ve örnek sayıları [4].

Sınıf Numarası	Sınıf Adı	Örnek Sayısı
1	Asphalt	6631
2	Meadows	18649
3	Gravel	2099
4	Trees	3064
5	Painted_metal_sheets	1345
6	Bare Soil	5029
7	Bitumen	1330
8	Self_Blocking_Bricks	3682
9	Shadows	947

Pavia merkezi hiperspektral görüntüsünün pankromatik bileşeni Şekil 2-12'de, doğruluk haritası ise Şekil 2-13'de görülmektedir.



Şekil 2-13: Pavia merkez pankromatik görüntüsü [11].




Şekil 2-14: Pavia merkez doğruluk haritası [11].

Pavia üniversitesi hiperspektral görüntüsünün pankromatik bileşeni Şekil 2-14’de verilirken, doğruluk haritası Şekil 2-15’de sunulmaktadır.



Şekil 2-15: Pavia üniversitesi pankromatik görüntüsü [11].



Şekil 2-16: Pavia üniversitesi doğruluk haritası [11].

3. GÖRÜNTÜ SINIFLANDIRMA TEKNİKLERİ VE HİPERSPEKTRAL GÖRÜNTÜLERDE UYGULAMALARI

3.1. Giriş

Sınıflandırma, uzaktan algılanarak elde edilen görüntülerin yorumlanabilir haritalara çevrilmesini sağlayan geliştirme sürecidir. Sınıflandırma, coğrafi bilgi biliminde sayısal görüntü işlemenin en önemli uygulamalarından biridir [10]. Geleneksel olarak sınıflandırma, elde edilen görüntülerin görsel olarak yorumlanması ve sınırlarının belirlenmesi olarak tanımlanabilir. Diğer taraftan, bilgisayar ve sayısal görüntülemenin gelişimiyle, sınıflandırma, bilgisayar destekli yorumlama kullanımına kaymıştır [10]. Buna karşın, insan gözü sınıflandırmada halen önemli bir konumda bulunmaktadır. Coğrafi bilgi bilimlerinde sınıflandırma, sayısal görüntülemenin getirmiş olduğu hız ve duyarlılık gibi avantajlarla daha da etkin hale gelebilmektedir. Sonuç olarak günümüzde; coğrafi bilgi bilimlerinde sınıflandırma, sayısal görüntülemenin yöntemlerinden faydalananarak, ancak en sonunda yine insanlar tarafından yorumlanarak gerçekleştirilmektedir.

Sınıflandırmada iki ana yaklaşım vardır: denetimli ve denetimsiz. Bu iki yaklaşımın arasındaki fark, sınıflandırmanın nasıl uygulandığıyla ilgilidir. Denetimli sınıflandırmada, sınıflandırıcının belirli bölgeler için sınırları gösteren eğitim örnekleri vardır. Bu örneklerden, sınıflandırıcı, sınıflandırılmak istenen bölgenin istatistiksel karakterizasyonunu çıkartabilmektedir. Denetimsiz sınıflandırmada ise, sınıflandırıcının elinde eğitim örnekleri yoktur. Denetimsiz sınıflandırmaya, kümeleme yaklaşımı da denmektedir.

Denetimsiz sınıflandırma, insana ihtiyaç duymadan sınıflandırma yapabilmektedir. Ancak denetimsiz sınıflandırıcılar genel olarak tek spektral bant üzerinde sınıf sayısını ve konumlarını tespit etmek için kullanılabilmektedirler. En popüler denetimsiz sınıflandırma algoritmalarından biri k-ortalama kümeleme algoritmasıdır [18].

Denetimli sınıflandırma, uzaktan algılanan görüntü verisinden nitel bilgiler elde etmek için kullanılan önemli bir araçtır. Denetimli sınıflandırmada, sınıflandırıcının belirli piksellerin sınıf bilgileri mevcuttur. Eğitim örnekleri her sınıf için ilgili sınıfa ait olan belirli piksellerden oluşur. Bu bilgiler genel olarak bir insan tarafından seçilerek ilgili sınıflara atanır. Eğitim örneklerinden sınıflandırıcı eğitilerek sınıfı belli olmayan pikseller sınıflandırılmaya çalışılmaktadır [12]. Denetimli sınıflandırma sınıflandırıcıları eğitim örneklerine ihtiyaç duymaktadırlar. Bu adım, sınıflandırıcının eğitilmesi adımıdır. Bundan sonra sınıflandırılmamış pikseller, sınıflandırıcıya sokularak hangi sınıfa ait olduğu kestirilmeye çalışılmaktadır.

Hiperspektral görüntüler, yüzlerce dar banttı oluştururlar. Uzaktan algılama görüntülerinin tanımlanmasında bu görüntülerin içerdığı zengin spektral bilgi kullanılacaktır. Yeryüzü üzerindeki her mineral, bitki, toprak ve su benzersiz bir spektral yansıma imzası oluşturur. Bu spektral imzaların ayırt edilmesinde makine öğrenmenin çok bilinen iki algoritması SVM ve en yakın komşuluk algoritmaları kullanılabilir. Bu algoritmalar Bölüm 3.2 ve Bölüm 3.3’de detaylıca anlatılmaktadır.


Bu çalışma kapsamında, hiperspektral görüntüler üzerinde denetimli sınıflandırıcılar kullanılarak başarımları karşılaştırılmıştır. Kullanılan sınıflandırma algoritmaları destek vektör makineleri (SVM) ve en yakın k komşuluk algoritmalarıdır. Bu algoritmalar ilerleyen bölümlerde detaylıca anlatılacak ve benzetim kısmında hiperspektral görüntülere uygulanacaktır.

3.2. Destek Vektör Makineleri Kullanarak Sınıflandırma

Destek vektör Makineleri (SVM), sınıflandırma problemlerini çözmek için en başarılı makine öğrenme algoritmalarından biridir [1]. SVM algoritması istatistiksel öğrenme teorisine dayanmaktadır. Birçok makine öğrenme algoritması, kestirim fonksiyonlarında kullandığı nitel bilgiyi (veri kümesini) azaltmaya çalışmaktadır. Bunun aksine, SVM tekniğinde mümkün olan her nitelik fazla önem içermese de kullanılmaya çalışılmaktadır. Bu teknikte nitel verilerden önemli olanı seçmek yerine bu verilerin nasıl birleştirileceğinin önemi vardır. Bu algoritma birçok sınıflandırma problemine başarılı bir şekilde uygulanmıştır. SVM Vapnik – Chervonenkis (VC) teorisine dayanmaktadır [1]. SVM sınıflandırma ilk olarak iki sınıflı problemleri çözmek için tasarlanmıştır. Daha sonra, çok sınıflı problemler üzerine uygulamak


için geliştirilmiştir. Bu çalışmada da benzer şekilde çok sınıflı problemi çözmek için kullanılmıştır. Problem, alt problemlere bölünerek, bir sınıfın diğer bütün sınıflardan ayırt edilmeye çalışılmaktadır.

SVM tekniğinin temel mantığı en uygun şekilde sınıf ayırıcı hiper-düzlemi veri kümeleri arasında yerleştirmektir. Şekil 3-1’de olası hiper-düzlemler gözükmemektedir. En iyi hiper-düzlem marjının maksimum olduğu noktadır



Şekil 3-1: Doğrusal iki sınıf sınıflandırma problemi ve olası hiper-düzlemler.


En uygun hiper-düzlem her iki sınıfın en yakın eğitim örneklerinden eşit uzaklıkta olan düzlemdir [1]. Eğitim örneklerinin hiper-düzleme en yakın olanlarına destek vektörleri denmektedir. Hiper-düzlem ile destek vektörleri arasında kalan uzaklığa marjın denmektedir. Böylece, en uygun hiper-düzlem, marjının maksimum olduğu yerdir denebilir. Şekil 3-2, marjının maksimum olduğu yani hiper-düzlemin en uygun olduğu yeri göstermektedir.



Şekil 3-2: Destek vektörleri ve marjın.

Destek vektör makineleri tekniği iki aşamadan oluşmaktadır. İlk aşamada, sınıflandırıcı eğitim verileri eğitilir. Eğitim verilerine uygun bir sınıflandırıcı

oluşturulur. Bundan sonra eğitilen sınıflandırıcı kullanılarak sınıflandırılmak istenen veriler teker teker sınıflarına ayrılır. Sınıflandırıcının eğitilmesine eğitim, eğitilen sınıflandırıcının kullanılarak sınıflandırılmamış verilerin sınıflandırılmasına da test aşaması denmektedir. Şekil 3-3’de doğrusal bir sınıflandırıcı görülmektedir. SVM’in matematiksel modeline geçecek olursak; n eğitim örnek sayımız ve $i = (1, 2, \dots, n)$ olmak üzere (x_i, y_i) şeklinde eğitim verimiz olsun. Burada $x_i \in R^d$ eğitim verileri ve $y_i \in \{-1, +1\}$ olmak üzere sınıf bilgilerini göstermektedir.



Şekil 3-3: Doğrusal sınıflandırıcı [13].

Bu verilerden $f(x)$ sınıflandırıcısı şu şekilde eğitilecektir;

$$f(x) = \begin{cases} \geq 0 & y_i = +1 \\ < 0 & y_i = -1 \end{cases} \quad (3.1)$$

Eğer sınıflandırıcımız doğrusal ise;

$$f(x) = \mathbf{w}^T + \mathbf{b} \quad (3.2)$$

şeklinde gösterilebilir. Buradaki b sapma sabiti, w ağırlık vektörüdür.

İki boyutta doğrusal sınıflandırıcı bir doğru iken 3 boyutta bir düzlemdir ve n boyutta ise sınıflandırıcı bir hiper-düzleme dönüşmektedir. Şekil 3-4’de bir hiper-düzlem örneği görülmektedir.

SVM sınıflandırıcısı öğrenme optimizasyon problemi olarak şu şekilde formüle edilir;

$$\max_w \frac{2}{||\mathbf{w}||}, y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 \text{ koşulu altında, } i = (1, 2, \dots, n) \quad (3.7)$$

Bu problem minimizasyon problemine çevrilerek şu şekilde yazılabilir;

$$\min_w \frac{1}{2} ||\mathbf{w}||^2, y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 \text{ koşulu altında, } i = (1, 2, \dots, n) \quad (3.8)$$

Bu bir kuadratik optimizasyon problemidir. Bu optimizasyon probleminin çözülmesiyle en iyi hiper-düzlem elde edilir [14]. En iyi hiper düzlemden kast edilen destek vektörlerin arasındaki uzaklığı maksimum yapan düzlemdir. Bu problemin çözümünde Lagrange çarpanlarından yararlanılarak optimum sonuca ulaşılmaya çalışmaktadır.

Lagrange denklemi;

$$L(\mathbf{w}, \mathbf{b}, \alpha) = \frac{1}{2} ||\mathbf{w}||^2 - \sum_{i=1}^n \alpha_i [y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b})] + \sum_{i=1}^n \alpha_i \quad (3.9)$$

Buradaki α_i değişkenleri Lagrange çarpanı olarak bilinmektedir. Bu problemin çözümünden elde edilen α_i değişkenleri yardımıyla w ağırlık vektörü ve b sabiti kolayca elde edilebilir. Aşağıdaki denklemle w ağırlık vektörü şu şekilde hesaplanır;

$$\mathbf{w} = \sum_{i=1}^n y_i \alpha_i \mathbf{x}_i \quad (3.10)$$

Lagrange denkleminde w yerine koyarsak aşağıdaki denklemi elde ederiz;

$$L(\mathbf{w}, \mathbf{b}, \alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j \mathbf{x}_i^T \mathbf{x}_j \quad (3.11)$$

w ağırlık vektörü bulunduktan sonra herhangi bir destek vektörü olan x_k ve bu destek vektörünün ait olduğu sınıf bilgisini içeren y_k alınarak b (sapma sabiti) sabiti aşağıdaki denklemden hesaplanır;


$$y_k(\mathbf{w}^T \mathbf{x}_k + \mathbf{b}) = 1 \quad (3.12)$$

Elde edilen sonuçlar yardımıyla sınıflandırıcı şu şekilde elde edilir;

$$f(x) = \text{sign} \left(\sum_{i=1}^n y_i x_i x_z + b \right) \quad (3.13)$$


Buradaki x_z sınıflandırılmak istenen veridir. Sınıflandırılmak istenen x_z verisi sınıflandırıcıya sokularak hangi sınıfa ait olduğu bulunur.

Buraya kadar anlatılan kısımda doğrusal olarak birbirinden ayrılabilen veri kümeleri üzerinde çalışan SVM sınıflandırıcısı anlatıldı. Ancak birbirinden doğrusal bir düzlemle ayrılamayan veri kümeleri vardır. Bu tür veri kümelerine bir örnek Şekil 3-6'da görülmektedir.



Şekil 3-6: Doğrusal olarak birbirinden ayrılmayan veri kümeleri [13].

Yukarıdaki şekilde gözüken veri kümelerini birbirinden ayıran bir hiper düzlem bulmak için verilerin bulunduğu düzlem derecesi artırılmalıdır. Böylece verileri doğrusal olarak birbirinden ayıran bir hiper düzlem bulunabilir. Şekil 3-7'de gözüktüğü gibi $\theta(x)$ düzlemine geçildiğinde, birbirinden doğrusal şekilde ayrılamayan veri kümesi, doğrusal bir düzlemle ayrılabilir.



Şekil 3-7: Yüksek boyutta çıkartılan veri kümesi.

SVM formüllerinde bu dönüşüm x_i noktasının farklı bir düzleme taşınarak θ_i olarak gösterimiyle formüle edilerek yazılabilir.


3.3. En Yakın K-Komşuluk Sınıflandırma

Hiperspektral görüntü sınıflandırma yapılırken, görüntü eğitim kümesinin her uzamsal pikseli bilinen bir sınıfa (uzaktan algılama görüntüsüne) aittir. Amacı, yeni ve bilinmeyen bir görüntü sahnesi hattının her bir uzamsal pikselinin sınıfını tespit etmektir. Benzer veriler aynı sınıfa ait olmalıdır şeklindeki düşünceye dayalı basit bir stratejidir. En yakın komşu algoritması, bu kadar kolay bir fikre dayanmaktadır ve sınıflandırma, eğitim görüntülerini içeren tüm önceden bilinen gözlem değerleri ile bilinmeyen yeni gözlem değeri karşılaştırarak yapılır. Benzerlik ölçümü Öklid uzaklığı ile hesaplanabilir.

Öklid Uzaklığı Bağıntısı;

$$D(s_1, s_2) = \sum_{i=1}^M (s_{1_i} - s_{2_i})^2 \quad (3.14)$$

Bu formülde s_1 , yeni bilinmeyen gözlem değeri, s_2 , eğitim gözlem değerlerinin her biri, M , eğitim gözlem değerlerinin (spektral bantların) sayısıdır. Sapma etkisini engellemek için yani yanlış sınıfa eşleştirilmiş eğitim gözlem değerlerinin etkisini engellemek için, tek bir tanesi yerine k komşusunu içeren bit metot çalıştırılır. Yeni gözlem değeri, en yakın eğitim gözlem değerinin sahip olduğu sınıfa doğrudan atanmaz. Öklid uzaklığı minimum olan ilk dört eğitim gözlem değerlerinin ait oldukları sınıflardan sayıca en fazla olan sınıf seçilir. Bilinmeyen yeni gözlem değeri bu sınıfa atanır. Bu yöntemle, sınıflandırma hata olasılığı en aza indirgenir [18]. Sınıflandırıcı, hesaba alınacak komşu sayısı K değerini parametre olarak alır. Şekil 3-8’de en yakın komşuluk sınıflandırmaya örnek bir şekil gösterilmektedir.




Şekil 3-8: En yakın komşuluk hesaplama ile ilgili bir gösterim.

4. SEYREKLİK VE SEYREKLİK SINIFLANDIRMA

4.1. Sıkıştırılmış Algılama ve Seyreklik Yaklaşımı

Sayısal algılama giderek gelişmektedir. Kullanılan sensör teknolojisiyle beraber aynı oranda alınan algılama sıklığı da artmaktadır. Algılama sıklığıyla beraber alınan veri yoğunluğu paralel şekilde artmaktadır. Veri çokluğunun artım oranına paralel olarak iletim hızının ve saklama kapasitelerinin de artması beklenmektedir. Ancak sensör teknolojileri hızla ilerlerlerken aynı kapasitede bu iki teknoloji gelişmemektedir. Alınan bu verilerin iletilmesi ve saklanması sorunlara yol açmaktadır. Sadece 2010 yılında 1250 milyar gigabayt veri üretilmiştir. Her yıl bir önceki yıldan yüzde 58 daha fazla veri üretilmektedir [15]. Bu verilerin saklanması başlı başına büyük bir problemdir. Sıkıştırılmış algılama bu sorunu çözmek için geliştirilmiştir. Şekil 4-1’de üretilen veri ile saklama kapasitesi grafiği gösterilmektedir [15].



Şekil 4-1: Var olan depolama alanı ile küresel üretilen veri eksabayt cinsinden [15].

Geçtiğimiz on yılda, sıkıştırılmış algılama ve seyrek modelleme yüksek boyutlu verilerin analiz edilmesinde kullanılmaya başlanmıştır. Seyrek sinyal işleme günümüzde çok popüler sinyal işleme tekniği olarak kullanılmaktadır. Son on yıl süresince, sinyal işlemenin seyreklik alanına ilgi giderek artmıştır. Bu ilgi sadece makine öğrenme topluluğu tarafından değil, diğer bilimsel çevreler tarafından da gösterilmektedir.

Sıkıştırılmış algılama, sinyalin elde edilmesinde ve geri çatılmasında kullanılan etkili bir sinyal işleme tekniğidir. Sıkıştırılmış algılama günümüzde önemli ve çok popüler bir sinyal işleme modülü olarak kullanılmaktadır. Seyrek gösterimli bir sinyal Shannon-Nyquist örnekleme teoreminden daha az örnek ile geri çatılabilir [16].

Sinyal işlemede genel amaç, belirli aralıklarla ölçülerek elde edilmiş verilerden sinyalin tekrar oluşturulmasıdır. Shannon-Nyquist örnekleme teoremine göre eğer bir sinyalin en yüksek frekansından en az iki kat fazla örnekleme alınırsa, sinyal mükemmel bir şekilde tekrar oluşturulabilmektedir [16]. Bir sinyalin seyrek veya sıkıştırılmış gösterimi ile sinyal, örnekleme teoreminde bahsedilen örnekleme frekansından daha az örnek ile tekrar oluşturulabilmektedir [17].

Gerçek hayatta kullanılan ve algılanan sinyallerin bazıları gerçekten seyrek, daha doğru bir deyişle sıkıştırılabilir sinyallerdir. Buna ek olarak, bu sinyaller seyrek sinyal modeline uygunlardır. Geleneksel istatistiksel çıkarımlar, küçük veri kümelerini göz önüne alırlar. Diğer taraftan, modern uygulamalarda karşılaşılan veri kümeleri, eğitim verilerinden oldukça fazla boyutlulardır. Yüksek boyutlu problemlerde klasik istatistiksel araçlar yetersiz kalmaktadır [17]. Bu yüzden, büyük veri kümelerini analiz edebilecek yeni bir istatistiksel tekniğe ihtiyaç duyulmaktaydı. Bu açık sıkıştırılmış algılama ile kapatılmıştır.

Seyrekliğe ilgi, yeni bir örnekleme teorisine olan ihtiyaçtan dolayı, örnekleme teorisine alternatif olarak artmıştır [17]. Bu yeni seyrek örnekleme teorisine sıkıştırılmış algılama, sıkıştırılmış örnekleme veya sıkıştırılan algılama denmektedir. Sıkıştırılmış algılamada öncelikli olarak sinyaller, seyrek kabul edilmektedir. Diğer taraftan, örnekleme teorisi frekansı bant genişliğine bağlı sinyaller üzerine kurulmuştur. Seyreklik ve örnekleme arasındaki bu bağlantının kurulmasıyla beraber sıkıştırılmış algılama teorisi birçok bilimsel alanda büyük etki yaratmıştır. Bu alanlara örnek vermek gerekirse; kodlama, bilgi teorisi, sinyal-görüntü işleme,


medikal görüntüleme ve jeofizik-astronomi veri analiz alanlarını sayabiliriz. Bugün, sıkıştırılmış algılama teorisi, dalgacık teorisinin yirmi yıl önce yaptığı gibi birçok alanı etkilemektedir [19].

4.2. Seyreklik Terimleri

Bu bölümde seyreklik yaklaşımında sıkça kullanılan terimler tanıtılacaktır ve matematiksel altyapı oluşturulacaktır. Anlatılacak terimler başlıca; atom, sözlük ve norm, alt başlıklarından oluşmaktadır.

4.2.1. Atom ve sözlük

Bir atom, şablonu temsil eden en küçük sinyal verisidir. Bu atomların topluluğundan daha büyük bloklar oluşmaktadır. Bu blokların doğrusal kombinasyonu ile karmaşık dalga biçimleri ortaya çıkartılabilir. Bu atomların bir araya gelmesiyle de sözlükler oluşmaktadır. Sözlük $N \times T$ matrisi şeklinde gösterildiğinde bu sözlüğün sütunları, sözlüğün atomlarıdır. Her bir sütun, bir atoma karşılık gelmektedir. Atomlar, vektörler şeklinde temsil edilmektedir. Eğer sözlüğün sahip olduğu sütun sayısı satır sayısından daha fazla ise, $T > N$, bu sözlük aşırı tam veya gereksiz bilgi içermektedir denir. Şekil 4-2’de sözlük örnekleri görülebilir.



Şekil 4-2: Sol tarafta analitik DCT aşırı tam sözlüğü, sağ tarafta eğitilmiş bir sözlük.

4.2.2. Norm kavramı

Norm kavramı, vektör uzayında gerçek değerli fonksiyon olarak tanımlanmaktadır. Bu fonksiyon aşağıdaki tanımlanan dört adet koşula uyar.

Koşul 1;

$$||x|| \geq 0 \quad \forall x \in \mathbb{R}^n \quad (4.1)$$

Koşul 2;

$$||x|| = 0 \text{ sadece ve sadece } x = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (4.2)$$

Koşul 3;

$$||\alpha x|| = |\alpha| ||x||, \quad \alpha \in \mathbb{C}, \text{ skalar büyüklük} \quad (4.3)$$

Koşul 4;

$$||x + y|| \leq ||x|| + ||y||, \quad \forall x, y \in \mathbb{R} \quad (4.4)$$

Bu koşullar altında l_p norm şu şekilde tanımlanabilir;

$$||x||_p = \begin{cases} \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} & p \in [1, \infty) \\ \max(|x_i|) \quad i = 1, 2, \dots, n & p = \infty \end{cases} \quad (4.5)$$

4.3. Seyrekliğe Matematiksel Yaklaşım


Sözlükteki her bir elemana atom denmektedir. Aşırı tam bir sözlük, atomlardan oluşmaktadır ve atom sayısı sinyal uzayından daha büyüktür. Böylece, herhangi bir sinyal, birden fazla atomun doğrusal kombinasyonu ile temsil edilebilmektedir. Seyrek gösterimle amaç, sinyali, aşırı tam bir sözlüğün atomlarının doğrusal kombinasyonu şeklinde ifade etmeye çalışırken olabildiğinde seyrek tutmaktır [19].

Seyrek yaklaşım problemi NP-zor (Np-hard) bir problemdir. NP-zor problemlerin tam olarak çözümüne ulaşmak, şu andaki hesaplama gücümüzle, yüzyıllar

sürmektedir. NP-zor problemlerine diğer örnekler olarak; çarpanlara ayırma, gezgin satıcı problemi ve Hamilton çemberi problemleri verilebilir [19].


Eşitlik 4.6'da; sözlük A ile ifade edilirken, x sinyalinin seyrek gösterimi α ve gürültü olarak ϵ gözükmemektedir. Bu denklemde a_i , A aşırı tam sözlüğü içerisindeki atomları göstermektedir.

$$x = A\alpha = \sum_{i=1}^n a_i d_i \quad (4.6)$$



Şekil 4-3: Seyrek gösterim.

Burada, x sinyalinin α seyrek gösterimi, belirli bir hata içerisinde bulunmaya çalışılmaktadır ve l_0 normu yerine l_1 ve l_2 normları kullanılıp problem rahatlatılarak yaklaşık çözümlere ulaşılmaya çalışılmaktadır. Şekil 4-4'de örnek bir aşırı tam sözlüğü görülmektedir.



Şekil 4-4: Örnek bir aşırı tam sözlük.

Eşitlik 4.7’te gösterilmiştir. Bu bir optimizasyon problemidir ve aşağıdaki şekilde formüle edilebilir;

$$\hat{\alpha} = \arg \min \|\alpha\|_0, A\alpha = x \text{ koşulu altında} \quad (4.7)$$

Bu denklem eşitsizlik olarak şu şekilde rahatlatılabilir;

$$\hat{\alpha} = \arg \min \|\alpha\|_0, \|A\alpha - x\|_2 < \sigma \text{ koşulu altında} \quad (4.8)$$

Eşitlik 4.7 ve 4.8’de görüldüğü gibi bu bir optimizasyon problemidir. Bu optimizasyon problemini çözmek için literatürde bir çok algoritma mevcuttur. Seyrek yaklaşım problemini çözen en popüler iki algoritma; lasso ve orthogonal matching pursuit(OMP) algoritmalarıdır [19]. Lasso tekniğinde seyrek yaklaşım algoritma problemini konveks bir probleme çevirerek çözmeye çalışmaktadır. Diğer taraftan, OMP algoritması ise açgözlü bir algoritma tekniğidir. Yineleme şeklinde çalışan OMP algoritması, her adımda en iyi yaklaşık sütun vektörünü seçerek çözüme ulaşmayı amaçlamaktadır.

4.3.1. Lasso yaklaşımı

Lasso algoritmasındaki [3] yaklaşım seyrek gösterim problemindeki l_0 normu yerine l_1 normunu kullanarak problemi rahatlatarak konveks (dışbükey) bir probleme dönüştürür.

Seyrek gösterim problemi (4.7), l_1 normu kullanılarak aşağıdaki probleme dönüştürülür;

$$\min \|\alpha\|_0, D\alpha = x \text{ koşulu altında.} \quad (4.9)$$

Lasso yaklaşımında bu problem l_1 normu üzerine bir kısıt uygulanarak da gösterilebilir.

$$\min \|D\alpha - x\|_2, \|\alpha\|_1 < \gamma \text{ koşulu altında.} \quad (4.10)$$

Yukardaki formülden anlaşılabileceği gibi Lasso tekniği bir yaklaşıklık bulmaya çalışır.

4.3.2. OMP yaklaşımı

OMP algoritması açgözlü bir algoritmadır. Yinelemeli şekilde çalışmaktadır ve bir yaklaşık çözüm bulmayı hedeflemektedir. Yinelenen her adımda yerel optimum çözüm hesaplanır. Bu algoritma D aşırı tam sözlüğü içerisindeki sütun vektörlerinden r artık vektörüne en çok benzeyeni seçerek çözüme yaklaştırmaya çalışır. Artık vektörün başlangıç değeri, yaklaşılmaya çalışılan x sinyaliyle eşitlenir, $r = x$. Her yinelenen adımda r vektörü güncellenerek, yerel optimum çözümlerin genel optimum çözüme götüreceği varsayımıyla devam eder.

Giriş parametreleri;

- x sinyali ve D aşırı tam sözlüğü
- Durdurma koşulu

Çıkış parametreleri;

- Yaklaşık seyrek çözüm α

Algoritma;

1. $r_0 = x$ sinyaline eşitle, zaman $t = 0$, indeks dizisi $V_0 = 0$,
2. $v_t = i$, ai D sözlüğü içerisindeki sütun vektörü olmak üzere $\max\langle r_t, a_k \rangle$,
3. i indeksinde ki vektör çıkartılarak indeks dizisi güncellenir,
4. Aşağıdaki en az kare problemi çözülür.

$$\min ||b - \sum_{j=1}^t \alpha(v_j) D_{v_j}||_2 \quad (4.11)$$

5. Yeni r vektörü hesaplanır.

$$r_t = r_{t-1} - \sum_{j=1}^t \alpha(v_j) a_{v_j} \quad (4.12)$$

6. Durdurma koşulu kontrol edilerek işlem durdurulur veya ikinci adıma geri dönülür.

4.4. Seyreklik Tabanlı Sınıflandırma

Seyreklik yaklaşımı, klasik sinyal işleme uygulamalarında kullanılan oldukça popüler ve kuvvetli bir araçtır. Doğada bulunan sinyaller, sözlükte bulunan atomları ifade eden ve sinyal hakkında en çok veri taşıyan birkaç katsayı şeklinde temsil edilebilirler [4]. Son zamanlarda, seyrek gösterimlerin uygulamaları, örüntü tanıma ve bilgisayarlı görme alanlarında, sıkıştırılmış algılama alanındaki gelişmelerden ötürü sıklıkla kullanılmaya başlanmıştır. Bu uygulamalar, genel olarak yüksek boyutlu verilerin gözlemine dayansa da aynı sınıfa ait olan sinyaller düşük boyutta alt uzaylarda var olurlar. Bu yüzden, benzer her örnek sinyal, seyrek gösterim ile uygun katsayıların doğrusal kombinasyonu şeklinde anlamsal olarak kodlanabilir. Sıkıştırılmış algılama teorisi ile tam olmayan seyrek gösterimli bir sinyal yüksek olasılıkla geri çatılabilir [4]. Bu bağlamda hiperspektral görüntülerin aynı sınıfa ait olan pikselleri, sözlük içerisindeki ilgili sınıfın eğitim verilerinin doğrusal kombinasyonu şeklinde yazılabilecektir. Aynı sınıftan olan veriler, yüksek boyutta olsalar bile düşük boyutta alt-uzayda yaşamaktadırlar. Bundan dolayı, hiperspektral görüntüler seyrek gösterime uygundur.

Aynı sınıfa ait olan piksel verilerinin spektral imzaları yaklaşık olarak aynı düşük boyutlu alt uzayda yatarlar [4]. M farklı sınıfımız olduğunu ve m . sınıfın N_m tane eğitim verisi olduğunu varsayalım olsun. Bu eğitim veri kümesi $\{a_j^m\}_{j=1,\dots,N_m}$ olarak gösterilebilir. x B – boyutlu hiperspektral piksel gözlem verisi olsun. Eğer x, m . sınıfa ait ise bu sinyalin spektral bilgisi yaklaşık olarak eğitim verilerinin $\{a_j^m\}_{j=1,\dots,N_m}$ düşük boyutlu alt uzayında yatar. x pikseli eğitim verilerinin doğrusal kombinasyonu olarak şu şekilde ifade edilebilir.

$$x \approx \alpha_1^m a_1^m + \alpha_2^m a_2^m + \dots + \alpha_{N_m}^m a_{N_m}^m \quad (4.13)$$

$$= \underbrace{[a_1^m \ a_2^m \ \dots \ a_{N_m}^m]}_{A^m} \underbrace{[\alpha_1^m \ \alpha_2^m \ \dots \ \alpha_{N_m}^m]^T}_{\alpha^m} \quad (4.14)$$

$$= A^m \alpha^m \quad (4.15)$$

Bu denklemlerdeki A_m matrisi $B \times N_m$ boyutludur ve m . sınıfın eğitim verilerinden oluşan alt sözlüktür. α_m vektörü N_m boyutludur ve A_m alt sözlüğü içerisindeki atomlara karşılık gelen ağırlık vektörlerini içerir. Seyrek gösterimde α_m seyrek vektör olarak kabul edilmektedir. Bir başka deyişle, içerdiği verilerin birkaç tanesi sıfırdan farklıdır.

Bilinmeyen bir test pikseli M sınıfın birleşiminden oluşan M alt uzay içerisinde modellenebilmektedir. Her sınıfa ait alt sözlüklerin birleşiminde $\{A^m\}_{m=1,\dots,M}$, x test örneği şu şekilde temsil edilebilir.

$$x = A^1 \alpha^1 + A^2 \alpha^2 + \dots + A^M \alpha^M \quad (4.16)$$

$$= \underbrace{[A^1 \ \dots \ A^M]}_A \underbrace{\begin{bmatrix} \alpha^1 \\ \vdots \\ \alpha^M \end{bmatrix}}_{\alpha} = A \alpha \quad (4.17)$$

Bu denklemlerde A matrisi $B \times N$ boyutlu sözlüktür ve bütün sınıflardan alınan eğitim örneklerini içerirler, $N = \sum_{m=1}^M N_m$. Ayrıca, α N boyutlu seyrek vektörüdür. Bu vektör $\{\alpha^m\}_{m=1,\dots,M}$ seyrek vektörlerinin art arda sıralanmasından oluşmaktadır. İdeal durumda eğer x sinyali m . sınıfa ait bir piksel ise $\alpha^j = 0, \forall j = 1, \dots, M, j \neq m$ şeklinde gösterilebilir. Test örneği olan x sinyalinin seyrek gösterimi, sözlüğün K

aktif atomlarının, a_{γ_k} , doğrusal kombinasyonu şeklinde gösterilebilir. Burada $a_{\gamma_k}, k = 1, \dots, K$ sıfır olmayan girdileri ifade etmektedir. Matematiksel ifadesi ise şu şekilde verilebilir;

$$x = \alpha_{\gamma_1} a_{\gamma_1} + \alpha_{\gamma_2} a_{\gamma_2} + \dots + \alpha_{\gamma_M} a_{\gamma_K}. \quad (4.18)$$

$$= \underbrace{\begin{bmatrix} a_{\gamma_1} & \dots & a_{\gamma_K} \end{bmatrix}}_{A_{\Lambda_K}} \underbrace{\begin{bmatrix} \alpha_{\gamma_1} \\ \vdots \\ \alpha_{\gamma_K} \end{bmatrix}}_{\alpha_{\Lambda_K}} = A_{\Lambda_K} \alpha_{\Lambda_K}. \quad (4.19)$$

Bu denklemlerde $K = ||\alpha||_0$, l_0 normunu ifade etmektedir. Bu ifade α seyrek vektörünün sıfır olmayan girdilerinin sayısını vermektedir. İndeks verilerini içeren $\Lambda_K = \{\gamma_1, \gamma_2, \dots, \gamma_K\}$ vektörüdür ve α seyrek vektörünü destekleyen A_{Λ_K} matrisidir. Bu matris $B \times K$ boyutlu olup K adet atom içermektedir, $\{\alpha_k\}_{k \in \Lambda_K}$. Burada ifade edilen, α_{Λ_K} , K boyutlu vektörü göstermektedir. Bu vektörün elemanları α vektörünün Λ_K indeksli girdilerinden oluşmaktadır.

Sınıflandırmak istediğimiz test verisinin seyrek gösterimi elde ettikten sonra seyrek gösterimden sinyali geri çatmaya çalışacağız. Eğitim verilerinden oluşan A sözlüğümüz ve α seyrek vektörüyle x sinyali şu şekilde $A\alpha = x$ geri çatılabilir. Bu geri çatım denklemini sağlayan α seyrek vektörünün hesaplanması, bir optimizasyon problemi olarak şu şekilde formüle edilebilir.

$$\hat{\alpha} = \arg \min ||\alpha||_0, A\alpha = x \text{ koşulu altında} \quad (4.20)$$

Bu denklem $A\alpha = x$ koşulunun yerine eşitsizlik kullanılarak şu şekilde yazılabilir;

$$\hat{\alpha} = \arg \min ||\alpha||_0, ||A\alpha - x||_2 < \sigma \text{ koşulu altında} \quad (4.21)$$

Burada σ hata toleransını göstermektedir. Yukarıda geçen problemde, yaklaşıklık hatası minimize edilirken kesin seyreklik derecesi koşulu da eklenirse problem aşağıda verilen biçime dönüşür.

$$\hat{\alpha} = \arg \min ||A\alpha - x||_2, ||\alpha||_0 \leq K_0 \text{ koşulu altında} \quad (4.22)$$

Bu denklemde K_0 sabit değeri, seyreklik derecesinin üst sınırını göstermektedir.

Bu problem, NP-zor problemidir ve önceki bölümlerde verilen yaklaşımlarla çözülebilir. Bu çalışmada, OMP tabanlı bir kütüphane kullanılarak bu problem çözdürülmüştür.

Test sinyali ile geri çatılan sinyal arasındaki hata m . sınıf için şu şekilde formüle edilir;

$$r^m(x) = ||x - A^m \hat{\alpha}^m||_2, m = 1, 2, \dots, M. \quad (4.23)$$

Burada $\hat{\alpha}^m$ vektörü geri çatılmış seyrek katsayılar vektörünün m . sınıfa ait olan kısmı olarak gösterilmiştir. Sınıflandırılmak istenen x sinyalinin sınıfı, bu hata vektörünün minimum olduğu sınıftır denilebilir. Bu söylem de şu şekilde formüle edilir;

$$Sınıf(x) = arg \min r^m(x), m = 1, \dots, M. \quad (4.24)$$

Bu çalışmada, alınan eğitim örneklerinde bu bölümde direkt olarak A aşırı tam sözlüğü oluşturulmuştur. Herhangi bir öğrenme algoritması kullanılmamıştır. Sınıfını bulmak istediğimiz test verimiz, A aşırı tam sözlüğünü içerisindeki a_i atomlarının doğrusal kombinasyonu şeklinde, OMP algoritması yardımıyla yazılmaya çalışılmıştır. Test edilen noktanın seyrek gösterim sonucu elde edilen α vektörü yardımıyla geri çatılır. Hangi sınıfa ait olduğu ise minimum hataya göre yukarıda verilmiş formülde görüldüğü şekilde hesaplanarak sınıflandırılır.

4.5. Uzamsal Seyreklik Tabanlı Sınıflandırma

Daha önceki bölümde anlatılan hiperspektral görüntüler için seyrek yaklaşımda sözlük, eğitim örneklerinden direkt olarak oluşturulmuştu. Bu bölümde ise bu sözlük belirli kısıtlar ile oluşturulacak ve başarıma katkısı kıyaslanacaktır. İlk olarak; sözlüğü oluşturacak verilerin uzamsal bilgileri daha önceki bölümde kullanılmamıştır. Eğitim verilerinin sadece spektral değerleri kullanılarak sözlüğün oluşturulması, bu verilerin birbiri ile komşuluklarını, bir başka deyişle, uzamsal bilgilerini kullanmamak bilgi kaybına yol açmaktadır [5].

Bu algoritmadaki ana fikir, hiperspektral görüntüyü piksel bölümlerine ayırmaktır. Buna ek olarak, bu bölümlerde uzamsal komşuluk ilkesi temel alınmaktadır. Oluşan her bir bölüme, bağlam (context) denilmektedir [5]. Belirli bir bağlam içerisinde bulunan pikseller, genel olarak aynı materyalden oluşmaktadır; yani aynı

sınıfa aittir denebilmektedir [5]. Bundan dolayı, bu piksellerin doğrusal kombinasyonlarını oluşturan bileşenler sözlükteki ortak atomlardır. Bağlam içerisindeki piksellerin benzer maddelerden oluştuğunu varsayarak belirli bir sözlüğe göre seyrek gösterimlerini ele aldığımızda, bu seyrek vektörler, sözlükten ortak atomları içereceklerdir. Diğer bir deyişle, bağlam içerisindeki pikseller aynı alt uzaya aittir ve bu piksellerin seyrek katsayılarının örüntüsü benzerdir [5]. Komşu olan hiperspektral görüntü içerisindeki pikseller benzer maddelerden oluştuğundan dolayı bunların spektral imzaları da benzerdir [4]. Bu bilgileri kullanarak sözlüğün spektral verilerden direkt olarak oluşturulması yerine uzamsal bilgiler de içeren bir şekilde oluşturulmasıyla daha başarılı bir sınıflandırıcı sözlüğe ulaşılabileceği düşünülmektedir [5].

İlk olarak sözlük öğrenme tekniğinden bahsedelim. Sözlük öğrenme tekniğinde her sinyal için hatayı düşürürken olabildiğince seyrek tutmaktır. İlgili sözlük öğrenmenin genel formülü şu şekildedir;

$$\arg \min_{D, y_i \in \mathbb{C}} \sum_{i=1}^N \frac{1}{2} \|x_i - Dy_i\|_2^2 + \gamma S(y_i) \quad (4.25)$$

Bu formülde, N sabit sayısı, eğitim uzayındaki sinyal sayısını göstermektedir. $S(y)$ ise seyreklik düzenleyicidir, en bilinenleri l_1 norm ve l_2 normdur. γ parametresi ise düzenleme parametresidir. Bu parametre ile seyrek gösterimdeki hatayı düzenler.

Sözlük öğrenme optimizasyon problemi için genel olarak iki adımlı yaklaşım uygulanmaktadır. İlk adımda seyrek kodlama yapılır ve ikinci adımda sözlük güncelleme adımıdır. Bu adımlar yinelemeli şekilde belirli kısıtlara yakınsayana kadar devam etmektedir.

- **Seyrek Kodlama Adımı:** Bu adımda, D sözlüğü sabit tutularak Y matrisine göre optimizasyon çözümü yapılmaya çalışılmaktadır. Seyrek kodlama formülü şu şekildedir;

$$\arg \min_{y_i} \frac{1}{2} \|x_i - Dy_i\|_2^2 + \gamma \|y_i\|_1 \quad (4.26)$$

Bu denklemde Lasso veya l_1 minimizasyonu kullanılmıştır. Bu problemi, rahatlatarak çözüme ulaşabilecek birçok algoritma mevcuttur. Bunların en bilinenleri Lasso, BPDN ve OMP algoritmaları sayılabilir.

- Sözlük Güncelleme Adımı: Bu adımda ise Y matrisi sabit tutulur ve sözlük güncellenmeye çalışılır. Böylece optimizasyon problemi şu hala gelmektedir;

$$\arg \min_D \frac{1}{2} \|X - DY\|_F^2, \forall_i \|d_i\|_2 \leq 1 \text{ koşulu altında} \quad (4.27)$$


Sözlük öğrenme 4.27 formülünde, seyrek gösterimler bağımsız olarak varsayılmıştır. Bu seyrek kodlama adımını basitleştirmiştir. Bu formüllemeler ile hiperspektral görüntülerin pikselleri arasındaki uzamsal korelasyonu göz ardı edilmektedir. Bu problemin üstesinden gelmek için, pikseller hangi bağlam grubuna ait olduğunu gösteren numaralar ile ilişkilendirilmiştir. Aynı bağlam grubuna ait olan pikseller genel olarak aynı maddeden yapılmışlardır. Bu ek olarak, bu piksellerin seyrek gösterimleri, sözlükteki aynı atom gruplarından oluşmaktadırlar. Bir diğer deyişle, sözlüğün aynı alt uzayındadırlar. Böylece aynı bağlama ait olan piksellerin seyrek gösterimleri bağımsız olmaktan çıkartılabilmektedir. Bağlam grupları $\{G_1, G_2, \dots, G_g\}$ şeklinde gösterilmektedir. $\{x_1, x_2, \dots, x_N\}$ ve $X_{G_i} = [x_i, 1, \dots, x_i, |G_i|]$ ise G_i vektörünün bileşenlerini göstermektedir. G_i vektörü X_{G_i} matrisinin sütunlarını oluşturmaktadır. Bu modele göre;

$$X_{G_i} = DY_{G_i} + E_{G_i} \quad (4.28)$$

Şeklinde yazılabilir. Bu formülde Y_{G_i} seyrek gösterimi temsil etmektedir ve E_{G_i} ise hata vektörüne karşılık gelmektedir.

D sözlüğünün $x_1, \dots, x_N$ spektral verilerinden direkt olarak öğrenilmesi yerine uzamsal bilgilerin de bu sözlükte yer alabilmesi için bağlam grupları belirlenerek bu bağlam gruplarından sözlük öğrenilmeye çalışılmaktadır. N tane eğitim verisinden oluşan $x_1, \dots, x_N$ spektral bilgilerinden $c_1, \dots, c_N$ bağlam verileri oluşturulmaktadır. Buradaki her bağlam grubu c_i, x_i pikselinin komşuluğunu oluşturan verilerin her bir spektral kanala olan momenti alınarak hesaplanır. Burada x_i , spektral verisinin etrafını saran veriler genel olarak aynı sınıftandır. Herhangi bir sınıfın birinci ve ikinci momentleri hiperspektral görüntülerin sınıflandırılması açısından bilgi

vericidir [5] Şekil 4-5’de gözüktüğü gibi x_i pikselinin etrafındaki veriler kullanılmaktadır.




Şekil 4-5: Komşuluğu alınan örnek bir piksel bağlamı [4].

Bağlam gruplarına göre sözlük öğrenme formülü şu şekilde oluşturulmaktadır;

$$\arg \min_{D, y_i \in C} \sum_{i=1}^N \frac{1}{2} \|c_i - Dy_i\|_2^2 + \gamma S(y_i) \quad (4.29)$$

Bu formülle elde edilen D sözlüğü ile SVM sınıflandırıcı eğitilecektir. Sınıflandırılmak istenen x test verisi geldiğinde, öncelikle bu test verisinin c bağlam grubu hesaplanacaktır ve D sözlüğü yardımıyla y seyrek gösterimi bulunacaktır. Sınıflandırılmak istenen x verisinin seyrek gösterimi olan y vektörünü eğitilmiş SVM sınıflandırıcıya sokulup sınıflandırılacaktır [5]. Şekil 4-6’da bu bölümde sunulan uzamsal seyreklik tabanlı sınıflandırma algoritmasının akış diyagramı verilmektedir.



Şekil 4-6: Uzamsal Seyreklik Sınıflandırma Tekniđi [5].

5. BENZETİM SONUÇLARI


Hiperspektral görüntüler, yüzlerce dar banttan alınan spektral veriden oluşmaktadırlar. Bu görüntülerin içerdiği kıymetli bilginin insan açısından faydalı olabilmesi için, görüntü üzerindeki farklı örüntülerin veya arazi örtülerinin sınıflandırılması zaruridir. Bu çalışma kapsamında, hiperspektral görüntüler üzerinde denetimli sınıflandırıcılar kullanılarak, farklı sınıflandırıcıların başarımları karşılaştırılmıştır. Kullanılan sınıflandırma algoritmaları destek vektör makinaları (SVM), Seyreklik yaklaşımı [4], Uzamsal seyreklik yaklaşımı [5], En yakın komşuluk yöntemi [18] olmak üzere dört algoritma kullanılmıştır. Bunlar AVIRIS sensörleriyle alınmış Pavia, Pavia üniversitesi, Salinas ve Indian Pines hiperspektral görüntüleri kullanılarak yeryüzü sınıflarına ayrılmaya çalışılmıştır. Başarımlar, doğruluk haritasına göre karşılaştırılarak; her sınıf için ayrı ayrı ve genel ortalamalarda hesaplanmıştır.

Bu çalışmada kullanılan veri setleri içinden rasgele yüzde 10'u eğitim seti olarak seçilmiştir. Her sınıftan yüzde 10 eğitim seti seçilirken geriye kalan yüzde 90 veri seti ise test verileri olarak kullanılmıştır. Bu test verileri sınıflandırılmak üzere eğitilen sınıflandırıcılara sokulmuştur. Başarımların daha doğru olarak karşılaştırılabilmesini sağlamak için eğitim ve test veri setlerinin her algoritma için aynı setlerden oluşması sağlanmıştır.

SVM sınıflandırıcı, libsvm-3.17 kütüphanesinden destek alınarak ve benzetimin çalıştırılacağı makine için derlenerek gerçekleştirilmiştir. Seyreklik yaklaşımında kullanılan algoritmalar için genel olarak SPAMS (Sparse Modeling Software) kütüphanesi kullanılmıştır. Benzer şekilde, ilgili kütüphane benzetim çalışacak makine üzerinde derlenerek benzetimde kullanılmıştır.

Matlab2012b ortamında tasarlanarak kullanıcı ara yüzü oluşturulmuştur. Şekil 5-1'de görüldüğü üzere bir ara yüz tasarlanmıştır. Farklı veri setleri için göz at butonu ile veri seti ve doğruluk haritası seçilebilmektedir. Veri setinin yüzde kaçının eğitim için kullanılacağı ve her çalışma için rastgele olup olmayacağı kullanıcı tarafından

arayüz ile belirlenebilmektedir. Ayrıca bu arayüz ile doğruluk haritası, sınıflandırılmış harita, eğitim veri haritası ve hata haritası görselleştirilmiştir.



Şekil 5-1: Matlab kullanıcı arayüz tasarımı.

5.1. Indian Pines Veri Seti Benzetimi


Indian Pines arazisinden alınan hiperspektral görüntünün dört adet sınıflandırıcıya sokularak alınmış sonuçları aşağıdadır.

Çizelge 5-1’de Indian Pines veri setinin her algoritma için ayrı ayrı başarımlar oranları verilmiştir.

Çizelge 5-1: Indian Pines veri seti için ortalama başarımlar.


Indian Pine Veri Seti	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
Ortalama Başarımlar	67.6%	61.5%	73.0%	91.8%

Şekil 5-2’de Indian Pines veri setinin destek vektör makineleri kullanılarak sınıflandırılmış arayüz çıktısı sunulmuştur.




Şekil 5-2: Destek vektör makineleri ile sınıflandırılmış Indian Pines hiperspektral görüntüsü.

Şekil 5-3’de Indian Pines veri setinin en yakın komşuluk algoritması kullanılarak sınıflandırılmış çıktıları verilmektedir.




Şekil 5-3: En yakın komşuluk algoritması ile sınıflandırılmış Indian Pines hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-4’de Indian Pines veri setinin seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları sunulmuştur.



Şekil 5-4: Seyreklik yaklaşımı ile sınıflandırılmış Indian Pines hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-5’de Indian Pines veri setinin uzamsal seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları verilmektedir.



Şekil 5-5: Uzamsal seyreklik yaklaşımı ile sınıflandırılmış Indian Pines hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Çizelge 5-2’de Indian Pines veri seti için her algoritmanın, sınıflara göre başarımları sunulmuştur.

Çizelge 5-2: Sınıflandırma algoritmalarının Indian Pines veri seti için başarımlarının sınıflara göre dağılımı.

Sınıf Numarası	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
1	14.6%	22 %	14.8%	70.7%
2	67.9%	53.4%	71.4%	95.9%
3	48.2%	48.5%	58.4%	95.3%
4	39.9%	38.9%	47.4%	97.2%
5	92.2%	82.3%	89.6%	99.8%
6	92.5%	90.7%	97.3%	96.2%
7	76.0%	73.2%	76.3%	96%
8	99.1%	99.1%	99.8%	98.1%
9	11.1%	16.7%	38.9%	83.3%
10	60.2%	64.9%	67.1%	93.5%
11	86.7%	72.3%	86.7%	97.4%
12	53.3%	37.7%	62.9%	96.2%
13	95.1%	90.2%	97.8%	98.4%
14	96.0%	88.8%	96.6%	99.7%
15	54.2%	41.5%	66.3%	97.9%
16	95.2%	92.8%	97.6%	97.6%

5.2. Salinas Veri Seti Benzetimi


Salinas arazisinden alınan hiperspektral görüntünün dört adet sınıflandırıcıya sokularak alınmış sonuçları aşağıdadır.

Çizelge 5-3’de Salinas veri setinin her algoritma için ayrı ayrı başarımlar verilmektedir.

Çizelge 5-3: Salinas veri seti için ortalama başarımlar.


Salinas Veri Seti	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
Ortalama Başarımlar	91.8%	89.1%	91.4%	97.7%

Şekil 5-6’da Salinas veri setinin destek vektör makineleri kullanılarak sınıflandırılmış arayüz çıktısı sunulmuştur.




Şekil 5-6: Destek vektör makineleri ile sınıflandırılmış Salinas hiperspektral görüntüsü için kullanıcı arayüz çıktısı.

Şekil 5-7’de Salinas veri setinin en yakın komşuluk algoritması kullanılarak sınıflandırılmış çıktıları verilmektedir.




Şekil 5-7: En yakın komşuluk algoritması ile sınıflandırılmış Salinas hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-8’de Salinas veri setinin seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları verilmektedir.



Şekil 5-8: Seyreklik yaklaşımı ile sınıflandırılmış Salinas hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-9'da Salinas veri setinin uzamsal seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları sunulmuştur.



Şekil 5-9: Uzamsal Seyreklik yaklaşımı ile sınıflandırılmış Salinas hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Çizelge 5-4’de Salinas veri seti için her algoritmanın, sınıflara göre başarımları sunulmuştur.

Çizelge 5-4: Salinas hiperspektral görüntüsünün algoritma sınıf başarımları

Sınıf Numarası	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
1	97.2%	98 %	100%	100%
2	99.0%	98.9 %	100%	99.9%
3	94.3%	99.2%	83.4%	99.9%
4	99.2%	99.3%	99.63%	97.6%
5	98.8%	98.1%	98.6%	99.5%
6	99.7%	99.4%	100%	100%
7	99.8%	99.5%	99.9%	100%
8	90.1%	76.3%	96.9%	99.4%
9	99.8%	99.3%	100%	100%
10	94.9%	92.4%	96.7%	99.8%
11	98.0%	94.4%	98.6%	100%
12	99.8%	99.8%	84.6%	100%
13	98.3%	98.1%	90.2%	99.3%
14	95.6%	93.8%	96.4%	100%
15	62.5%	64.5%	53.1%	99.2%
16	99.3%	99.1%	99.9%	100%

5.3. Pavia Veri Seti Benzetimi


Pavia arazisinden alınan ve belirli bir kısmı olan Pavia üniversitesi hiperspektral görüntülerinin dört adet sınıflandırıcıya sokularak alınmış sonuçları aşağıdadır.

Çizelge 5-5’de Pavia veri setinin her algoritma için ayrı ayrı başarımları verilmiştir.

Çizelge 5-5: Pavia veri seti için ortalama başarımlar.


Pavia Veri Seti	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
Ortalama Başarımlar	94.7%	92.0%	95.6 %	96.4%

Şekil 5-10’da Pavia veri setinin destek vektör makineleri kullanılarak sınıflandırılmış arayüz çıktısı sunulmuştur.



Şekil 5-10: Destek vektör makineleri ile sınıflandırılmış Pavia hiperspektral görüntüsü


Şekil 5-11’de Pavia veri setinin en yakın komşuluk algoritması kullanılarak sınıflandırılmış çıktıları verilmektedir.



9


Şekil 5-11: En yakın komşuluk algoritması ile sınıflandırılmış Pavia hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-12’de Pavia veri setinin seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları sunulmaktadır.



Şekil 5-12: Seyreklik yaklaşımı ile sınıflandırılmış Pavia hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-13’de Pavia veri setinin uzamsal seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları verilmektedir.



Şekil 5-13: Uzamsal Seyreklik yaklaşımı ile sınıflandırılmış Pavia hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Çizelge 5-6’da Pavia veri seti için her algoritmanın, sınıflara göre başarımları sunulmuştur.

Çizelge 5-6: Pavia hiperspektral görüntüsünün algoritma sınıf başarımlar oranları


Sınıf Numarası	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
1	99.9%	99.96%	99.98%	99.97%
2	96.0%	94 %	94.94%	93.7%
3	89.6%	87.9%	97.1%	98.1%
4	80.2%	81.3%	90.9%	92.2%
5	96.7%	95.6%	98.2%	99.2%
6	97.3%	95.7%	87.9%	89.9%
7	93.1 %	92.3%	96.7 %	94.5%
8	99.7%	99.3%	99.9%	99.9%
9	99.5%	99.9%	94.5%	96.4%

Çizelge 5-7’de Pavia üniversitesi veri setinin her algoritma için ayrı ayrı başarımlar oranları verilmiştir.

Çizelge 5-7: Pavia üniversitesi veri seti için ortalama başarımlar.


Pavia Üniversitesi Veri Seti	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
Ortalama Başarımlar	87.7%	81.1%	90.82%	95.7%

Şekil 5-14’de Pavia üniversitesi veri setinin destek vektör makineleri kullanılarak sınıflandırılmış arayüz çıktısı sunulmuştur.




Şekil 5-14: Destek vektör makineleri ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü

Şekil 5-15’de Pavia üniversitesi veri setinin en yakın komşuluk algoritması kullanılarak sınıflandırılmış çıktıları verilmektedir.




Şekil 5-15: En yakın komşuluk algoritması ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-16'da Pavia üniversitesi veri setinin seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları verilmektedir.



Şekil 5-16: Seyreklik yaklaşımı ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Şekil 5-17’de Pavia üniversitesi veri setinin uzamsal seyreklik yaklaşımı kullanılarak sınıflandırılmış çıktıları verilmektedir.



Şekil 5-17: Uzamsal Seyreklik yaklaşımı ile sınıflandırılmış Pavia üniversitesi hiperspektral görüntüsü: a) doğruluk haritası, b) sınıflandırılmış harita, c) eğitim haritası, d) hata haritası.

Çizelge 5-8’de Pavia üniversitesi veri seti için her algoritmanın, sınıflara göre başarımları sunulmuştur.

Çizelge 5-8: Pavia üniversitesi hiperspektral görüntüsünün algoritma sınıf başarımlar oranları

Sınıf Numarası	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
1	90.8%	86.8%	81.7%	99.3%
2	97.7%	93.6%	98.7%	99.9%
3	72.5%	67.3%	86.9%	96.5%
4	92.8%	83.6%	91.1%	96.4%
5	99.5%	99.1%	100%	100%
6	68.5%	64.4%	79.2%	99.9%
7	81.9%	80.1%	92.6%	98.7%
8	86.3%	82.3%	90.8%	92.2%
9	98.8%	82.4%	96.9%	96.3%

Çizelge 5-9’da sınıflandırma algoritmalarının her bir veri seti için çalışma süreleri verilmektedir.

Çizelge 5-9: Sınıflandırma algoritmalarının veri setleri için çalışma süreleri

Veri Setleri	SVM	KNN	Seyreklik Yaklaşımı	Uzamsal Seyreklik Yaklaşımı
Indian Pines	3.1 saniye	3.5 saniye	10.5 saniye	4.5 dakika
Salinas	47.9 saniye	2 dakika	56 dakika	41 dakika
Pavia	34.1 saniye	5 dakika	7 saat	10 saat
Pavia Üniversitesi	13.9 saniye	31.8 saniye	30 dakika	33 dakika

6. SONUÇ

Seyreklik yaklaşımı kullanarak, hiperspektral görüntü üzerindeki arazilerin, ayırt edilebilmesi için arazi örtülerine göre sınıflandırma gerçekleştirilmiştir. Yapılan bu çalışmada, makine öğrenme destek vektör makineleri algoritması ve en yaygın yöntem olan en yakın komşuluk algoritmaları temel başarımlar kriteri olarak alınarak ilgili hiperspektral görüntüler üzerinde koşturulmuştur. Seyreklik tabanlı yaklaşımlarda iki sınıflandırıcı algoritması kullanılmıştır. Bunlardan bir tanesinde sadece spektral bilgilerden yola çıkılarak hiperspektral görüntüler sınıflandırılmaya çalışılmaktadır. Diğer seyreklik yaklaşımlı sınıflandırmada ise uzamsal bilgilerde sınıflandırma algoritmasına sokulmaya çalışılmıştır. Bu iki algortmada hiperspektral görüntüler üzerinde koşturularak, destek vektör makineleri ve en yakın komşuluk algoritmasının başarımlarıyla kıyaslanmıştır.

En yakın komşuluk algoritması, her dört veri seti içinde en düşük başarımları vermiştir. En iyi ortalama başarımları ise uzamsal seyreklik algoritması vermiştir. Uzamsal seyreklik algoritması genelde 95% üzerinde başarımlar göstermiştir. Seyreklik algoritması genel olarak 90% seviyesinden yüksek başarımlar göstermiştir. En yakın komşuluk ve destek vektör makinesi algoritmaları sırasıyla yaklaşık %80 ve %90 ortalama başarımlar göstermişlerdir.

Seyrek tabanlı sınıflandırıcıların, destek vektör makinelerinden daha iyi sonuçlar verdiği gözlemlenmiştir. Ancak seyrek gösterim ile sınıflandırmada karşılaşılan güçlük algoritmanın işlem karmaşıklığının yüksek oluşudur. Bu karmaşıklık hesaplamaların yapılmasında harcanan zamanın yüksek olmasına yol açmaktadır. Destek vektör makineleri en hızlı çalışan algoritma iken uzamsal seyreklik algoritması en yavaş çalışan algoritma olarak gözlemlenmiştir. Seyreklik tabanlı sınıflandırıcıların hiperspektral verilerde kullanımının başarımlar artımına imkân verdiği gözlenmiştir. Seyreklik tabanlı bu tür yeni sınıflandırma yaklaşımlarının, sözlük öğrenme, analiz seyreklik gibi diğer seyreklik modelleriyle birleşiminin başarımdaki iyileşmeyi daha da arttıracakı düşünülmektedir.

KAYNAKLAR

- [1] **Kononenko, I., Kukar, M.** (2007). Machine Learning and Data Mining: Introduction to Principles and Algorithms, Horwood Publishing Limited.
- [2] **Candès, E. J., Romberg, J. K., Tao, T.** (2006). Stable signal recovery from incomplete and inaccurate measurements. Comm. Pure Appl. Math., 59: 1207–1223. doi: 10.1002/cpa.20124.
- [3] **Donoho, David L.** (2006). Compressed sensing Information Theory, IEEE Transactions on 52.4 : 1289-1306.
- [4] **Chen, Y., Nasrabadi, N., Tran, T.** (2011). Hyperspectral image classification using dictionary-based sparse representation, IEEE Trans. Geosci. remote Sens., Vol. 49, no. 10, pp. 3973-3985, Oct.
- [5] **Farani, A.A., Rabiee, H. R., Hosseini, S. A.** (2013). Spatial-Aware Dictionary Learning for Hyperspectral Image Classification, IEEE Trans. Geosci. remote Sens., Vol. X, No.Y.
- [6] <<http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/14639>>, alındığı tarih: 16.4.2015
- [7] **Eastman, J. R.** (2001). IDRISI32 Release 2, Guide to GIS and Image Processing, vol. 1, Worcester, MA: Clark University.
- [8] <http://tr.wikipedia.org/wiki/Elektromanyetik_tayf>, alındığı tarih: 16.4.2015
- [9] <https://www.digitalglobe.com/sites/default/files/DigitalGlobe_Spectral_Response_1.pdf>, alındığı tarih: 16.4.2015
- [10] **Eastman, J. R.** (2001). IDRISI32 Release 2, Guide to GIS and Image Processing, vol. 2, Worcester, MA: Clark University.
- [11] http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes, alındığı tarih: 11.4.2015
- [12] **Campbell, J. B., Wynne, R. H.** (2011). Introduction to Remote Sensing, Statistical Learning Theory, Guilford Press.

- [13] <<http://www.robots.ox.ac.uk/~az/lectures/ml/lect2.pdf>>, alındığı tarih: 16.4.2015
- [14] **Vapnik, V. N.** (1998). AT&T Research Laboratories, A Wiley-Interscience Publication, John Wiley & Sons, INC.
- [15] <http://www.economist.com/node/15557443>, alındığı tarih: 16.04.2015
- [16] **Huang, K., Aviyente, S.** (2006). Sparse Representation for Signal Classification, Neural Information Processing Systems
- [17] **Wellner, J., Zhang, T.** (2013). Introduction to the Special Issue on Sparsity and Regularization Methods., arXiv preprint arXiv:1301.0211.
- [18] **Garcia-Allende, P. B., Conde, O. M., Amado, M., Quintela, A., & Lopez-Higuera, J. M.** (2008). Hyperspectral data processing algorithm combining principal component analysis and K nearest neighbours. In SPIE Defense and Security Symposium (pp. 69660H-69660H). International Society for Optics and Photonics.
- [19] **Starck, Jean-Luc, Murtagh, F., Fadilli, J. M.** (2010) Sparse image and signal processing: wavelets, curvelets, morphological diversity. Cambridge University Press

ÖZGEÇMİŞ

Ad Soyad : Halil ÇAĞLAR
Doğum Yeri ve Tarihi : Eskişehir - 1986
E-Posta : halilcaglar26@hotmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2011, Eskişehir Osmangazi Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- Gömülü Yazılım Mühendisi, Tübitak-UEKAE, 2011-Halen