

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**SEZGİSEL YÖNTEMLERLE HİPERSPEKTRAL
GÖRÜNTÜLERDE BOYUT İNDİRGEME**

HÜSEYİN ÇUKUR

**YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
HABERLEŞME PROGRAMI**

**DANIŞMAN
PROF. DR. ABDULLAH BAL**

İSTANBUL, 2015

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SEZGİSEL YÖNTEMLERLE HİPERSPEKTRAL
GÖRÜNTÜLERDE BOYUT İNDİRGEME

Hüseyin ÇUKUR tarafından hazırlanan tez çalışması 30.11.2015 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Abdullah BAL
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Abdullah BAL
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Gökhan Bilgin
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Atilla ÖZMEN
Kadir Has Üniversitesi

Bu alıřma, 112E207 nolu “Hiperspektral Grntlerde Uzamsal ve Spektral znitelikler Kullanarak Yksek Hızda Hedef Tespiti ve Sınıflama Yapan Algoritmaların Geliřtirilmesi” isimli TBİTAK projesi kapsamında desteklenmiřtir.

ÖNSÖZ

Öncelikle, örüntü tanıma ve hiperspektral görüntüleme alanlarıyla tanışmamı sağlayan ve çalışmalarımın her aşamasında bana yardımcı olan, bilgi ve deneyimleriyle bana yol gösteren, maddi ve manevi olarak desteğini hiç esirgemeyen danışman hocam sayın Prof. Dr. Abdullah Bal’a değerli katkılarından dolayı şükranlarımı sunuyorum.

Aralarına katıldığım andan itibaren gösterdikleri sıcak ilgi ve sağladıkları uygun çalışma ortamı nedeniyle Yıldız Teknik Üniversitesi ve özellikle Elektronik ve Haberleşme Mühendisliği Bölümü ailesine de teşekkürlerimi sunuyorum.

Tezimde kullandığım verilere ulaşmamı sağlayan, teknik ekipmanlarını yardımımıza sunan YAZGILAB’daki arkadaşlarıma teşekkürlerimi sunarım.

Tezimdeki ilerlemelerde büyük katkısı olan, 112E207 nolu “Hiperspektral Görüntülerde Uzamsal ve Spektral Öznitelikler Kullanarak Yüksek Hızda Hedef Tespiti ve Sınıflama Yapan Algoritmaların Geliştirilmesi” isimli TÜBİTAK projesine ve bu projedeki ekip arkadaşlarıma teşekkürlerimi sunuyorum.

Son olarak, üzerimdeki emeklerini ve desteklerini hayatımın her anında hissettiğim değerli aileme teşekkür ederim.

Kasım, 2015

Hüseyin Çukur

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ.....	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	x
ÖZET.....	xii
ABSTRACT.....	xiv
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı.....	4
1.3 Hipotez.....	4
BÖLÜM 2	
HİPERSPEKTRAL GÖRÜNTÜLEME SİSTEMLERİ	5
2.1 Hiperpektral Görüntüler	5
2.1.1 Hiperpektral Görüntüleme Sistemi ve Spektral İmza	7
2.1.2 Hiperpektral Sensörler ve Kullanım Alanları	10
BÖLÜM 3	
METASEZGİSEL YÖNTEMLERLE BOYUT İNDİRGEME VE SINIFLANDIRMA YÖNTEMLERİ	15
3.1 Metasezgisel Yöntemler.....	15
3.1.1 Benzetilmiş Tavlama (BT)	18
3.1.2 Değişken Komşuluk Arama (DKA)	20
3.1.3 Genetik Algoritmalar (GA)	21
3.1.4 Diferansiyel Gelişim Algoritması (DGA)	25
3.2 Spektral Açık Haritalayıcı (SAH).....	26
3.3 Bant Gruplama Yaklaşımı.....	27
3.3.1 Karşılıklı Bilgi (kb)	27
3.3.2 Değişken Komşuluk Arama (DKA)	28
3.3.3 Genetik Algoritmalar (GA)	29

3.4 Destek Vektör Makinaları (DVM).....	30
BÖLÜM 4	
HİPERSPEKTRAL GÖRÜNTÜLERDE BOYUT İNDİRGEME	32
4.1 Sezgisel Algoritmalar ile Boyut İndirgeme	32
4.1.1 KSC Görüntülerinde Sezgisel Algoritmalar ile Boyut İndirgeme.....	32
4.1.1.1 DKA ile boyut indirgeme.....	34
4.1.1.2 BT ile boyut indirgeme	35
4.1.1.3 GA ile boyut indirgeme.....	35
4.1.1.4 DGA ile boyut indirgeme.....	35
4.1.1.5 KSC Görüntülerinde Sezgisel Algoritmalar ile Boyut İndirgemeye Dayalı Sınıflandırma	36
4.1.2 Çatalca02 Görüntüsünde Sezgisel Algoritmalar ile Boyut İndirgeme.....	39
4.2 Sezgisel Algoritmalar ile Bant Gruplama Tabanlı Boyut İndirgeme.....	43
4.2.1 KSC Görüntülerinde Sezgisel Algoritmalar ile Bant Gruplama Tabelanlı Boyut İndirgeme	47
4.2.2 Çatalca02 Görüntüsünde Sezgisel Algoritmalar ile Bant Gruplama Tabelanlı Boyut İndirgeme	50
4.3 Sezgisel Algoritmalar ile Spektral Kümelemeye Dayalı Bant Gruplama Tabelanlı Boyut İndirgeme	53
BÖLÜM 5	
SONUÇ VE ÖNERİLER.....	60
KAYNAKLAR	62
ÖZGEÇMİŞ	67

SİMGE LİSTESİ

CR	Çaprazlama oranı
D	Değişken sayısı
d	Uzaklık
F	Ölçekleme Oranı
G	Nesil
$H(X)$	Entropi
$H(X Y)$	Şartlı Entropi
I	Karşılıklı Bilgi Oranı
NP	Populasyon büyüklüğü
$p(x)$	Olasılık dağılım fonksiyonu
$p(x,y)$	Bağıl yoğunluk fonksiyonu

KISALTMA LİSTESİ

AVIRIS	Airborne Visible InfraRed Imaging Spectrometer
BT	Benzetilmiş Tavlama
ÇTBA	Çekirdek Temel Bileşen Analizi
DGA	Diferansiyel Gelişim Algoritması
DKA	Değişken Komşuluk Arama
DVM	Destek Vektör Makinaları
ESA	European Space Agency
GA	Genetik Algoritma
HSG	Hiperspektral Görüntü
HYDICE	Hyperspectral Digital Imagery Collection Experiment
IEEE	Institute of Electrical and Electronics Engineers
KB	Karşılıklı Bilgi
KSC	Kennedy Space Center
NASA	National Aeronautics and Space Administration
SAH	Spektral Açık Haritalayıcı
SK	Spektral Kümeleme
TBA	Temel Bileşen Analizi
YAZGI	Yapay Zeka ve Görüntü İşleme Laboratuvarı

ŞEKİL LİSTESİ

	Sayfa
Şekil 1. 1	Veri işleme adımları..... 2
Şekil 1. 2	DVM yöntemi ile boyut indirgeme..... 3
Şekil 2. 1	Işığın görülebilen dalga boyu aralığı 6
Şekil 2. 2	Mantis karidesinin göz yapısı 6
Şekil 2. 3	Hiperspektral küp ve spektral imzanın çıkarılışı 7
Şekil 2. 4	Hiperspektral görüntüleme düzeneği 8
Şekil 2. 5	HSG'nin elde edilişi, hiperspektral küp verisi ve spektral imza..... 8
Şekil 2. 6	Toprak, kuru bitki ve bitki için elde edilen spektral imzalar 9
Şekil 2. 7	Spektral imzalardaki bozulmalar 10
Şekil 2. 8	Hiperspektal kamera 11
Şekil 2. 9	Elma görüntülerindeki spektral imzalar a) Bozuk elma b) Taze elma..... 12
Şekil 2. 10	Kullanılan HSG' ye ait a) Renkli görüntü b) doğrulama görüntüsü 13
Şekil 2. 11	Kullanılan HSG ve ağaç çeşitlerinin ayrılması 13
Şekil 2. 12	Meksika körfezinde yaşanan petrol sızıntısı felaketi 14
Şekil 3. 1	Metasezgisellerin temel çalışma mekanizması 17
Şekil 3. 2	Metasezgisellerin arama çözüm sayısına dayalı sınıflandırılması 18
Şekil 3. 3	BT'de ısıtma işlem basamakları 19
Şekil 3. 4	GA Akış Şeması..... 22
Şekil 3. 5	GA'da tek noktadan çaprazlama örneği..... 24
Şekil 3. 6	GA'da mutasyon örneği 24
Şekil 4. 1	KSC verisine ait a) doğrulama verisi b) renkli görüntü ve sınıf isimleri..... 33
Şekil 4. 2	KSC verisinde 4 yönteme ait ortalama sınıflandırma başarımları üzerinden performans karşılaştırması 39
Şekil 4. 3	Çatalca02 verisine ait a) Renkli görüntü b) Doğrulama görüntüsü 40
Şekil 4. 4	Çatalca02 verisinde 4 yönteme ait ortalama sınıflandırma başarımları üzerinden performans karşılaştırması 43
Şekil 4. 5	a) KSC b) Çatalca02 verisinde bantlar arası Korelasyon..... 44
Şekil 4. 6	a) KSC b) Çatalca02 verisinde ardışık bantlar arası KB..... 45
Şekil 4. 7	KSC verisine ait imzalar ve gruplama sonucu 46
Şekil 4. 8	Çatalca02 verisine ait imzalar ve gruplama sonucu..... 47
Şekil 4. 9	KSC verisi üzerinde, DKA ve gruplama tabanlı DKA yöntemlerinin sınıflandırma başarımları üzerinden performans kıyaslaması..... 52
Şekil 4. 10	a) KSC verisinde b) Çatalca02 verisinde bantlar arası KB..... 53
Şekil 4. 11	KSC verisi üzerinde a) DKA b) Gruplama tabanlı DKA c) Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 5 banda ait doğrulama haritası..... 56

Şekil 4. 12 KSC verisi üzerinde a) DKA b) Gruplama tabanlı DKA c) Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 20 banda ait doğrulama haritası.....	57
Şekil 4. 13 KSC verisi üzerinde a) DKA b) Gruplama tabanlı DKA c) Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 60 banda ait doğrulama haritası.....	58

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2. 1	Başlıca HSG hava platform sensörleri 10
Çizelge 2. 2	Başlıca HSG uydu sensörleri 11
Çizelge 3. 1	BT Akış Şeması..... 19
Çizelge 3. 2	DKA Akış Şeması 21
Çizelge 3. 3	DGA Akış Şeması 25
Çizelge 3. 4	Spektral Kümeleme Akış Şeması..... 29
Çizelge 4. 1	KSC verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 10 bant 36
Çizelge 4. 2	KSC verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 20 bant 36
Çizelge 4. 3	KSC verisine ait sınıflar ve sınıflandırma aşamasında eğitim ve test aşamaları için kullanılan örnek miktarları..... 37
Çizelge 4. 4	KSC verisine ait sınıflarda boyut indirgeme sonrası sınıflandırma doğruluğu 38
Çizelge 4. 5	Çatalca02 verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 10 bant 40
Çizelge 4. 6	Çatalca02 verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 20 bant 41
Çizelge 4. 7	Çatalca02 verisine ait sınıflar ve sınıflandırma aşamasında eğitim ve test aşamaları için kullanılan örnek miktarları..... 41
Çizelge 4. 8	Çatalca02 verisine ait sınıflarda boyut indirgeme sonrası sınıflandırma doğruluğu 42
Çizelge 4. 9	KSC verisinde bant gruplama ve seçim olasılığı 46
Çizelge 4. 10	DKA Akış Şeması 46
Çizelge 4. 11	KSC verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 10 bant 47
Çizelge 4. 12	KSC verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 20 bant 48
Çizelge 4. 13	KSC verisine ait sınıflarda bant gruplama tabanlı boyut indirgeme sonrası sınıflandırma doğruluğu..... 49
Çizelge 4. 14	Çatalca02 verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 10 bant..... 50
Çizelge 4. 15	Çatalca02 verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 20 bant..... 50
Çizelge 4. 16	Çatalca02 verisine ait sınıflarda bant gruplama tabanlı boyut indirgeme sonrası sınıflandırma doğruluğu..... 51

Çizelge 4. 17	KSC verisi üzerinde, kullanılan yöntemlere ait işlem süreleri (sn) kıyaslaması	52
Çizelge 4. 18	Korelasyon ve KB işlemlerinin hesaplama süreleri (sn) kıyaslaması	52
Çizelge 4. 19	KSC verisinde SK ile elde edilen gruplar	54
Çizelge 4. 20	Çatalca02 verisinde SK ile elde edilen gruplar	54
Çizelge 4. 21	KSC verisi için bulunan çok sınıflı DVM doğruluk sonuçları.....	54
Çizelge 4. 22	Çatalca02 verisi için bulunan çok sınıflı DVM doğruluk sonuçları	55
Çizelge 4. 23	KSC verisi üzerinde farklı bant değerlerinde ki çok sınıflı DVM süreleri (sn) kıyaslaması.....	59

SEZGİSEL YÖNTEMLERLE HİPERSPEKTRAL GÖRÜNTÜLERDE BOYUT İNDİRGEME

Hüseyin Çukur

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Prof. Dr. Abdullah BAL

Sezgisel yöntemler, en iyiyi ya da en iyiye yakın çözümleri bulmak için arama uzayını hızlı bir şekilde araştırmayı esas alan yöntemlerdir. Bu yöntemler, arama içerisinde kullanılan komşuluğun sistematik olarak değiştirilmesini esas alırlar ve genellikle büyük boyutlardaki arama uzayının kısa sürede araştırılıp optimum sonuca ulaşılmasında kullanılırlar. Hiperspektral görüntüler gibi büyük miktarlarda bilgi içeren verilerin kısa sürede incelenip, gereksiz bilgilerin (bantların) ayrıştırılması hem zaman hem de hedef sınıflama/tanıma performansı açısından oldukça önemlidir. Bu çalışmada, hiperspektral görüntülere değişik sezgisel yöntemler (Değişken Komşuluk Arama, Benzetilmiş Tavlama, Genetik Algoritma, Diferansiyel Gelişim Algoritması) uygulanarak, bant seçimi yaklaşımıyla boyut indirgeme yapılmış ve veriyi en iyi temsil eden bantlar bulunmuştur. İkinci aşamada ise, değişik gruplama yöntemleri (Karşılıklı Bilgi, Korelasyon, Spektral Kümeleme) kullanarak bantlar arası benzerliğe dayalı gruplar oluşturulmuş ve boyut indirgeme adımı bu gruplar üzerinde gerçekleştirilmiştir. Son aşamada ise, boyut indirgeme sonucu bulunan en iyi bantlar sınıflandırma algoritması (Destek Vektör Makineleri) ile denenmiştir. Sunulan yöntemleri test etmek için çeşitli gerçek hiperspektral görüntüler (KSC, Çatalca02) kullanılmıştır. Test sonuçları sunulan yöntemlerin hiperspektral görüntülerde başarı ile kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Benzetilmiş Tavlama, Boyut İndirgeme, Değişken Komşuluk Arama, Destek Vektör Makinaları, Diferansiyel Gelişim Algoritması, Genetik

Algoritmalar, Hiperspektral Görüntüleme, Karşılıklı Bilgi, Korelasyon, Metasezgisel Yöntemler, Sezgisel Yöntemler , Spektral Açık Haritalayıcı, Spektral Kümeleme.

ABSTRACT

DIMENSION REDUCTION WITH HEURISTIC METHODS IN HYPERSPECTRAL IMAGES

Hüseyin ÇUKUR

Department of Electronics and Communications Engineering
M.Sc. Thesis

Adviser: Prof. Dr. Abdullah BAL

Heuristic Methods are based on searching the solution space quickly to get optimal or approximately optimal solution. These methods are relied on the systematically neighborhood change in search area and generally used to achieve the optimal solution in a short time in high dimensional search space. Examining the data including large scale of information such as hyperspectral images and eliminating redundant features (bands) is quite important for computation time and target classification/detection performance. In this study, band selection as a dimension reduction procedure is employed to hyperspectral images using several heuristic methods (Differential Evolution Algorithm, Genetic Algorithm, Simulated Annealing and Variable Neighborhood Search) and then useful bands are selected. In the next stage, as a preprocessing step of band selection, different grouping methods (Mutual Information, Correlation Coefficient and Spectral Clustering) are utilized for forming groups based on similarity between bands. Final stage, superlative bands which are found after band selection are tested with a classification algorithm (Support Vector Machine). To test the proposed methods real hyperspectral images (KSC and Çatalca0202) are used. Test results indicate that presented methods can be applied in hyperspectral imagery successfully.

Keywords: Correlation Coefficient, Differential Evolution Algorithm, Dimension Reduction, Genetic Algorithm, Heuristic Methods, Hyperspectral Imagery, Mutual

Information, Simulated Annealing, Spectral Angle Mapper, Spectral Clustering, Support Vector Machine, Variable Neighborhood Search.

GİRİŞ


1.1 Literatür Özeti

Optimizasyon, bir sistemde varolan işgücü, zaman, kapital, süreçler, hammaddeler, kapasite, ekipman gibi kaynakların en verimli şekilde kullanılarak maliyet enazaltılması, kâr ençoklanması, kapasite kullanımının enyükseltilmesi ve verimliliğin ençoklanması gibi amaçlara ulaşılmasını sağlayan bir teknoloji olarak literatüre girmiştir [1]. Optimizasyon ile karar verme süreçleri hızlandırılmakta, karar kalitesi arttırılmakta ve gerçek hayatta karşılaşılan problemlerin etkin, doğru ve gerçek zamanlı çözümüne katkı sağlanmaktadır.

Yapılmış veya yapılmakta olan işin en iyi çözümünü ortaya koymak için kullanılan optimizasyon teknikleri kullanılarak ortaya konulmuş olan çözüm, optimum çözüm olarak adlandırılır. Hedef her zaman için bu optimum çözümü yakalayabilmektir. Yapılacak olan bir inşaattan oluşturulmaya çalışılan bir web sitesine kadar her alanda bu tekniklere gereksinim duyulur. İmge sınıflandırma ve imge tanıma problemleri de, optimizasyon tekniklerine ihtiyaç duyan alanlardandır. İmgelerin boyutlarının anlamlı bir şekilde düşürülmesi manasına gelen boyut indirgeme algoritmaları da birer optimizasyon tekniğidirler. Yapılan çalışmada hiperspektral görüntü olarak bilinen ve büyük miktarlarda bilgi içeren bu verilere optimizasyon yaklaşımı ile boyut indirgeme algoritmaları uygulanmıştır.

Yüksek miktarlarda bilgilere sahip olan veriler herhangi bir sınıflandırma veya tanıma prosedürüne doğrudan tabi tutulamazlar. İşlem süresinin uzun olması ve veri tabanlarında kapladıkları yer fazlalığı, kullanılan yöntemlerin başarısının düşmesine sebep olmaktadır. Bu problemlerin önüne geçmek için verilere ilişkin kullanılacak

sınıflandırma ve tanıma işlemlerinden önce başarılı bir boyut indirgeme süreci gerekmektedir. Boyut indirgeme, bir veri kümesini onun orijinal bütününi temsil eden daha küçük bir boyuta indirmeyi amaçlayan veri işleme aşamasıdır. Boyut indirgeme algoritmaları ile daha düşük boyutlardaki veriler ile sınıflandırma ve tanıma işlemlerinin yapılması sağlanır. Bu sayede hem veri tabanında daha düşük boyutlu veri saklanmış hem de hesaplama süresi azaltılmış olur. Ayrıca, boyut indirgeme teknikleri sayesinde veri kümesindeki ilgisiz ve gereksiz tekrar eden veriler de elenmiş olacaktır. Ancak boyut indirgeme esnasında imgelerin öz niteliklerinin karakteristik özelliklerinin korunmasına da dikkat edilmelidir. Şekil 1.1’de veri işleme adımları gösterilmiştir.




Şekil 1.1 Veri işleme adımları

Hiperspektral görüntüler (HSG), yüksek miktarlarda bilgi içeren özel görüntülerdir. Boyut indirgeme alanında hiperspektral görüntüler kullanılarak yapılmış birçok akademik çalışma mevcuttur. Bu çalışmalar farklı yöntemler ile HSG’de boyut indirgeme problemine çözüm önermişlerdir.

HSG üzerinde işlemler gerçekleştirilirken, görünür dalga boyu ile elde edilmiş görüntülere göre farklı yaklaşımlar geliştirmek gerekmektedir. İki görüntü türü arasındaki temel fark; görünür dalga boyu ile alınmış resimler tek bir bantta görüntü

içerirken, HSG’de ise resimler birden fazla banda sahiptirler. Bu durumun en önemli avantajı; HSG sayesinde incelenen malzemenin göz ile algılanamayan bazı özellikler hakkında da bilgi sahibi olunmasıdır.

2006 yılında, G. Balasubramanian ve V.K. Shettigara [2], yayınladıkları makalelerinde, Destek Vektör Makinaları (DVM) kullanarak HSG’de boyut indirgeme yapmışlardır. Kullandıkları veri kümesindeki 128 spektral bandı, kümelere ayırıp en uygun bant sayısına ulaşmaya çalışmışlardır. Şekil 1.’de belirtilen sonuçlara göre 59 tane bant seçildiğinde en yüksek performansa ulaşılmıştır.



Şekil 1.2 DVM yöntemi ile boyut indirgeme [2]

2013 yılında yayınlanan “Hiperspektral Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi” çalışmasında ise, Temel Bileşen Analizi (TBA), Doğrusal Ayraç Analizi ve Faktör Analizi yöntemleri boyut indirgeme algoritmaları olarak tasarlanmışlardır [3]. Yapılan çalışmada 224 bantlı AVIRIS görüntüsünün bahsedilen yöntemler ile bant sayısı azaltılmış ve çıkan sonuçlar kıyaslanarak en iyi boyut indirgeme yöntemine ulaşılmaya çalışılmıştır.

2014 yılında yayınlanan “Dirichlet Karışım Modelleriyle Hiperspektral Görüntülerin Bölütlenmesi” adlı çalışmada ise, hiperspektral algılayıcılardan elde edilen yüksek boyutlu HSG’nin spektral dağılımlarının Dirichlet Karışım Modeli kullanılarak eğitici olarak bölütlenmesi önerilmektedir [4]. Ancak, çalışmada kullanılan ve büyük boyutlara sahip *AVIRIS Cuprite S4* hiperspektral verisinde bölütleme öncesi hesapsal yükü azaltmak için boyut indirgeme yöntemleri olarak TBA ve çekirdek TBA (ÇTBA) kullanılmıştır. Sonuçta da TBA’nın ÇTBA’ya göre daha iyi sonuçlar verdiği bulunmuş ve boyut indirmeye yeni bir katkı sunulmuştur.

Sezgisel yöntemler ise, çözüm uzayında stokastik ancak bilinçli bir şekilde arama gerçekleştiren yöntemlerdir [5]. Sezgisel yöntemler birçok optimizasyon problemine uygulanmışlardır. Özellikle probleme kolay uygulanabilirliği sayesinde son yıllarda hiperspektral görüntülerde kullanımı artmıştır. Örneğin, 2011 yılında Yang-Lang Chang tarafından yapılan çalışmada Benzetilmiş Tavlama (BT) yöntemi ile hiperspektral görüntülerde özellik çıkarımı gerçekleştirilmiştir [6]. BT tabanlı bu özellik çıkarımı işlemi sonucunda ise En Yakın k -Komşu Algoritması ile sınıflandırma yapılmış ve kullanılan sezgisel yöntemin hiperspektral görüntülere olan uyumu ön plana çıkmıştır.

2011 yılında yapılan bir başka çalışmada ise Li vd. hiperspektral görüntülerde Genetik Algoritma (GA) ile bant seçme işlemini gerçekleştirmişlerdir [7]. Bu çalışmada ayrıca, bant seçimi öncesi Karşılıklı Bilgi (KB) yöntemi ile de gruplamaya gidilmiş ve GA tabanlı bant seçim işleminin sınıflandırma başarımını kullanılan *Indian Pine* verisi için %82'den %84'e çıkarmıştır.

2013 yılında Ashish Ghosha ve arkadaşları tarafından gerçekleştirilen çalışmada ise, Diferansiyel Gelişim Algoritması (DGA) hiperspektral görüntülerde bant seçimi için kullanılmıştır [8]. Yapılan çalışmada DGA başarımını ölçmek için diğer metasezgisel yöntemlerden Karınca Koloni Algoritması ve GA kullanılmış ve bu 3 farklı yöntemin başarımları kıyaslanmıştır.

1.2 Tezin Amacı

Bu tez kapsamında HSG üzerinde boyut (bant) indirgeme ve bant gruplama algoritmaları geliştirmek amaçlanmıştır. Değişken Komşuluk Arama (DKA), BT, GA, DGA, KB, Korelasyon Alma ve Spektral Kümeleme (SK) kullanarak hiperspektral görüntülerde sınıflama başarısını artırmaya yönelik boyut indirgeme planlanmaktadır.

1.3 Hipotez


HSG'de boyut indirgeme ile daha etkin ve daha yüksek sınıflandırma başarımına ulaşmak için, DKA, BT, GA ve DGA ile bu algoritmalarda da uyumluluk fonksiyonu olarak kullanılmak üzere Spektral Açık Haritalıyıcı (SAH) hipotez olarak önerilmiştir. İlerleyen aşamada ise boyut indirgemeye KB, Korelasyon Alma ve SK yöntemleri ile bant gruplama yaklaşımı eklenerek daha yüksek sınıflandırma başarımı ve daha yüksek hızda boyut indirgeme amaçlanmıştır.

HİPERSPEKTRAL GÖRÜNTÜLEME SİSTEMLERİ

2.1 Hiperspektral Görüntüler

Hiperspektral görüntüleme 1970’li yılların başından itibaren kullanılmaya başlanmış bir teknoloji olmasına rağmen, yaygın kullanımı geçtiğimiz son 10 seneye dayanmaktadır. Hiperspektral görüntüleme yüzey materyallerinden yansıyan enerjinin dar ve bitişik çok sayıda dalga boyu bandında ölçümüdür. Hiperspektral; ‘*hiper*’ yani çok fazla, aşırı anlamındadır, ayrıca çok sayıda spektral banttan oluşan anlamına gelmektedir. Hiperspektral alıcıların en belirgin özelliği çok bantlı (*multispektral*) görüntülerden farklı olarak çok daha fazla banda sahip olmalarıdır. Ancak, alıcıları hiperspektral yapan özellik bant sayısından çok, bantların ne kadar dar ve birbirine ne kadar bitişik olduğudur [9].

Hiperspektral görüntüler diğer sayısal görüntülerin aksine ışığın dalga boyunun insan gözü ile görülemeyen kısımları hakkında da yüksek çözünürlükte spektral bilgi içeren özel görüntülerdir. Özel sensörlerle alınan bu görüntülerle genellikle ultraviyole ışınları ile kızılötesi ışınları arasında kalan dalga boyu aralığı kaydedilebilmektedir. Şekil 2.1’de görüldüğü gibi insan gözünün algılayabileceği ışığın dalga boyu aralığı 400 nm ile 700 nm arasında sınırlıyken, hiperspektral sensörler görünür ve kızılötesi bölgesini kapsayan daha geniş bir spektrumda görüntü kaydedebilmektedir. Böylece elde edilen görüntülerde klasik görüntülere göre daha fazla karakteristik özellik bulunmaktadır.




Şekil 2.1 Işığın görülebilen dalga boyu aralığı [10]

Hiperspektral görüntüleri yakalayabilen sensörlerin yapımında dünya üzerinde 400 milyon yıldan beri yaşayan bir deniz canlısından ilham alınmıştır. Mantis karidesi olarak bilinen bu canlı, gözlerindeki gelişmiş sensörler sayesinde dünya üzerinde başka hiçbir hayvanda bulunmayan bir algılama yeteneğine sahiptir. 3 ayrı ana renge duyarlı insan gözüne karşın, mantis karidesinin 12 ayrı ana renge duyarlı olan gözleri bir tür hiperspektral sensör gibi çalışabilmektedir (Şekil 2.2) [11].



Şekil 2.2 Mantis karidesinin göz yapısı

Normalde bir imge iki boyutlu (x,y) uzamsal koordinatlarında ifade edilirken hiperspektral görüntülerde ise her bir bant aralığı için bir katman olmak üzere z ekseninde yüzlerce görüntü vardır (Şekil 2.3). Hiperspektral görüntüler bu özellikleri nedeniyle ilk iki boyut uzamsal, üçüncü boyut spektral bilgi olmak üzere, üç boyutlu hiperspektral imge küpü (*Hiperküp*) olarak ifade edilir [12].




Şekil 2.3 Hiperspektral küp ve spektral imzanın çıkarılması [13]

İnsan gözünün algılayabileceği dalga boyu sınırlı olmasına karşın, hiperspektral görüntülerde ise dalga boyu aralığı için sınırlar yoktur. Kullanılan sensörün hassasiyetine göre seçilen bir dalga boyu aralığı çok sayıda parçaya ayrılabilir. Böylece HSG’de istenilen görüntüyü temsil edecek çok sayıda matris oluşacak ve her piksel için, elde edilen matris sayısı kadar yeni özellik elde edilecektir (Şekil 2.3). Elde edilen matrislerin sayısının artması, görüntüyü ifade eden ayırt edici özelliklerin artması anlamına gelmektedir.

2.1.1 Hiperspektral Görüntüleme Sistemi ve Spektral İmza


Hiperspektral görüntüleme, spektrometre adı verilen cihazlarla gerçekleştirilir. Karmaşık bir yapıya sahip olan bu alıcı cihazlar, uzaktan algılama ve spektroskopinin (materyallerden yansıyan veya yayılan ışığın farklı dalga boylarına dağılımı üzerine

çalışan bilim dalı) bir araya gelmesiyle ortaya çıkmıştır. Materyallerin yüzeyinden yansıyan ışığın, bulunduğu yerde veya laboratuvarlarda ölçümü için kullanılan spektrometre, içindeki prizmaya benzer optik bileşen sayesinde spektrometreye ulaşan ışığı dar ve birbirini takip eden çok sayıda dalga boyu bandına ayırıştır (Şekil 2.4).



Şekil 2.4 Hiperspektral görüntüleme düzeneği [13]


Yüzeyden yansıyan güneş ışınları, bir uydu veya uçağa yerleştirilmiş bir sensör yardımıyla yakalanabilmektedir (Şekil 2.5). Yansıyan kısmın bir kısmı insan gözü tarafından hissedilebilirken, hissedilebilenden daha büyük bir aralığa ulaşmak için ise daha duyarlı sensörler kullanılması gerekmektedir.



Şekil 2.5 HSG'nin elde edilişi, hiperspektral küp verisi ve spektral imza [14]

Işığın yansıyan miktarı yüzde olarak '*reflektans*' (yansıma) terimi ile ifade edilir. '*Reflektans spektrumu*' materyalden yansıyan ışığın farklı dalga boylarındaki enerjisinin ölçümü ile elde edilir. Materyallerin kendilerine has yansıma ve Emilme özellikleri sayesinde, farklı malzemelerin aynı dalga boylarındaki reflektans değerleri birbirinden farklı olacaktır. Bu sayede, 'Spektral imza' adı verilen örüntüler ile materyallerin


tanınması sağlanır. Şekil 2.6’da toprak, kuru bitki ve bitki için elde edilen spektral imzalar görülmektedir. Üç farklı yüzey materyalinden gelen yansıma miktarlarının dalga boylarına göre değişimi görülmektedir.



Şekil 2.6 Toprak, kuru bitki ve bitki için elde edilen spektral imzalar [15]

Görüldüğü gibi spektral imzaları kullanarak görüntü üzerindeki alanları birbirlerinden ayırt etmek ve sınıflandırmak mümkündür. Eğer elimizde, görüntü üzerinde bir bitkiye ait spektral imza varsa, bu görüntüdeki tüm benzer özellikteki bitkileri de bu imzayı kullanarak anlama imkânı vardır.

HSG’de potansiyel çok fazla olmasına rağmen, atmosferik etkiler, su buharı emilimi ve ışığın yansıması gibi bozucu durumlar dolayısıyla spektral bantların bir kısmı hatalı bilgi içerebilmektedir. Bu yüzden, öncelikle bozulmalara uğramış olan bantları görüntüden çıkarıp veriyi daha güvenilir bir hale getirmektir. Şekil 2.7’deki bozulmuş bantları temizlenmemiş spektral imzalardan örneklerde görüldüğü gibi, 140 ile 160 numaralı bantlar arasında ve 200 numaralı banttan sonrasındaki değerler sürekliliği bozmaktadır. Öncelikle bu bantlar kullanılacak veriden çıkarılarak başlanmalıdır.



Şekil 2.7 Spektral imzalardaki bozulmalar

2.1.2 Hiperspektral Sensörler ve Kullanım Alanları

HSG'yi elde etmek için genel olarak hava veya uzay platformları kullanılmaktadır. Hava platformlarından görüntüleme, öncelikle görüntü alınacak bölge için bir uçuş planı tasarlanır ve belirlenen gün ve saatte uçuş gerçekleştirilir. Ancak uçağın uçurulması ile ilgili bütçenin çok yüksek olması ve bu yolla yapılan görüntüleme çok geniş bölgelerin görüntülenememesi dolayısıyla, bu görüntüler genellikle yerel ölçekli ve araştırma odaklı çalışmalarda kullanılır. AVIRIS ve HYDICE gibi bazı görüntüleme sistemleri bugüne kadar kullanılmış ve günümüzde de hala kullanılmaktadır. Çizelge 2.'de bazı bilinen hava platform sensörleri ve bu sensörlerin özellikleri verilmiştir.

Çizelge 2.1 Başlıca HSG hava platform sensörleri [16]

TİP	ADI	ÜRETİCİ	BANT SAYISI	DALGA BOYU (nm)
Uçak	AVIRIS	NASA Jet Propulsiyon Lab.	224	400 – 2500
Uçak	HYDICE	ABD Donanma Araştırma Lab.	210	400 – 2500
Uçak	PROBE-1	Earth Search Sciences Şirketi	128	400 – 2500
Uçak	CASI	ITRES araştırma şirketi	228	400 – 1000


1990'ların başından itibaren uzay platformları aracılığıyla hiperspektral analiz ve uygulamaları yapılmaktadır. İlk olarak NASA, ESA ve daha sonra Avustralya tarafından başlatılan bu çalışmaları ilerleyen yıllarda Kanada ve İtalya'da

desteklemiştir. Ancak yapılan bu çalışmalarda NASA'nın "EO 1 Hyperion [17] alıcısı ve ESA'nın CHRIS Proba alıcısı [18] haricinde başarılı olan çıkmamıştır. Çizelge 2.2'de bazı bilinen uydu sensörleri ve bu sensörlerin özellikleri verilmiştir.

Çizelge 2.2 Başlıca HSG uydu sensörleri [16]

TİP	ADI	ÜRETİCİ	BANT SAYISI	DALGA BOYU (nm)
Uydu	FTHSI on MightySat II	ABD Hava Kuvvetleri Araştırma Lab.	256	350 – 1050
Uydu	Hyperion on EO-1	NASA Goddard Uzay Uçuş Merkezi	220	400 – 2500
Uydu	HySI	Hindistan ISRO	64	400 – 950
Uydu	HJ-1A	Çin CAST	110	450 – 950
Uydu	HICO	ABD NASA	128	353 – 1081

Çizelgede gösterilen sensörlerin yanında, genelde ticari faaliyetler için üretilmiş HSG kameralar da vardır (Şekil 2.8). Bu kameralar yardımıyla herhangi bir hava veya uzay platformuna gerek duymadan çeşitli uygulamalar için farklı dalga boyu aralıklarını gözleyip amaca uygun sonuçlar almak mümkündür.




Şekil 2.8 Hiperspektal kamera [19]

Hiperspektal görüntülemenin özellikle son yıllarda artan çok geniş bir kullanım alanı vardır. Sonuçlarının diğer görüntüleme sistemlerine göre daha anlamlı olması ve daha fazla bilgi içermeleri sebebiyle savunma sanayiinden sağlık sektörüne birçok araştırmacı çok bantlı görüntüleri tercih etmektedir. Başlıca uygulama alanları [20]:


- Madencilik için, yer altı kaynaklarının tespit edilmesi,
- Tarımda, hasat zamanı oluşabilecek olası hastalık ve zararları önlemede,
- Askeri alanda, termal kızılötesi hiperspektral görüntülemeye,
- Astronomide, uzak gezegen, meteor, yıldız ve bulutsu gibi gök cisimlerinde bulunan maddelerin belirlenmesinde,
- Kimyasal alanda, havadaki renksiz ve kokusuz olan zararlı maddelerin tespitinde,
- Çevresel konularda, fabrika ve yük gemilerinden sızan zehirli atıkların tespitinde,
- Ayrıca Uzaktan Algılama, Adli Tıp, Biyoteknoloji, Medikal Bilimler, Mikroskop Kullanım Alanları ve İlaç Üretimi.

Yukarıdaki veriler ışığında, hiperspektral sensörler ile değişik alanlarda gerçekleştirilen birçok çalışma mevcuttur. Örneğin, 2001 yılında gerçekleştirilen bir çalışmada Kim vd. [21], Amerikan Tarım Bakanlığı bünyesinde besin sağlığı üzerinde durmuş, hiperspektral görüntüler kullanarak besinlerdeki sağlığı bozucu etkileri tespit etmişlerdir. Yaptıkları deneylerde taze elmalar ile bozulmuş elmaların spektral imzalarının farklı olduğunu görüp bu şekilde elmaları sınıflamışlardır (Şekil 2.9).




Şekil 2.9 Elma görüntülerindeki spektral imzalar, a) Bozuk elma b) Taze elma [21]

2003 yılında Plaza vd. [22] tarafından gerçekleştirilen çalışmada ise hiperspektral görüntüler üzerindeki hedefleri, gözetimsiz bir yöntem olan genişletilmiş matematiksel morfolojik işlemler ile sınıflandırmayı önermişlerdir. Şekil 2.10'da HSG'den seçilmiş bir bant ve doğrulama verisi görülmektedir. 1 ve 2 olarak farklı türlerdeki ağaçlar işaretlenmiştir. Bu sınıfları birbirinden ayırmak amaçlanmıştır.



Şekil 2.10 Kullanılan HSG' ye ait, a) Renkli görüntü b) doğrulama görüntüsü [22]

2008 yılında Çetin vd. [23], yaptıkları çalışma ile ise yer ölçmelerine bağlı olarak Hiperspektral uydu görüntülerinden elde edilen test alanlarına ait spektral eğriler kullanılarak hiperspektral görüntülerden ağaç türlerini ayırmayı başarmışlardır. Şekil 2.11'de bu çalışma sonucunda tesbit edilen ağaç türleri renklendirme ile gösterilmiştir.



Şekil 2.11 Kullanılan HSG ile ağaç çeşitlerinin ayrılması [23]

20 Nisan 2010 tarihinde Meksika körfezindeki bir petrol rafinesinde gerçekleşen patlama sonucu yaklaşık 5 milyon varil petrol körfeze yayılmıştır. Clark ve arkadaşları Kuzey Baltık denizi boyunca yayılan petrol sızıntılarının tespitini hiperspektral görüntülemeyle gerçekleştirmiş ve kirlilik oranının tesbit etmeye çalışmışlardır [24].



Şekil 2.12 Meksika körfezinde yaşanan petrol sızıntısı felaketi [24]

METASEZGİSEL YÖNTEMLERLE BOYUT İNDİRGEME VE SİNIFLANDIRMA YÖNTEMLERİ

3.1 Metasezgisel Yöntemler

Teknik yazında ilk defa Glover (1986) tarafından ifade edilen metasezgisel terimi, kelime anlamı itibariyle “Meta” ve “Sezgisel” kelimelerinin birlesiminden türetilen bir kavramdır. “Meta” Latince ya da Yunanca’da kullanıldığı bilinen ve birlikte, -den, ortasında, -den sonra anlamlarına gelen bir kelimedir. Sezgisel kavramı ise “Heuristic” olarak İngilizce’ye geçen Almanca kökenli bir kelime olup, keşfetme, bulma anlamını taşımaktadır. Bir arada kullanıldığında ise, kullanıcı tanımlı bir takım kurallar ya da prosedürler yardımıyla hesaplama yapabilen ve problem çözen yaklaşımlar bütünü olarak tarif edilebilmektedir. Metasezgisel algoritmalar, temel sezgisel metotları daha üst seviye bir çatı altında toplayarak, çözüm uzayını verimli ve etkili bir şekilde araştırmayı amaçlayan iteratif optimizasyon teknikleridir [25].


Metasezgisel yaklaşım çözüm uzayında stokastik ancak bilinçli bir şekilde arama gerçekleştiren yöntemlerden oluşur [26]. Bu yöntemler her iterasyonda çözüm kümesinden yola çıkarak yeni çözümler üretirler. Böylece, arama uzayının en uyguna yakın olan noktalarında arama gerçekleştirerek ve yerel en iyi noktalardan kurtularak, en uygun çözüme yakın sonuçlar elde etmeyi sağlarlar.

2003 yılında Blum ve Roli’nin çalışmalarına göre [26], metasezgisel yöntemler aşağıdaki şekilde karakterize edilmektedir:

- Metasezgisel yöntemler arama işlemine yön veren stratejilerdir.
- Genel amaç, arama uzayını etkili bir şekilde keşfederek en iyi veya en iyiye yakın sonuçlar elde etmektir.

- Metasezgisel yöntemler yerel arama tekniklerinden, karmaşık öğrenme işlemlerine kadar yayılım gösterir.
- Metasezgisel algoritmalar yaklaşık ve genelde belirleyici olmayan yöntemlerdir.
- Arama uzayında yerel en iyi konumlara takılıp kalmayı engelleyecek mekanizmaları içerirler.
- Metasezgisel teknikler belirli bir probleme özgü değildir.


Bir metasezgisel algoritmanın iyi sonuçlar üretmesi için yapılması gereken ilk işlem, yöntemin temel kavramlarının probleme iyi bir şekilde adapte edilmesidir [27]. Algoritmada kullanılacak uygunluk fonksiyonunun probleme uygunluğu, elde edilecek sonucun iyi olmasında çok önemli bir yer tutmaktadır. Metasezgisel algoritmaya ilk olarak bir başlangıç popülasyonu oluşturularak başlanır. Popülasyon üyeleri genellikle çözüm uzayına rasgele dağılacak şekilde ilk değerlerini alırlar. Daha sonra mevcut popülasyonun tamamı veya belirli bir kısmı seçilir ve seçilen bu üyeler kullanılarak farklı yeni nesil üyeler elde edilir. Yeni nesil üyelerin elde edilmesi işlemi çok çeşitlidir ve algoritmalar arasındaki temel farklılıklardandır. Yeni üye elde etme işleminde ebeveyn üyeler arasında çaprazlama bilgi paylaşımı yapılabilir. Ayrıca yeni üyeler, ebeveyn üyelerin üzerinde belirli bir olasılığa bağlı ve diğer üyelerden bağımsız değişiklikler yapılarak da oluşturulabilir. Diğer taraftan yeni üyeler optimizasyon sürecinde daha önceden elde edilen bilgiler kullanılarak da üretilebilirler. Oluşturulan yeni üyelerin içerisinde belirli kurallara bağlı olarak seçilen bireyler popülasyon içindeki ebeveyn üyelerin bir kısmının veya tamamının yerini alırlar. Böylece tam bir çevrim ile sürecin başına dönmüş olur. Söz konusu iteratif döngü, belirlenen bir maksimum iterasyon sayısına ulaşıncaya veya istenen kriterlere sahip bir amaç fonksiyonu değeri bulununcaya kadar devam eder. Optimizasyon süreci sonunda elde edilen sonuç, en uygun veya istenilen kriterleri sağlayan en uygunu yakın bir değer olabilir. Metasezgisel algoritmaların temel çalışma mekanizması şematik olarak Şekil 3.1’de sunulmuştur.



Şekil 3.1 Metasezgisellerin temel çalışma mekanizması [29]

Metasezgisel yöntemler, yerel arama, benzetilmiş tavlama, tabu arama, genetik algoritmalar, evrimsel hesaplama, karınca kolonisi eniyilemesi gibi birçok farklı yöntemden oluşmaktadır. Bu yöntemler, farklı yönler göz önünde bulundurularak çeşitli şekillerde sınıflandırılabilir. Temel olarak metasezgisel yöntemler [28] :


- Doğadan esinlenerek geliştirilenler – Doğadan esinlenmeden geliştirilenler
- Popülasyon tabanlı algoritmalar – Tek nokta (yerel arama) algoritmalar (Şekil 3.1)
- Dinamik amaç fonksiyonlu – Statik amaç fonksiyonlu algoritmalar
- Tek komşu yapılı – Çok komşu yapılı algoritmalar
- Hafıza kullanan – Hafıza kullanmayan algoritmalar



Şekil 3.2 Metasezgisellerin arama çözüm sayısına dayalı sınıflandırılması [29]

3.1.1 Benzetilmiş Tavlama (BT)

1983 yılında Kirkpatrick ve arkadaşları tarafından kullanılmaya başlanan BT, kombinatoriyal eniyileme problemlerinin çözümü için geliştirilmiş yerel arama algoritmalarından biridir [30]. Algoritma, metalürji ve malzeme bilimlerinde, belirli bir malzemenin sertlik ya da güç gibi özelliklerinin, ısı işlem ile değiştirilmesine dayanan tavlama süreci ile kombinatoriyal eniyileme problemleri arasında bir benzerlik kurarak, eniyileme problemlerine çözüm getirmeyi amaçlar. Yoğun madde fiziğinde, tavlama, bir katının ısı banyosunda düşük enerji durumlarının elde edilmesini sağlayan termal süreç olarak tanımlanmaktadır. Süreç, ısı banyosunun sıcaklığının, katının eriyeceği maksimum sıcaklık değerine yükseltilmesi ve tanecikler en düşük enerji seviyeli duruma gelinceye dek, ısı banyosunun sıcaklığının dikkatlice azaltılması şeklinde iki adımdan oluşmaktadır [31] (Şekil 3.3).



Şekil 3.3 BT’de ısı işlem basamakları [32]

BT’de amaç, sıcaklığın kontrollü bir biçimde azaltılması ile küresel en iyinin bulunmasıdır. Başlangıç çözümünün ve başlangıç sıcaklığının belirlenmesinin ardından sıcaklık azaltılarak yeni çözümlerin oluşturulması, değerlendirilmesi ve sıcaklığın uyarlanması ile algoritma devam eder [33]. Çizelge 3.1’de BT algoritmasının akış şeması gösterilmiştir.

Çizelge 3.1 BT Algoritması Akış Şeması

1-Başlangıç çözümü oluştur ve fitness değerini hesapla
2-Başlangıç çözümünü en iyi çözüm olarak belirle
3-İterasyon sayısı kadar tekrar et
a-Mevcut çözümden komşu bir çözüm üret
b-Komşu çözümün fitness değerini hesapla
c-Komşu çözümün sonucu mevcut çözümün fitness değerinden daha iyi ise komşu çözümü mevcut çözüm olarak belirle
d-Değilse kabul formülüne göre komşu çözümü kabul veya reddet
e-Mevcut çözüm en iyi çözümden daha iyi ise en iyi çözüm olarak belirle
4-Sistemi soğutma formülüne göre soğut
5-Sonlandırma koşulu sağlanmadığı sürece adım 3’e git

BT algoritmasında kullanılan parametreler:

- Başlangıç sıcaklığı: Bu ısı ne kadar yüksek olursa taranan genişlik okadar yüksek olur
- Soğutma Oranı: Mevcut sıcaklıkla çarpılarak azalmasını sağlar

- Döngü sayısı: Her bir sıcaklık seviyesinde gerçekleştirilecek döngü miktarıdır. Döngü miktarı belirlenen limite ulaştığında sıcaklık soğutma oranı ile çarpılarak düşürülür
- Durdurma kuralı: Sıcaklık bu sıcaklığa düştüğünde döngüyü durdur. Ne kadar küçük seçilirse taranan genişlik okadar yüksek olur ancak cpu süresi artar.

Algoritmanın temel amacı, herhangi bir problem için genel iyileştirme (global optimizasyon) elde etmektir. Diğer bir deyişle, herhangi bir fonksiyon ya da ölçümün genel (global) minimum yada genel maximumunu bulmaktır. Bu sebeple, özellikle matematiksel modellerle gösterilemeyen kombinasyonel problemlerin eniyileme uygulamalarında tercih edilir.

3.1.2 Değişken Komşuluk Arama (DKA)

DKA metodu, global optimizasyon problemlerinin çözümü için kullanımı son zamanlarda artan yerel arama tabanlı bir meta-sezgisel yöntemdir. VNS yönteminde temel fikir, SA'da anlatıldığı gibi komşuluk yapısının arama sırasında sistematik bir şekilde değişmesi esasına dayanır. Genel olarak, aday komşuların oluşturulması, daha iyi bir komşu bulunmadığı takdirde algoritmanın sonlandırılması, aksi takdirde, daha iyi bir komşunun seçilmesi ile devam edilmesi ve sonlandırma ölçütü sağlandığında elde edilen son çözümün listelenmesi şeklinde bir genel yapıya sahiptir [25].

Sistematik bir arama söz konusu olmamasına rağmen, DKA'nın düşük miktardaki hafıza kullanımı ve büyük ya da sonsuz durum uzayına sahip problemlere makul çözümler üretmesi DKA'yı avantajlı bir duruma getirmektedir [34]. Bunun yanında DKA, çok sayıda olası çözümü kısa bir zamanında değerlendirebilme, birçok problem çeşidine kolayca uyarlanabilme, daha kolay bir biçimde anlaşılabilme ve gerçekleştirilebilme özelliklerine sahiptir [35]. Ancak bu avantajlarına karşın, DKA'nın yerel en iyiye takılması dezavantaj olarak karşımıza çıkmaktadır. DKA'da, yerel en iyiden kurtulmak için:

- Çözümün farklı bir başlangıç çözümü üzerinden yinelenmesi,
- Mevcut çözümü iyileştirmeyen komşuların da kabul edilmesi,
- Arama sırasında komşuluk yapısının değiştirilmesi gibi farklı yaklaşımlar uygulanmaktadır [25].

Çizelge 3.2 DKA Algoritması Akış Şeması

Başla

Arama için kullanılacak olan $k=1, \dots, k_{\max}$ için, N_k komşuluk fonksiyonlarını tanımla. Başlangıç çözümü için bir x çözümümü bul.

while durdurma kriteri sağlanıncaya kadar

$k \leftarrow 1$

$k = k_{\max}$ oluncaya kadar tekrar et

Rasgele bir x' komşuluğu seç ($x' \in N_k(x)$)

Eğer bulunan x' çözümü x çözümünden daha iyi ise

$x \leftarrow x'$

Değilse

$k \leftarrow k + 1$

bitir-while

Bitir

3.1.3 Genetik Algoritmalar (GA)


GA ilk olarak 1970 yılında Holland tarafından önerilmiş ve 1975 yılında “*Adaptation in Natural and Artificial Systems*” adlı kitapta yayınlanmıştır [36, 37]. Temel olarak canlılardaki doğal gelişim prensibine dayanan GA’da, gerçek yaşamda bir populasyon içerisinde çevrenin ve ortamın gerektirdiklerine daha iyi cevap verebilen bireyler bir sonraki nesle genlerini aktarabilmekte, yetersiz olanların ise büyük bir kısmı elimine olmaktadır. Bu şekilde bir sonraki nesil daha gelişmiş olmaktadır. Nesiller ilerledikçe en iyi gen kombinasyonuna ulaşılması mümkün hale gelmektedir.

Çok fazla teorik bilgiye ihtiyaç duyulmadan uygulanabilen GA, uygulamadan elde edilen sonuçları da direkt kullanabilmesi sayesinde yaygın olarak kullanılmaktadır. GA’nın grup çözümle uğraşması özelliği sayesinde de çok sayıda çözümün içinden en iyileri seçilip kötülerini elenebilir.

Kopyalama, çaprazlama ve mutasyon olmak üzere toplamda 3 aşamada gerçekleşen GA adımlarına geçmeden önce genel birkaç terimin bilinmesinde fayda vardır:

- Kromozom: Bir ya da birden fazla gen yapısının bir araya gelmesiyle oluşan ve problemin çözümü için gerekli tüm bilgiyi içeren diziler [38].

- Gen: Kromozom içerisinde kendi başına genetik bilgi taşıyan en küçük yapı birimi [39].
- Popülasyon: Çözüm bilgilerini içeren kromozomların bir araya gelerek oluşturdukları topluluk. Popülasyon büyüklüğü arttıkça popülasyondaki çeşitlilikte artış gösterecektir ancak daha fazla uygunluk değeri hesaplanacağından problemin çözüm süresi de uzayacaktır [40, 41].
- Kodlama: Probleme ait bilgilerin GA'nın anlayabileceği dile çevrilmesi [42]. Genetik algoritmanın uygulanmasındaki ilk adım değişkenlerin kodlanmasıdır.
- Uygunluk Fonksiyonu: Bulunmaya çalışılan optimum değere ulaşmak için önerilen matematiksel denklem. GA'nın beynini oluşturmaktadır. Genetik algoritmanın probleme özel çalışan tek kısmı bu fonksiyondur.
- Çaprazlama oranı: Çaprazlamanın hangi sıklıkla yapılacağını belirler [43].
- Mutasyon oranı: Mutasyon aşamasında kromozomda ne kadar değişiklik olacağını gösteren orandır [43].



Şekil 3.4 GA Akış Şeması [44]


GA’da ilk adım deęişkenlerin kodlanmasıdır. İyi bir kodlama sayesinde iyi bir genetik yapı oluşturulabilir. Her probleme göre kromozomların kodlama şekli de deęişmektedir. Genel olarak GA’da ikili kodlama ve permütasyon kodlama kullanılır. Ancak problemin çeşidine göre deęer kodlama ve ağaç kodlamada kullanılabilir [45]. Kodlamanın sonrasında popülasyonun büyüklüğüne karar verilir ve rastgele bir çözüm atanır. Ardından, uygunluk fonksiyonu yardımıyla her kromozomun ne kadar iyi olduęu bulunur. Uygunluk fonksiyonu GA için çok önemli bir yer tutar. Çoęu zaman genetik algoritmanın başarısı bu fonksiyonun verimli ve hassas olmasına göre deęişebilmektedir [46]. Uygunluk fonksiyonun da belirlenmesinden sonra sırasıyla kopyalama, çaprazlama ve mutasyon işlemleriyle devam edilir. Şekil 3.4’te genetik algoritma akış şeması gösterilmiştir.

Kopyalama:

Bu aşamada, popülasyondaki iyi olan bireyler seçilir ve bir sonraki nesle aktarılır. Bu sayede kötü olan bireylerden de kurtulmuş olur. Kopyalamada rulet tekerleęi seçimi ve turnuva seçimi gibi seçme yöntemleri kullanılmaktadır. Bu iki yöntemden en sık kullanılanı ise rulet tekerleęi yöntemidir. Rulet tekerleęi tekniğinde her birey uygunluk deęeri ölçüsünde seçilme olasılığına sahiptir. En iyi uygunluk deęerine sahip bireyin seçilme olasılığı en yüksektir. Fakat en kötü bireyin de çok az da olsa bir seçilme olasılığı bulunmaktadır.

Çaprazlama:

İki ata çözümden yavrunun oluşturulması sürecidir. Kopyalamadan galip olarak çıkan bireyler, rasgele eşleştirilir ve belirli bir kurala göre iki bireyin bazı genleri birbirleriyle deęiştirilerek yeni bireyler oluşturulur. Tek noktadan çaprazlama, iki noktadan çaprazlama, çok noktadan çaprazlama, düzenli çaprazlama ve aritmetik çaprazlama olmak üzere 5 farklı çaprazlama çeşidi kullanılabilir. Tek noktadan çaprazlama en çok tercih edilen çaprazlama tekniğidir. Bu teknikte bir çaprazlama noktası seçilir ve birinci atanın çaprazlama noktasına kadar olan kısmı, ikinci atanın kesme noktasından sonraki kısmı bir araya getirilerek, yavru oluşturulur [36]. Şekil 3.5’te tek noktadan çaprazlama örneęi görülmektedir.




Şekil 3.5 GA’da, tek noktadan çaprazlama örneği

Çaprazlamada karşımıza çıkan bir diğer kavramda çaprazlama işleminin hangi sıklıkla yapılacağını belirleyen çaprazlama oranıdır. Eğer genetik algoritma adımlarından çaprazlama gerçekleştirilmez ise, ata bireyler ile yavru bireyler birbirlerinin aynı olurlar ve bu yüzden genetik çeşitlilik sağlanamamış olur [36].

Mutasyon:

Bu aşamada bireyler, diğer bireyler ile etkilesime girmeden kendi içinde gen değişimine uğrarlar. Yerel en iyiye sıkışma probleminin önüne geçilmesi için mutasyon çok önemlidir. Ayrıca toplumda çeşitliliğin sürdürülmesi de sağlanmış olur.

Mutasyonda da farklı yöntemler kullanılabilir. Kromozom üzerinde rasgele iki gen seçilerek bu iki genin yer değiştirilmesi veya rasgele seçilen bir genin sonrasındaki genlerin tersinin alınması gibi yaklaşımlar bulunmaktadır [44]. Şekil 3.6’da kromozom üzerinde rasgele iki gen seçilerek bu iki genin yer değiştirilmesine bir örnek verilmiştir.



Şekil 3.6 GA’da mutasyon örneği

Mutasyonda karşımıza çıkan bir diğer kavramda mutasyon işleminin hangi sıklıkla yapılacağını belirleyen mutasyon oranıdır. Mutasyon olmaması durumunda, yavrular, çaprazlama sonrası doğrudan oluşturulurlar [36].

Tüm bu adımlardan sonra elde edilen bireyler, popülasyonun en iyi bireyleri olurlar. Ancak tek bir iterasyon sonucu genetik çeşitliliğin tam olarak sağlanamaması dolayısıyla, algoritmanın en iyiye ulaşması kadar tekrarlanması gerekmektedir.

3.1.4 Diferansiyel Gelişim Algoritması (DGA)

Price ve Storn (1995) tarafından geliştirilen DGA, sürekli verilerin olduğu problemlerde etkin sonuçlar verebilen bir algoritmadır [47]. Genetik algoritma tabanlı ve popülasyon temelli sezgisel bir global optimizasyon tekniği olan DGA, aynı anda birçok farklı noktada araştırma yeteneğine sahiptir. Bu sayede çözüm uzayının çok geniş olduğu durumlarda veya matematiksel yöntemlerin çok uzun zamanda çözüm bulabildiği problemlerde diğer algoritmalarla göre daha iyi sonuçlar vermektedir. Genetik algoritmadaki çaprazlama, mutasyon ve seçme operatörleri DGA tarafından da kullanılmaktadır. Fakat DGA'da GA'dan farklı olarak, değişkenler gerçek değerleriyle kullanılır ve her bir operatör tüm popülasyona uygulanır [48]. Ayrıca GA ve diğer sezgisel algoritmalar için yüzlerce satırdan oluşan kodlar söz konusu iken DGA için yaklaşık onlarla ifade edilebilen satırlık kod yeterli olmaktadır [49]. Başlangıç popülasyonu belirleme, mutasyon, çaprazlama ve karşılaştırma olmak üzere 4 temel adımdan oluşan DGA'ya ait akış şeması Şekil 3.3'te gösterilmiştir.

Çizelge 3.3 DGA Akış Şeması

-
- 1-Algoritmanın parametrelerinin belirlenmesi (maksimum jenerasyon, çaprazlama olasılık oranı, ölçekleme faktörü, popülasyon boyu gibi)
 - 2-Başlangıç popülasyonunun rastgele oluşturulması
 - 3-Her bir bireyin maliyet fonksiyonunun hesaplanması ve en iyi bireyin tespit edilerek saklanması
 - 4-Popülasyon içinden üç farklı bireyin seçilmesi ve seçilen stratejiye uygun olarak mutasyon ve çaprazlama işlemleri ile yeni popülasyonun oluşturulması
 - 5-Eski popülasyon ve yeni oluşturulan popülasyondaki bireylerin maliyet fonksiyonu değerlerine göre yeni popülasyon bireylerinin seçilmesi
 - 6-Popülasyondaki en iyi bireyin güncellenmesi
 - 7-Eğer maksimum jenerasyona ulaşılmadı ise 4. adıma gidilmesi, aksi halde aramanın sonlandırılması
 - 8-Son adımdaki en iyi bireylerin çözüm olarak kullanılması.
-

Başlangıç Popülasyonu :

DGA'ya ilk olarak başlangıç popülasyonunu belirlemekle başlanır. Probleme ait değişken sayısı (D) her bir kromozomu oluşturan gen sayısına eşittir. Kromozom sayısı (NP) her zaman 3'ten büyük olmalıdır. Çünkü DGA'da yeni kromozomların üretilmesi için mevcut kromozom dışında üç adet kromozom gerekmektedir. Başlangıçta kromozom sayısı ve değişken sayısı kadar boyutlu başlangıç popülasyonu üretilir [50].

Mutasyon :

Mutasyon ile mevcut kromozomun bir kısım genleri üzerinde rasgele deęişiklikler yapılır. Yapılan deęişiklikler ile çözüm noktası çözüm uzayında hareket eder ve oluşan birey, çözüm uzayında yeni bir çözümü göstermeye başlar. Doğru yönde doğru miktarda hareketi sağlayacak deęişikliklerin belirlenmesi, mutasyonun hedefine ulaşabilmesi için önemlidir.

Mutasyon işlemine tabi tutulacak olan kromozom dışında üç kromozom seçilir. Seçilen kromozomların ilk ikisinin farkı alınarak, fark vektörü F parametresiyle çarpılır. F parametresi genellikle $(0,2)$ aralığında deęerler almaktadır. Elde edilen ağırlıklandırılmış fark vektörü ile rastgele seçilen üçüncü vektör toplanır. Böylece, çaprazlamada kullanılacak mutasyon vektörü elde edilmiş olur. Literatürde daha farklı mutasyon operatörleri de bulunmaktadır [51].

Çaprazlama :

Çaprazlama işlemi ile genetik çeşitlilięi sağlayarak seçenek sayısını artırmak ve seçeneklerin çözüm uzayında farklı yerlerden seçilebilmesini sağlamak amaçlanır. Ayrıca mutasyon sonucu elde edilen fark kromozomu ve mevcut kromozom kullanılarak yeni nesle aday kromozom üretilir.

Karşılaştırma :

Üzerinde çalışılan kromozom ve üretilen yeni kromozomlar deęerlendirilir ve bir sonraki kusak oluşturulur. Uygunluğu yüksek olan kromozomlar, yeni neslin bireyi olarak atanır [52].

3.2 Spektral Açı Haritalayıcı (SAH)

Uyumluluk (uygunluk) fonksiyonu, bulunmaya çalışılan optimum deęere ulaşmak için önerilen matematiksel denklemdir. Bu fonksiyon metasezgisel yöntemler için çok önemli bir yer tutar. Çoęu zaman kullanılan yöntemin başarısı uyumluluk fonksiyonunun verimli ve hassas olmasına göre deęişebilmektedir. Ayrıca kullanılan yöntemlerin probleme özel çalışan tek kısmı bu fonksiyondur. Yapılan çalışmada SAH, uyumluluk fonksiyonu olarak kullanılmıştır.

SAH, iki vektör arasındaki açı deęerini ifade eder. L uzunluklu s_i ve s_j vektörleri arasındaki açı olmak üzere;

$$SAH(s_i, s_j) = \cos^{-1} \left[\frac{\sum_{l=1}^L (s_{il} * s_{jl})}{[\sum_{l=1}^L s_{il}^2]^{\frac{1}{2}} * [\sum_{l=1}^L s_{jl}^2]^{\frac{1}{2}}} \right] \quad (3.2)$$

biçiminde hesaplanır [53].

İmza bilgisine sahip olduğumuz sınıfın resim üzerindeki tüm piksellerle olan SAH değerleri hesaplanır. Küçük olan SAH değerleri çalışılan sınıfa olan yakınlığı gösterirken yüksek olan SAH değerleri sınıftan uzaklaştığını göstermektedir.

3.3 Bant Gruplama Yaklaşımı

Bu bölümde bantlar arası benzerliği ölçerek bantları gruplamak için kullanacağımız Karşılıklı Bilgi (KB), Korelasyon ve Spektral Kümeleme (SK) yöntemleri tanıtılacaktır.

3.3.1 Karşılıklı Bilgi

Olasılık ve bilgi teorisinde iki rassal değişkenin birbirine ne kadar bağlı olduğunu ölçen karşılıklı bilgi, yapay öğrenme uygulamalarında ise öznitelik vektörünün her bir boyutu ile bu öznitelik vektörüne atanan sınıf etiketleri arasında bağılılığı ölçer. KB yöntemiyle her bir özniteliğin sınıf etiketlerine karşılıklı bilgi tabanlı benzerlik oranı olağanlık çizelgesi ile hesaplanır. Ardından yüksek benzerlik oranına sahip özniteliklerden başlanarak belirli sayıda öznitelik seçimi yapılır [54].

İki ayrık rasgele değişken arasındaki KB Denklem 3.3 ile, iki sürekli değişken arasındaki KB ise Denklem 3.4 ile hesaplanır. Burada $p(x, y)$ olarak ifade edilen, X ve Y 'nin bağıl olasılık dağılım fonksiyonu, $p_1(x)$ ve $p_2(y)$ marjinal olasılık fonksiyonlarıdır.

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p_1(x)p_2(y)} \right) \quad (3.3)$$

$$I(X; Y) = \int_Y \int_X p(x, y) \log \left(\frac{p(x, y)}{p_1(x)p_2(y)} \right) dx dy \quad (3.4)$$

Eğer iki farklı durum olan X ve Y birbirleri hakkında çok az bilgi içeriyorsa, $I(X, Y)$ 0'a yakındır. İki değişkenin birbirinden bağımsız olma durumunda ise, $I(X, Y) = 0$ olacaktır. Çünkü, X ve Y birbirinden bağımsız ise, $p(x, y)$ değeri gittikçe $p_1(x) p_2(y)$ 'e yaklaşacaktır. Bu durumda Denklem 3.3 ve Denklem 3.4'e göre sonuç 0 çıkacaktır.

KB, entropi kavramıyla da ifade edilebilmektedir.


$$I(X;Y) = H(X) - H(X|Y) \quad (3.5)$$

$$= H(Y) - H(Y|X) \quad (3.6)$$

$$= H(X) + H(Y) - H(X,Y) \quad (3.7)$$

$$= H(X,Y) - H(X|Y) - H(Y,X) \quad (3.8)$$

Burada $H(X)$ ve $H(Y)$ marjinal entropi değerleridir ve değişkenin kararsızlığı hakkında bilgi verirler. $H(X|Y)$ ve $H(Y|X)$ şartlı entropidir. $H(X|Y)$ ile Y değişkeninin X hakkında bilmediklerini buluruz. $H(X,Y)$ ise bağıl entropi değeridir. $H(X|Y) + H(Y)$ ifadesi ile bulunabilir. Şekil 3.7’de marjinal entropi, şartlı entropi, bağıl entropi ve KB kümesel gösterilmiştir.



Şekil 3.7 Marjinal entropi, şartlı entropi, bağıl entropi ve KB’nin kümesel gösterimi

3.3.2 Korelasyon

Korelasyon, iki adet vektör ya da matris arasındaki ilişkiyi bulmak amacıyla kullanılır. Örneğin; matrissel ifade edilen iki resmin korelasyonu, aynı kordinatlara karşılık gelen pikseller arasındaki benzerliği olarak bulunur. İmgelere ait korelasyon katsayısı, iki imgenin en fazla benzerlik göstermesi durumunda 1 ve en fazla farklılık göstermesi durumunda ise -1 olacak şekilde hesaplanır [55]. Korelasyon katsayısı imgelere ait piksellerin benzerliği analizinde sıkça kullanılır. Denklem 3.9’da, iki imgenin korelasyon katsayı hesabı gösterilmiştir.

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\sum_{i=1}^n (x_i - \mu_x)^2} \sqrt{\sum_{i=1}^n (y_i - \mu_y)^2}} \quad (3.9)$$

3.3.3 Spektral Kümeleme

Kümeleme yöntemleri, makine öğrenmesi ve veri madenciliğinde önemli bir yer almaktadır. Kümeleme yöntemlerine göre her bir “Küme”, birbirine benzer verilerin bir arada toplandığı grup olarak düşünülebilir. Kümeleme işlemlerini yapan çok sayıda algoritma mevcuttur. *k*-Ortalamlar Yöntemi, *Affinity propagation*, *Mean-shift*, Hiyerarşik Kümeleme ve SK bunlardan birkaçıdır. Gerçekleştirilen çalışmalarda SK algoritmasının, *k*-Ortalamlar Yöntemi ve diğer kümeleme algoritmalarına göre kümeleri bulmakta daha etkili olduğu gösterilmiştir [56]. Spektral kümeleme, görüntü özvektörlerine ve ikili yakınlık matrisinden türetilen $N \times N$ boyutundaki özdeğerlere dayanmaktadır. Bu özvektörler, piksellerin düşük boyutlu alt uzaylara ayrılmasını sağlamaktadır. SK algoritmasının çalışması kısaca Çizelge 3.4’de verilmiştir

Çizelge 3.4 SK Akış Şeması

Giriş Sınıfa ait örnekler $S = \{S_1, S_2, \dots, S_n\}$, küme sayısı K .

Çıkış Hazır olan kümeler $A = \{A_1, A_2, \dots, A_K\}$.

1-Benzerlik matrisi hesapla (W).

2-Laplacian matrisi hesapla ($L = D - W$).

3-Normalize Laplacian matrisi hesapla ($L = I - D^{-1}W$).

4- L ’ye ait ilk K özvektörü hesapla ve U olarak belirt.

5- U ’ya ait satırları veri noktaları olarak seç ve *k*-Ortalamlar Yöntemi ile k kümeye ayır.


SK, daha önce yapılan çalışmalarda $m \times n$ boyutlu veri içerisindeki kümeleri bulmada kullanılmıştır [57, 58]. Yapılan çalışmada da, bantlar arası benzerlik hesabı (KB ve Korelasyon) sonucu bulunan benzerlik haritaları SK ile kümelere ayrılmıştır. SK algoritması ile boyut indirgeme başarımının dahada artırılması amaçlanmıştır.

3.4 Destek Vektör Makinaları (DVM)

Sınıflandırma, belirli özellikleri yakınlık gösteren veriler arasında ilişki kurulması işlemidir. İmge işleme alanında çeşitli istatistiki analiz yöntemleri ile beraber kullanılmaktadır. Açıklayıcıdaki dizilim ya da sıralanış genellikle desen ya da örüntü olarak adlandırılır. Sınıflandırma işlemi bu örüntülerin benzerlikleri ve farklılıklarına bağlı olarak yapılmaktadır. Genel olarak sınıflandırma yöntemleri, eğitilmiş ve eğitimsiz sınıflandırma yöntemleri olmak üzere iki başlık altında incelenebilir. Eğitilmiş sınıflandırma yöntemlerinde, sınıflandırma sürecine geçmeden önce sınıflandırma yapmak istenilen veri tabanı hakkında ön bilgi sahibi olunmalıdır. Sahip olunan bu ön bilgiler sayesinde veriler başarı ile sınıflandırılabilir [59]. Regresyon Ağaçları, Naive Bayes Metodu, DVM ve En Yakın k -Komşu Algoritması eğitilmiş sınıflandırmaya örnek olarak verilebilir. Eğitimsiz sınıflandırma yöntemlerinde ise, sınıflandırılmak istenen verilere ilişkin herhangi bir ön bilgi bulunmamaktadır. Sınıflandırma işlemi verilerin dağılımları göz önüne alınarak yapılır [60]. k -Ortalamalar Yöntemi ve Hiyerarşik Kümeleme Yöntemleri eğitimsiz sınıflandırma yöntemlerine örnek olarak verilebilir.

Vladimir Vapnik ve arkadaşları tarafından önerilen DVM sınıflandırma, regresyon ve yoğunluk tahmini gibi pek çok yaygın problemin çözümünde kullanılan güçlü bir yöntemdir [61]. DVM, karar sınırlarının belirlenmesi için karar düzlemlerinin değiştirilmesi temeline dayanır. Doğrusal olarak ayrıştırılamıyacak sınıfların çeşitli dönüşümler sonucunda doğrusal olarak ayrıştırılacak bir şekle getirilmesini amaçlar. Özellikle imge sınıflandırma problemlerinin çözümü için günümüzde oldukça sık başvurulan bir yöntem durumuna gelmiştir [62].

Sınıflandırma için bir düzlemde bulunan iki grup arasında bir sınır çizilerek iki grubu ayırmak mümkündür. Bu sınırın çizileceği yer ise iki grubun da üyelerine en uzak olan yer olmalıdır. DVM bu sınırın nasıl çizileceğini belirler. Bu işlemin yapılması için iki gruba da yakın ve birbirine paralel iki sınır çizgisi çizilir ve bu sınır çizgileri birbirine yaklaştırılarak ortak sınır çizgisi üretilir. Şekil 3.8’de birbirinden ayrılmaya çalışılan iki sınıf ve sınır çizgisi gösterilmiştir.



Şekil 3.8 DVM ile iki sınıfın ayrımı [63]

Her problem Şekil 3.8’de gösterildiği gibi doğrusal bir şekilde ayrıştırılamayabilir. DVM bu tarz problemler için çözmek için giriş uzayını doğrusal olarak ayrıştırabilecek bir özellik uzayına taşır [64]. Taşıma işlemi bazı çekirdek fonksiyonlar yardımı ile yapılır. Gauss, polinom ve radial tabanlı Gauss en çok kullanılan çekirdek fonksiyonlardır.

HİPERSPEKTRAL GÖRÜNTÜLERDE BOYUT İNDİRGEME


Bu bölümde metasezgisel algoritmalar ve bant gruplama algoritmaları, hiperspektral veri kümelerinde sınıflandırma performansını artırmaya yönelik boyut indirgeme algoritmaları olarak kullanılmışlardır. Kullanılan algoritmaların başarımları, iki farklı hiperspektral veri üzerinde yapılan deneylerle hesaplanmış ve elde edilen sonuçlar karşılaştırmaya tabi tutulmuştur. Deneylerde, Intel(R) Core(TM) i5-2400 CPU, 3.10 GHz işlemci ve 2,00 GB RAM'e sahip bir masaüstü bilgisayar kullanılmıştır.

4.1 Sezgisel Algoritmalar ile Boyut İndirgeme


Sezgisel algoritmalar ile KSC ve Çatalca02 veri setlerinde ayrı ayrı boyut indirgeme gerçekleştirilmiş ve boyut indirgemenin sınıflandırma performansına olan etkileri incelenmiştir.

4.1.1 KSC Görüntülerinde Sezgisel Algoritmalar ile Boyut İndirgeme

AVIRIS sensörleri tarafından 23 Mart 1996 tarihinde alınan bu görüntü, Amerika'nın Florida eyaletinde bulunan tarlaları içermektedir. Yaklaşık 20 km yükseklikten elde edilen veri, 18 m uzamsal çözünürlüğe sahiptir. Ayrıca görüntü, 400–2500 nm dalga boyları aralığında 10nm'lik değişimlerle alınmış toplamda 224 adet spektral bant içermektedir [65]. Veri üzerinde tanımlanmış 13 farklı sınıf bulunmaktadır. Şekil 4.1'de veriye ait görüntü ve doğrulama görüntüsü görülmektedir. Görüntü üzerinde, ışığın yansımaları ve su emilimi sırasında oluşan anlamsız bantların atılmasıyla toplamda 176 bant kullanılmıştır. KSC verisine ait görüntü ve doğrulama görüntüsü Şekil 4.1'de gösterilmiştir.



(a)



(b)

Şekil 4.1 KSC verisine ait a) doğrulama verisi b) renkli görüntü ve sınıf isimleri [65]

HSG çok geniş bir tayftan görüntüleme yaptığı için, nesnelerin ve içyapılarının kavranmasında çok yardımcı olur. Ancak, elde edilen görüntülerin klasik görüntülere göre çok daha fazla ayırt edici özellik içermesi aynı zamanda büyük bir işlem yükünü beraberinde getirmiştir [66]. Sezgisel yöntemler gibi, kısa sürede arama uzayını taramayı esas alan yöntemler ile büyük boyutlardaki hiperspektral verilerin kısa zamanda taranarak sınıfları en iyi temsil edebilecek bant kümelerinin bulunması amaçlanmıştır. Milyonlarca iterasyonla hesaplanabilecek sonuçlar sezgisel yöntemler sayesinde, düşük miktar hesaplarla elde edilebilmektedir.

Yapılan çalışmada, KSC verisine ait 13 ayrı sınıfın herbirini en iyi temsil eden spektral bantlar bulunmaya çalışıldı. Bu maksatla öncelikle her sınıfın sahip olduğu bütün piksellerin ortalamasını alarak sınıflara ait spektral imzalar çıkarıldı. Şekil 4.7’ de KSC verisindeki her sınıfa ait imza vektörleri görülmektedir.

Normal şartlarda elde edilen spektral imzalar ile sınıflandırma ve hedef tanıma gibi uygulamalar gerçekleştirilebilirken, boyut indirgeme algoritmaları ile ise hiperspektral imzayı en iyi temsil eden spektral bantlar çıkarılmakta ve yapılan uygulamalar bu bantlar üzerinden gerçekleştirilmektedir. Bu kapsamda Değişken Komşuluk Arama (DKA), Benzetilmiş Tavlama (BT), Genetik Algoritma (GA) ve Diferansiyel Gelişim Algoritması (DGA) algoritmaları ile ayrı ayrı boyut indirgeme gerçekleştirilecektir. Bu yöntemler ile boyut indirgeme işlemi gerçekleştirilirken, ilk olarak indirgemek istenilen bant sayısı belirlenmelidir. Optimum bant sayısı belirlenemediği için sırasıyla en iyi 5, 10, 20, 40 ve 60 bant bulunmuştur. Ayrıca uyumluluk fonksiyonu olarak seçilen Spektral Açık Haritalayıcı (SAH) fonksiyonunun değeri, değişen her bir komşulukta minimize edilmeye çalışılmış ve Şekil 4.7’deki orijinal imzalara en yakın bant gruplarına ulaşmaya çalışılmıştır.

4.1.1.1 DKA ile boyut indirgeme

DKA yöntemine ilk olarak rastgele bir çözüm önerisi ile başlanır ve bu rastgele çözüm en iyi çözüm olarak atanır (KSC verisi 176 banda sahip olduğu için 1 ile 176 arasındaki rastgele 5, 10, 20, 40 ya da 60 değer seçilir). Bu çözümün uyumluluk değeri hesaplanır ve kaydedilir. 2. adımda ise komşulukta bir değişikliğe gidilerek yeni oluşan çözümün uyumluluk değeri hesaplanır (Örneğin en iyi 5 bant bulma esnasında, seçili 5 banttan biri seçilmemiş olan bantlardan biri ile değiştirilir ve yeni uyumluluk değeri hesaplanır). Eğer bulunan bu değer bir önceki uyumluluk değerinden daha düşük bir değer ise bu çözüm en iyi çözüm olarak değiştirilir aksi durumda komşuluk sayısı 2 ve 3 çıkarılır ve aynı işlemler tekrar eder (Komşuluk sayısının 2 ve 3 çıkarılması değiştirilen bant sayısının 2 ve 3’e artırılması demektir). Yapılan bu işlemler belirlenen bir iterasyon sayısına ya da belirlenen bir durdurma kriterine kadar devam eder. Yapılan çalışmada her bir algoritma eşit sayıda iterasyon ile gerçekleştirilmiş ve kıyaslamalar eşit şartlarda yapılmıştır. KSC verisine ait ilk sınıfta ki DKA yöntemi ile bulunan en iyi 10 bant ve 20 bant Çizelge 4.1 ve Çizelge 4.2’ de verilmiştir.

4.1.1.2 BT ile boyut indirgeme

BT yöntemi, işleyiş açısından DKA'ya benzerde belirli farklılıkları ile DKA'dan ayrılmıştır. Daha önceden Bölüm 3.1'de bahsedildiği gibi, BT algoritmasındaki amaç sıcaklığın kontrollü bir biçimde azaltılması ile küresel en iyinin bulunmasıdır. Bu yüzden ilk olarak belirli bir başlangıç sıcaklığı ve soğutma kriteri belirlenmelidir. Bu iki kriter yöntemin iterasyon sayısını etkilediği için, bu değişkenler diğer yöntemlerin iterasyon sayısına eşit olacak şekilde seçilmiştir. Ardından DKA'da olduğu gibi rastgele bir çözüm önerisi belirlenir ve bu çözüm için uyumluluk hesaplanır. Ardından komşu bir çözüm oluşturulur ve bu komşu çözüm için uyumluluk fonksiyonu hesaplanır. Eğer bulunan komşu çözümün sonucu mevcut çözümün uyumluluk değerinden daha iyi ise komşu çözüm mevcut çözüm olarak belirlenir. Aksi durumda ise sistem soğutma formülüne göre soğutulur ve bu şekilde en iyi çözüme ulaşılmaya çalışılır.

4.1.1.3 GA ile boyut indirgeme

İçerisinde kromozom, gen, popülasyon, kodlama, çaprazlama oranı ve mutasyon oranı gibi birçok değişken barındıran GA algoritmasında ilk olarak bu değişkenlerin probleme uygun bir şekilde tanımlanması gerekir. Bizim problemimizde herbir bant gen olarak, herbir bant grubu kromozom olarak atanmıştır. Ayrıca kodlama olarak, binary kodlama yerine bantların sahip olduğu sayısal değerler kullanılmıştır. Çaprazlama ve mutasyon oranı olarak ise değişik varyasyonlar denenmiş ancak sonuca aşırı etki etmediği görüldüncede 0.1 olarak seçilmiştir. Diğer yöntemlerden farklı olarak GA' da rastgele çözümler ile başlanır ve bu çözümlerin herbiri için uyumluluk değerleri bulunur (Seçilen bu çözümlerin herbirisi kromozom olarak adlandırılır). Ardından sırasıyla çaprazlama ve mutasyon işlemleri gerçekleştirilerek tekrardan uyumluluk değeri hesaplanır. Bu işlemler belirlenen iterasyon sayısı kadar tekrar edildikten sonra ise en düşük uyumluluk değerine sahip kromozom en iyi çözüm olarak seçilir.

4.1.1.4 DGA ile boyut indirgeme

GA ile benzer bir yapıya sahip olan DGA algoritmasına da ilk olarak, değişkenlerin GA ile benzer olacak şekilde tanımlanmasıyla başlanır. Ardından ise GA'daki çaprazlama, mutasyon ve seçim operatörleri DGA'da da kullanılır. GA'dan farklı olarak her bir operatör tüm popülasyona sırayla uygulanmamaktadır. Kromozomlar tek tek ele alınmakta, rasgele seçilen diğer üç kromozomda kullanılarak yeni bir birey elde

edilmektedir. Bu işlemler sırasında mutasyon ve çaprazlama operatörleri kullanılmaktadır.

4.1.1.5 KSC Görüntülerinde Sezgisel Algoritmalar ile Boyut İndirgemeye Dayalı Sınıflandırma

Yukarıda bahsedilen yöntemler KSC verisine ait herbir sınıfa ayrı ayrı uygulanarak, herbir sınıfı temsil eden en iyi bantlar bulunmuştur. Çizelge 4.1 ve Çizelge 4.2’de örnek olması için, KSC verisine ait ilk sınıfta ki boyut indirgeme yöntemleri ile bulunan en iyi 10 bant ve 20 bant gösterilmiştir.

Çizelge 4.1 KSC verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 10 bant

Metot	En iyi bantlar
DKA	7 8 22 24 28 31 95 132 133 175
BT	6 38 132 133 134 167 168 174 175
GA	3 6 30 45 132 140 164 167 172
DGA	11 15 39 133 133 137 144 149 171

Çizelge 4.2 KSC verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 20 bant

Metot	En iyi bantlar
DKA	2 3 6 11 25 30 31 42 102 134 150 156 157 165 167 170 172 174 175 176
BT	1 2 4 16 38 132 133 135 138 159 163 166 167 168 169 170 171 172 175 176
GA	3 4 10 15 19 19 24 39 99 109 134 141 143 154 161 164 167 169 171 172
DGA	3 21 30 31 39 56 100 106 111 112 125 140 144 149 167 167 167 172 174 176

Boyut indirgeme aşamasından sonra ise sınıflandırmaya geçilmiş ve seçilmiş bantların sınıfları temsil gücü ölçülmeye çalışılmıştır. Bu maksatla Destek Vektör Makinaları (DVM) yöntemi sınıflandırma amaçlı kullanılmıştır. DVM karar sınırlarının belirlenmesi için karar düzlemlerinin değiştirilmesi temeline dayanır. Eğitici bir sınıflandırıcı olan DVM’in belirli bir örnekle eğitilmesi gerekir. Yaptığımız çalışmada, sınıflar %10 örnekle eğitime tabi tutulmuşlardır ve geriye kalan %90 oranındaki örnek

ile de test işlemi gerçekleştirilmiştir. Çizelge 4.3’de KSC verisine ait, DVM’de kullanılan eğitim ve test örnek miktarları verilmiştir.

Çizelge 4.3 KSC verisine ait sınıflar ve sınıflandırma aşamasında eğitim ve test aşamaları için kullanılan örnek miktarları

KSC		
Sınıf	Eğitim	Test
Bodur Ağaç	76	685
Söğüt Bataklığı	24	219
Lahana Palmiye	25	231
Lahana Meşe	25	227
Çizgi Çam	16	145
Geniş Yapraklı Hamak	22	207
Parke Bataklık	10	95
Graminoid bataklık	43	388
Spartina bataklık	52	468
Katail bataklık	40	364
Tuz bataklık	42	377
Çamur daireler	50	453
Su	92	835

DVM sonucunda, her bir sınıfın diğer sınıflarla olan birebir sınıflandırma skorları bulunmuştur. Çizelge 4.4’de KSC verisine ait 13 sınıfın boyut indirgeme sonrası bulunan en iyi bantları ile gerçekleştirilen sınıflandırma başarımları gösterilmiştir. Bulunan sonuçlar, sınıfları temsil eden bütün bantların sınıflandırma sonuçları ile karşılaştırılmıştır. Çizelgeden de görüleceği üzere, 1. ve 11. sınıfların en iyi 5 bant sınıflandırma başarımları bütün boyut indirgeme yöntemlerinde tam bant başarısının önüne geçmiştir. Ayrıca diğer sınıflarda da genelde 40 bantta ve bazen de 60 bantta tam bant başarısının önüne geçilmiştir. Bulunan sonuçlar, boyut indirgeme algoritmaları ile bulunan en iyi bantların sınıflandırma sonuçlarını arttırdığını göstermektedir. Çizelgede her bir sınıf için her bir yöntemin ürettiği en iyi sonuçlar kalın yazı tipi ile gösterilmiştir.


Çizelge 4.4 KSC verisine ait sınıflarda boyut indirgeme sonrası sınıflandırma doğruluğu (%)

Sınıf	Tam Bant	DKA					BT				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	94,3	94,4	95,4	97,3	97,6	97,5	94,9	96	97,7	97,4	97,3
2	97,5	82,9	95,9	98,1	98,5	98,6	72,9	89,6	97	98,4	98,5
3	98,2	75,9	91,8	96,5	98	98,7	77,9	78,8	93,6	98,3	98,7
4	96	71,2	84,4	91,7	95,2	95,9	75,8	84,4	91,5	94,9	95,9
5	97,4	77,4	85,3	95,3	96,9	97,9	77	83,9	94	97,5	97,9
6	95,9	73,4	86,5	91,9	96	96,2	78,8	84,9	93,6	96,1	96,1
7	98,9	89,2	95,2	98,5	99	99	86,4	95,1	98,6	99	98,9
8	94,3	90	92,6	96,2	97,4	97,3	89,8	94,1	96,7	97,4	97,1
9	95,8	94,6	95,2	96,1	96,7	97,4	94	95,4	96,3	96,8	97,3
10	93,4	86,9	91,9	96,2	96,9	96,5	82,9	89,7	96,7	97,1	96,4
11	93,3	99	99,1	99	98	97,3	98,9	99	98,7	98,1	97,2
12	94,6	91,6	93,9	97	98,1	97,6	90,7	93,5	97	97,7	97,4
13	99,8	89,2	93	99	99,9	99,9	84	90,2	97,9	99,9	100

Sınıf	Tam Bant	GA					DGA				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	94,3	94,3	96,8	97,3	97,9	97,7	95,3	96,9	97,4	97,7	97,6
2	97,5	78,9	95,6	98	98,1	98,5	85,7	96,2	97,7	98,1	98,5
3	98,2	77,1	83,8	97,1	97,9	98,7	77,1	94,3	97,4	98,4	98,5
4	96	74,1	87,8	91,8	94,9	95,9	80	85	92,3	95,5	96
5	97,4	84	83,2	92,2	96,6	97,4	77,5	87,3	94,7	97	97,7
6	95,9	71,4	85,8	91,6	95,7	96	77,9	88,6	92,8	94,8	96,1
7	98,9	85,3	97,6	98,3	99	99,2	87,3	95,6	98,6	98,9	99
8	94,3	90,3	92,6	95,9	97	97,3	86,6	94	96,8	97,5	97
9	95,8	93,6	94,8	95,8	97,5	98,2	93,7	94,9	96	97,3	97,6
10	93,4	87,3	94,1	96,5	98,2	97,8	84,6	93,4	97,1	97,6	97,1
11	93,3	99	98,8	99	98,8	97,8	99,3	99,4	99	98,4	97,9
12	94,6	92	94,1	97,6	97,9	98,1	90,6	94,1	97,5	97,8	97,7
13	99,8	88,8	94,4	99,9	100	100	95,1	99,2	99,8	100	100

DKA, BT, GA ve DGA'yı kendi aralarında kıyasladığımızda ise, özellikle görece düşük bant değerlerinde DGA'nın diğer algoritmalara göre daha iyi sınıflandırma başarımına ulaştığı görülmektedir. Ancak daha yüksek bant değerlerine indirgemedi ise bu

başarımlar birbirine yaklaşımaktadır. Şekil 4.2 KSC verisinde 4 yönteme ait ortalama sınıflandırma başarımları gösterilmektedir.




Şekil 4.2 KSC verisinde 4 yönteme ait ortalama sınıflandırma başarımları üzerinden performans karşılaştırması

4.1.2 Çatalca02 Görüntüsünde Sezgisel Algoritmalar ile Boyut İndirgeme

SPECIM sensörleri tarafından alınan bu görüntü, 7 Haziran 2015 tarihinde Tekirdağ'ın Çatalca eyaletinde bulunan tarlaları ve insan yapımı nesneleri içermektedir. 810×1091 pikselden oluşan görüntü, 400–1000 nm dalga boyları aralığında 3nm'lik değişimlerle alınmış toplamda 196 adet spektral bant içermektedir. Veri üzerinde tanımlanmış 8 farklı sınıf bulunmaktadır. Çatalca02 verisine ait görüntü ve doğrulama görüntüsü Şekil 4.3'de gösterilmiştir.



(a)



(b)

Şekil 4.3 Çatalca02 verisine ait a) Renkli görüntü b) Doğrulama görüntüsü

Yapılan çalışmada, Çatalca02 verisine ait 8 ayrı sınıfın herbirini en iyi temsil eden spektral bantlar bulunmaya çalışıldı. Bu amaçla öncelikle her sınıfın sahip olduğu bütün piksellerin ortalamasını alarak sınıflara ait spektral imzalar çıkarıldı. Şekil 4.8’de Çatalca02 verisindeki her sınıfa ait imza vektörleri görülmektedir.

Bölüm 4.1.1’ de, çalışmada kullanılan yöntemlerin probleme uygulanışı ayrıntılı olarak anlatıldığı için bu bölümde bu kısım tekrardan anlatılmayacaktır. KSC verisi 196 banda sahip iken Çatalca02 verisi ise 176 banda sahiptir. Geriye kalan bütün işlem basamakları aynıdır. Çizelge 4.5 ve Çizelge 4.6’ da örnek olması için, Çatalca02 verisine ait ilk sınıfta ki boyut indirgeme yöntemleri ile bulunan en iyi 10 bant ve 20 bant gösterilmiştir.

Çizelge 4.5 Çatalca02 verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 10 bant

Metot	En iyi 10 bant
DKA	44 63 79 84 91 93 94 95 96 101
BT	21 49 71 78 105 111 162 163 177 193
GA	1 9 34 45 66 173 174 175 178 181
DGA	18 34 36 68 77 175 178 180 186 188

Çizelge 4.6 KSC verisine ait ilk sınıfta boyut indirgeme yöntemleri ile bulunan en iyi 20 bant

Metot	En iyi bantlar																			
DKA	50	62	65	83	85	91	93	94	95	96	98	99	100	101	102	103	104	105	106	107
BT	18	19	45	64	83	92	98	103	116	119	124	148	149	155	166	172	176	186	189	196
GA	7	17	26	28	29	33	39	47	65	68	69	73	172	174	175	176	179	181	189	195
DGA	8	12	18	19	32	48	63	64	86	97	100	152	174	175	176	178	179	182	190	196

Çatalca02 verisine ait en iyi 5, 10, 20, 40 ve 60 bant değerleri yukarıda bahsi geçen 4 algoritma ile bulunmuştur. Ardından ise bulunan sonuçların sınıflama başarımına etkisini ölçmek için DVM ile sınıflandırmaya gidilmiştir. Sınıflar %10 örnekle eğitime tabi tutulmuşlardır ve geriye kalan %90 oranındaki örnek ile de test işlemi gerçekleştirilmiştir. Çizelge 4.7’de Çatalca02 verisine ait, DVM’de kullanılan eğitim ve test örnek miktarları verilmiştir.

Çizelge 4.7 Çatalca02 verisine ait sınıflar ve sınıflandırma aşamasında eğitim ve test aşamaları için kullanılan örnek miktarları

Çatalca02			
Sınıf Numarası	Sınıf İsmi	Eğitim	Test
1	Buğday samanı	6768	60920
2	Araçlar	49	445
3	Biçilmemiş buğday tarlası	413	3726
4	Toplanmış buğday başağı	333	3002
5	Yaş çalı	451	4066
6	Kuru Çalı	6421	57789
7	Yeşil ayçiçeği	4648	41833
8	Buğday balyası	3867	34806

DVM sonucunda her bir sınıfın diğer sınıflarla olan birebir sınıflandırma skorları bulunmuştur. Çizelge 4.8’de Çatalca02 verisine ait 8 sınıfın boyut indirgeme sonrası bulunan en iyi bantları ile gerçekleştirilen sınıflandırma başarımları gösterilmiştir.


Bulunan sonuçlar, sınıfları temsil eden bütün bantların sınıflandırma sonuçları ile karşılaştırılmıştır. Çizelge 4.8’de Çatalca02 verisine ait sınıflarda boyut indirgeme sonrası sınıflandırma başarıları gösterilmiştir.

Çizelge 4.8 Çatalca02 verisine ait sınıflarda boyut indirgeme sonrası sınıflandırma doğruluğu (%)

Sınıf	Tam Bant	DKA					BT				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	70,5	77,7	80,6	83,5	87,4	81,2	81,9	84,8	86,1	84,3	80,4
2	99,8	99,1	99,4	99,8	99,8	99,8	99,7	99,8	99,8	99,8	99,8
3	98,2	83	93,7	98,9	99,4	99,5	95,7	98,8	99,7	99	98,4
4	98,5	75,6	81,5	94	98,3	98,9	91	97	98,7	98,7	98,6
5	98	92	94,1	97,2	99,1	99,3	95,2	98,2	99	98,4	98,1
6	72	96,9	98,4	98,7	99,1	98,9	94,2	98,3	98,5	94,2	80,8
7	79,8	93,6	96,9	98,5	97,5	93,6	97,1	98,3	97	92,6	85,4
8	83,2	74,7	76,6	80	84,9	88,4	77	80,6	84,7	87,6	87,3

Sınıf	Tam Bant	GA					DGA				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	70,5	69,9	82,3	83,2	82,5	78,1	80,2	83,8	84,1	74,7	71
2	99,8	99,8	99,8	99,8	99,8	99,8	99,2	99,8	99,8	99,8	99,8
3	98,2	92,5	99,1	98,8	98,8	98,3	97	99,3	98,9	98,3	98,2
4	98,5	93,4	98,3	98,6	98,6	98,6	93,9	97,8	98,7	98,6	98,5
5	98	94,7	98,6	98,5	98,2	98,1	96,7	98,4	98,4	98,1	98
6	72	89,1	95,8	93,3	92	83,5	91,3	97,2	96,7	83,7	73,4
7	79,8	98,9	99,3	98,4	92,9	83	98,8	99,3	98	91,2	83,7
8	83,2	69,1	81,5	85,2	86,6	85,1	74,4	82,2	85,9	84,4	83,4

Çizelge 4.8 ve Şekil 4.4’den da görüleceği üzere, 1, 2, 6 ve 7. sınıfların en iyi 5 bant sınıflandırma başarıları, bütün boyut indirgeme yöntemlerinde tam bant başarısının önüne geçmiştir. Sınıflandırmadaki bu başarı 10 ve 20 bantta indirgemedede de görülmektedir. Ancak 40 ve 60 banttaki sınıflandırma kabiliyetlerinde DKA haricindeki boyut indirgeme yöntemlerinde büyük bir düşüş gözlenmektedir. Bu düşüş bir taraftan DKA’nın sınırlı sayıda iterasyonda diğer yöntemlere göre daha çabuk yansıdığını gösterirken, diğer taraftan yüksek miktarlardaki bilginin her zaman başarımı arttırmadığını hatta azaltabildiğini de göstermektedir.




Şekil 4.4 Çatalca02 verisinde 4 yönteme ait ortalama sınıflandırma başarımları üzerinden performans karşılaştırması


4.2 Sezgisel Algoritmalar ile Bant Gruplama Tabanlı Boyut İndirgeme

Gruplama (kümeleme) yöntemleri, makine öğrenmesi ve veri madenciliğinde önemli bir yer tutmaktadır. Gruplama yöntemlerine göre her bir “Grup”, birbirine benzer verilerin bir arada toplandığı küme olarak düşünülebilir. Kümeleme işlemlerini yapan çok sayıda algoritma mevcuttur. *Affinity Propagation*, *k*-Ortalamlar Yöntemi, *Mean-shift*, Hiyerarşik Kümeleme ve Spektral Kümeleme (SK) bunlardan birkaçıdır. Gerçekleştirilen çalışmada ise, Karşılıklı Bilgi (KB), Korelasyon ve SK algoritmaları bant gruplama amaçlı kullanılmıştır.

İlk olarak, hiperspektral veriye ait tüm bantlar arasındaki korelasyon miktarı hesaplanmıştır. Şekil 4.5’de kullanılan verilere ait, bantlar arası korelasyon miktarlarını gösteren haritalar verilmiştir. Yüksek korelasyonun yüksek benzerlik manasına gelmesinden dolayı, aralarında yüksek korelasyona sahip bant grupları aynı grup içerisine alınmıştır.




(a)




(b)

Şekil 4.5 a) KSC b) Çatalca02 verisinde bantlar arası Korelasyon

Korelasyon gibi bir benzerlik ölçütü olan KB ile ise, ardışıl bantlar arasındaki benzerlik miktarı ölçülmüştür. Korelasyon yaklaşımına benzeyen bu yaklaşımda ise, ard arda gelen bantlarda ki global minimumlar yakalandı. Çünkü bu global minimum noktaları büyük bir değişimin göstergesidir ve bu noktalarada ardışıl iki bant arasındaki benzerlik minimuma inmiştir. Şekil 4.6'da kullanılan verilere ait ardışıl bantlar arası KB miktarlarına bağlı oluşan grafikleri göstermektedir. Bu grafiklerden birincisinden istediğimiz bilgilere ulaşip gruplamaya gidebilirken ikinci grafikten ise gruplamayı gerçekleştirebilecek bilgiye ulaşılammıştır. Bu yüzden Çatalca02 verisi, yalnızca Şekil 4.5(b)'deki bilgiler ışığında gruplamaya tabi tutulmuştur.



(a)




(b)

Şekil 4.6 a) KSC b) Çatalca02 verisinde ardışık bantlar arası KB

Yapılan çalışmada, Korelasyon ile yapılan gruptama sonuçları ile KB ile yapılan gruptama sonuçları birbirinin aynısı olmuştur. Bu sonuçlara göre KSC verisinde bantlar 4 ayrı gruba, Çatalca02 versinde ise 2 ayrı gruba bölünmüşlerdir. Ayrıca her grubun sahip olmuş olduğu bant miktarına göre bir seçim kriteri belirlenmiştir. Çizelge 4.9 ve Çizelge 4.10'da kullanılan verilere ait bant gruptama sonuçları ve bu gruptardan eleman seçiminde kullanılacak seçim olasılığı gösterilmiştir. Şekil 4.7 ve Şekil 4.8'de ise, kullanılan verilere ait imzaların bant gruptama ile bölünmeleri ve oluşan yeni gruplar gösterilmiştir.

Çizelge 4.9 KSC verisinde bant gruplama ve seçim olasılığı


Grup Numarası	1	2	3	4
Bant aralığı	1 - 32	33 - 97	98 - 131	132 - 176
Toplam bant	32	65	33	45
Seçim olasılığı	$\frac{32}{176}$	$\frac{65}{176}$	$\frac{33}{176}$	$\frac{45}{176}$



Şekil 4.7 KSC verisine ait imzalar ve gruplama sonucu

Çizelge 4.10 Çatalca02 verisinde bant gruplama ve seçim olasılığı

Grup Numarası	1	2
Bant aralığı	1 - 105	106 - 196
Toplam bant	105	91
Seçim olasılığı	$\frac{105}{196}$	$\frac{91}{196}$



Şekil 4.8 Çatalca02 verisine ait imzalar ve gruplama sonucu

4.2.1 KSC Görüntülerinde Sezgisel Algoritmalar ile Bant Gruplama Tabanlı Boyut İndirgeme

Şekil 4.7’den de görüleceği üzere KSC verisi 4 ayrı gruba ayrılmıştır. Bir önceki bölümde bütün veri üzerinden gerçekleştirilen sezgisel bant seçim işlemi, bu bölümde ise bant grupları üzerinden gerçekleştirilmektedir. Kısacası, verinin tamamının değil de veriye ait grupların en iyi bantları bulunmaya çalışılmıştır. Bu aşamada da bir önceki aşamadaki gibi veriyi en iyi temsil eden 5, 10, 20, 40 ve 60 bant değerleri bulunmaya çalışılmıştır. Çizelge 4.11 ve Çizelge 4.12’de KSC verisine ait ilk sınıfta, gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 10 bant ve 20 bant gösterilmiştir. Bu bant değerleri tamamen birbirinin aynısı değildir, fakat veriyi temsil bakımından birbirlerine yakın başarımlar göstermektedirler.

Çizelge 4.11 KSC verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 10 bant

Metot	En iyi 10 bant
DKA	6 12 34 39 47 65 108 122 150 153
BT	16 27 34 39 42 96 98 112 135 170
GA	11 21 34 40 42 92 102 130 153 160
DGA	2 9 34 35 39 42 112 116 169 176

Çizelge 4.12 KSC verisine ait ilk sınıfta grupta tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 20 bant

Metot	En iyi bantlar
DKA	2 7 21 28 33 36 44 54 55 66 81 87 99 112 123 129 133 134 146 149
BT	13 16 25 26 33 36 39 44 47 58 69 93 101 113 115 116 132 143 154 167
GA	16 21 28 32 33 34 43 47 53 70 91 97 101 108 115 120 135 147 171 176
DGA	2 6 25 26 33 34 35 38 39 48 73 87 101 107 126 129 132 134 152 174

4 farklı yöntem ile ayrı ayrı bulunan bantlar kullanılarak, her bir sınıfın diğer sınıflarla olan birebir DVM skorları bulunmuştur. Çizelge 4.13’de KSC verisine ait 13 sınıfın grupta tabanlı boyut indirgeme sonrası bulunan en iyi bantları ile gerçekleştirilen DVM başarımları gösterilmiş ve bulunan sonuçlar birbirleriyle ve sınıfları temsil eden bütün bantların sınıflandırma sonuçları ile karşılaştırılmıştır. Çizelgeden de görüleceği üzere, 1, 2, 10, 11 ve 13. sınıfların en iyi 5 bantları kullanılarak bile veriyi temsili sağlanabileceği ispatlanmaktadır. Ayrıca diğer sınıflarda da kimi zaman 10 kimi zaman ise 20 bant ile tam bant ile elde edilen sınıflandırma başarısının üzerine çıkmıştır. Bulunan sonuçları Çizelge 4.4 ile de kıyasladığımızda ise, grupta tabanlı boyut indirgemenin KSC verisinde sınıflandırma başarımında belirgin bir artış sağladığı görülmüştür. Özellikle düşük sayıdaki bant sayılarına indirgeme de bu artış daha iyi görülebilmektedir.

Çizelge 4.13 KSC verisine ait sınıflarda bant gruplama tabanlı boyut indirgeme sonrası sınıflandırma doğruluğu (%)

Sınıf	Tam Bant	Gruplama+DKA					Gruplama+BT				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	94,3	96,5	96,7	97,8	97,9	97,6	96,6	97,6	97,5	97,6	97,7
2	97,5	97,8	97,7	97,9	98,2	98,4	96,3	97,5	98	98,7	98,4
3	98,2	94,2	96,1	97,4	98	98,7	93,1	96,2	96,9	98,3	98,6
4	96	85,7	88,9	93,1	95	95,6	84,7	88,7	92,5	94,9	95,6
5	97,4	88,1	90,1	95,2	96,9	98	85,7	92	95,2	96,8	97,4
6	95,9	80,9	89,3	91,9	95,1	95,9	82,2	88,9	90,2	95,2	95,6
7	98,9	95,8	98	98,8	98,8	99	97,3	98	98,6	99,1	99
8	94,3	85,3	91,2	95,5	97,3	97,9	85	94,3	95,4	97,6	98
9	95,8	93,8	95,6	96,6	98,1	98,5	93,8	95,2	96,6	97,9	98,5
10	93,4	93,9	97,2	98,4	98,6	97,7	92,8	97	98	98,1	97,9
11	93,3	99,2	99,4	99,3	98,6	98,1	99,3	99,4	99,1	98,7	98
12	94,6	91,8	95,7	98	98,2	98,2	92	93,2	96,8	98,5	98,2
13	99,8	99,5	99,8	100	100	99,9	99,7	99,9	100	100	99,9

Sınıf	Tam Bant	Gruplama+GA					Gruplama+DGA				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	94,3	96,7	97	98	97,8	97,7	96,7	97,2	97,7	98	98
2	97,5	96,9	98,1	98,4	98,7	98,4	97,6	97,9	98	98,4	98,5
3	98,2	94,6	95,6	97,6	97,9	98,7	93,6	95,8	97,7	98,5	98,5
4	96	85,6	87,5	91,9	94,8	95,7	84,3	89,2	92,5	95,1	96,2
5	97,4	86,9	93	94,4	96,6	97,4	88,6	90,8	95,4	96,6	97,9
6	95,9	83,5	87,5	92,1	95,7	96,4	82,5	88,5	93,4	94,7	96,5
7	98,9	96,6	98,4	98,8	99	99,1	97,3	98,3	98,6	99	99,1
8	94,3	83,5	92,8	96,4	97,1	97,7	86,6	92,5	96	97,7	97,9
9	95,8	94	94,8	96,8	98,1	98,4	94,6	95,4	97,2	98,2	98,5
10	93,4	92,5	97,2	98	98,5	97,7	91,8	95,9	97,5	98,2	98,5
11	93,3	99,3	99,4	99,3	98,7	98,1	99,3	99,3	99,1	98,8	98,9
12	94,6	91,9	94,4	97,1	98,1	98,2	90,5	93,6	98,3	98,2	98,7
13	99,8	99,3	99,8	100	100	100	98,7	99,8	99,9	100	100

4.2.2 Çatalca02 Görüntüsünde Sezgisel Algoritmalar ile Bant Gruplama Tabanlı Boyut İndirgeme

Çizelge 4.10’da bant aralığı ile seçim olasılığı verilen Çatalca02 verisi, Şekil 4.8’den de görüleceği üzere 2 ayrı gruba ayrılmıştır. Ardından gerçekleştirilen bant seçim işlemleri ile elde edilen bantlar, Çizelge 4.14 ve Çizelge 4.15’te gösterilmiştir.

Çizelge 4.14 Çatalca02 verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 10 bant

Metot	En iyi 10 bant
DKA	2 16 59 87 98 173 174 180 185 195
BT	10 23 26 46 62 109 165 179 191 195
GA	2 41 58 89 96 111 150 178 182 196
DGA	1 20 23 62 69 86 178 178 181 195

Çizelge 4.15 Çatalca02 verisine ait ilk sınıfta gruplama tabanlı boyut indirgeme yöntemleri ile bulunan en iyi 20 bant

Metot	En iyi bantlar
DKA	2 4 5 12 21 25 44 54 77 78 111 112 128 163 174 180 182 189 190 192
BT	15 19 36 40 42 62 64 70 79 95 139 142 144 166 169 178 185 186 188 192
GA	1 11 15 23 32 34 38 64 68 96 110 171 174 180 181 181 189 191 191 193
DGA	9 12 18 19 32 48 63 64 86 97 105 142 174 175 176 178 179 182 190 195

Son aşama olarak gerçekleştirilen sınıflandırma işlemi sonuçları Çizelge 4.16’da gösterilmiştir. Bu sonuçlara göre DKA yöntemi diğer 3 yönteme göre daha iyi sonuçlar vermiştir. Ayrıca 1, 6 ve 7. sınıfların 20 bant sonrası düşen sınıflama performansları da boyut indirgemenin lüzumunu ortaya çıkarmıştır.

Çizelge 4.16 Çatalca02 verisine ait sınıflarda bant gruplama tabanlı boyut indirgeme sonrası sınıflandırma doğruluğu (%)

Sınıf	Tam Bant	Gruplama+DKA					Gruplama+BT				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	70,5	82,3	83,7	88	86,1	84	80,7	83,2	85,9	82,9	80
2	99,8	99,8	99,8	99,8	99,8	99,8	99,8	99,8	99,8	99,8	99,8
3	98,2	99	99,3	99,3	98,6	98,2	98,2	99,3	99,4	98,7	98,5
4	98,5	93,2	97,3	98,7	98,6	98,5	92,1	97,5	98,7	98,6	98,6
5	98	97,1	98,8	98,7	98,1	98	96,4	98,7	98,8	98,2	98
6	72	96,6	97,5	99	88,8	76,8	93,6	96,8	97,6	87,9	76,1
7	79,8	98,9	99,1	98,6	86,3	94,7	98,3	99,2	96,8	90,5	87,9
8	83,2	77,4	81,6	85,5	86,3	89,6	77,6	80,5	84,7	86,6	88

Sınıf	Tam Bant	Gruplama+GA					Gruplama+DGA				
		Bant Sayısı					Bant Sayısı				
		5	10	20	40	60	5	10	20	40	60
1	70,5	80,8	83,4	84,7	83,4	79,7	81,6	83,8	82,3	80	77
2	99,8	99,8	99,8	99,8	99,8	99,8	99,6	99,8	99,8	99,8	99,7
3	98,2	99	99,4	99,1	98,6	98,2	97,1	99,5	99,1	98,6	97,9
4	98,5	94,7	98	98,6	98,6	98,6	91,5	97,5	98,3	98,7	98,8
5	98	97,8	98,7	98,6	98,4	98,1	95,8	98,7	98,7	99,1	98,2
6	72	95,8	97,4	97	93,7	74,6	90,9	97,3	97,5	84,3	73,6
7	79,8	96,8	98,9	96,9	89,4	84,4	98,6	99,2	98,9	91,8	86,7
8	83,2	79,5	81,9	85,1	87,2	88	74,1	80,1	82,4	84,1	84,5

Bant gruplama yaklaşımı, sınıflama performansına katkısının yanında işlem hızına da katkıda bulunmaktadır. Çizelge 4.17’de verilen verilere göre 4 ayrı sezgisel algoritmanın işlem süresi gruplama yaklaşımı ile düşmüştür. Ayrıca kullanılan yöntemlerden DKA, yüksek hızı ile diğer yöntemleri geride bırakmıştır. DGA ve GA’nın yapısında bulunan çaprazlama ve mutasyon işlemleri ile BT’de bulunmayan komşuluk değiştirme adımı DKA’yı diğer yöntemlere göre hızlı kılmıştır.


Çizelge 4.17 KSC verisi üzerinde, kullanılan yöntemlere ait işlem süreleri (sn) kıyaslaması

Metotlar		Bant Sayısı				
		5	10	20	40	60
	GA	182.60	161.34	153.18	145.92	137.24
	DGA	92.80	88.28	84.76	75.02	68.32
	BT	65.76	67.22	68.96	70.52	72.13
	DKA	37.52	41.72	53.37	58.44	66.01
Gruplama +	GA	171.73	156.78	147.89	140.13	136.67
	DGA	88.73	79.06	74.33	66.91	60.41
	BT	39.94	41.38	42.40	43.34	43.56
	DKA	32.37	34.45	35.78	36.62	37.74

Çizelge 4.18’de ise gruplama amaçlı kullanılan Korelasyon ve KB yöntemlerinin hesaplama sürelerine ait bilgiler verilmiştir. Veriye ait bantlar arası ilişkiyi bulmamıza yarayan bu yöntemlerden Korelasyon, yüksek hızı ile KB’ye göre daha kullanışlı bir yöntem olarak karşımıza çıkmaktadır.

Çizelge 4.18 Korelasyon ve KB işlemlerinin hesaplama süreleri (sn) kıyaslaması


Veri	Metot	
	Korelasyon	KB
KSC	265.69	854.66
Çatalca02	1228.81	16440.34



Şekil 4.9 KSC verisi üzerinde, DKA ve gruplama tabanlı DKA yöntemlerinin sınıflandırma başarıımı üzerinden performans kıyaslaması

4.3 Sezgisel Algoritmalar ile Spektral Külemeye Dayalı Bant Gruplama Tabanlı Boyut İndirgeme

Bölüm 4.2’de gruplama, görsel olarak yorumlama yapabildiğimiz tüm bantlar arası Korelasyon ya da ardışık bantlar arası KB ile oluşturulmuştu. Görsel olarak gerçekleştirilen gruplardaki bireyler ardışık bant değerlerinden oluşmaktaydı. Bu kısımda ise görsel olarak yorumda bulunmakta zorlandığımız tüm bantlar arası KB değerlerinin, Spektral Kümeleme (SK) yöntemiyle gruplanması ve ardından boyut indirgeme işleminin bu gruplar üzerinden gerçekleştirilmesi amaçlanmıştır. Şekil 4.10’da kullanılan iki farklı veriye ait, bantlar arası KB miktarlarını gösteren haritalar verilmiştir.



Şekil 4.10 a) KSC verisinde b) Çatalca02 verisinde, bantlar arası KB

Şekil 4.10’da görülen ve verilerdeki bantlar arası benzerlik ile ilgili bilgiye ulaşmak istediğimiz şekillerin, görsel olarak yorumlanması oldukça zordur. Bu nedenle üstteki iki benzerlik haritası, SK Algoritması ile gruplamaya tabi tutulmuştur. SK, görüntü özvektörlerine ve ikili yakınlık matrisinden türetilen $N \times N$ boyutundaki özdeğerlere dayanmaktadır. Bu özvektörler, piksellerin düşük boyutlu alt uzaylara (gruplara) ayrılmasını sağlamaktadır. Ancak bu alt uzayların (grupların) sayısı belirtilmek zorundadır. Bu sebeple verilerdeki bantların kaç gruba ayrılacağı bilgisi Çizelge 4.9 ve Çizelge 4.10’dan alınmıştır.

Çizelge 4.19 KSC verisinde SK ile elde edilen gruplar

Grup 1	2 5 12 13 16 21 26 34 36 41 43 47 55 56 57 60 63 64 65 66 77 83 84 85 86 87 88 90 91 92 94 96 97 100 101 106 107 109 110 115 119 125 128 130 156
Grup 2	1 23 30 32 33 54 93 98 103 104 105 113 114 116 118 120 122 123 124 126 129 132 135 136 137 138 139 140 141 142 146 147 149 150 153 154 155 159 161 165 166 168 169 170 171 173 174 175 176
Grup 3	4 6 7 8 9 14 15 18 20 22 24 25 27 29 31 35 37 39 42 44 45 46 49 50 52 53 59 68 70 75 76 78 80 82 95 99 102 108 111 112 117 121 127 131 133 134 143 144 145 148 151 152 157 158 160 162 163 164 167 172
Grup 4	3 10 11 17 19 28 38 40 48 51 58 61 62 67 69 71 72 73 74 79 81 89

Çizelge 4.20 Çatalca02 verisinde SK ile elde edilen gruplar

Grup 1	4 5 17 19 21 22 32 33 36 39 49 53 54 58 61 62 63 66 68 69 70 73 75 79 82 91 92 93 95 96 97 98 99 103 107 108 109 111 113 114 115 116 117 118 119 120 121 122 123 124 126 127 128 129 130 131 132 133 134 135 136 137 138 139 140 141 142 143 144 145 146 147 148 149 150 151 152 153 155 156 157 158 159 160 161 162 163 164 165 166 167 168 169 170 171 172 173 176 177 178 179 180 182 183 184 185 186 187 188 189 190 191 192 193 194 195 196
Grup 2	1 2 3 6 7 8 9 10 11 12 13 14 15 16 18 20 23 24 25 26 27 28 29 30 31 34 35 37 38 40 41 42 43 44 45 46 47 48 50 51 52 55 56 57 59 60 64 65 67 71 72 74 76 77 78 80 81 83 84 85 86 87 88 89 90 94 100 101 102 104 105 106 110 112 125 154 174 175 181

Çizelge 4.19 ve Çizelge 4.20’de iki verinin SK sonucu elde edilen grupları görülmektedir. Bu gruplara ulaşılmasının ardından ise DKA yöntemiyle boyut indirgemeye geçilmiştir. Boyut indirgeme aşamasında verilerdeki her sınıfın ayrı ayrı en iyi bantlarını bulmak yerine bütün veriyi en iyi temsil eden bantları bulmak amaçlandı. Bant indirgeme sonucu hem KSC hem de Çatalca02 verisini en iyi ifade eden 5, 10, 20, 40 ve 60 bant bulunmuştur. Sınıflandırma aşamasında ise Bölüm 4.1 ve Bölüm 4.2’nin aksine iki gruplu DVM yerine çok sınıflı DVM kullanılmıştır. Çizelge 4.21 ve Çizelge 4.22’de çeşitli bant değerlerine göre bulunan çok sınıflı DVM sonuçları gösterilmektedir.

Çizelge 4.21 KSC verisi için bulunan çok sınıflı DVM doğruluk sonuçları


Metot	Tam Bant	5	10	20	40	60
DKA		76,33	79,71	88,23	92,59	94,33
Ardışıl	95,63	88,10	93,05	94,66	94,87	95,50
Gruplama+DKA						
SK gruplama+DKA		79,94	89,79	94,78	95,64	95,58

Çizelge 4.22 Çatalca02 verisi için bulunan çok sınıflı DVM doğruluk sonuçları


Metot	Tam Bant	5	10	20	40	60
DKA		83,80	92,16	97,88	98,69	99,13
Ardışıl						
Gruplama+DKA	99,59	90,30	96,43	98,21	98,79	99,33
SK gruplama+DKA		91,51	91,58	98,91	99,22	99,42

Çizelge 4.21 ve Çizelge 4.22’de ki sonuçlara bakıldığında özellikle 5 ve 10 bant değerlerinde Ardışıl Gruplama tabanlı DKA yönteminin diğer iki yöntemden daha iyi sonuçlar verdiği görülmektedir. 20, 40 ve 60 bant değerlerinde ise başarımların birbirine yakın olduğu ancak Spektral Kümelemeye dayalı gruplama tabanlı DKA yönteminin diğer iki yöntemden çok az da olsa daha iyi sonuçlar verdiği görülmektedir.


Şekil 4.11, Şekil 4.12 ve Şekil 4.13’te KSC verisi üzerinde DKA, Gruplama tabanlı DKA ve Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 5, 20 ve 60 banda ait doğrulama haritaları görülmektedir. Verideki indekslenmiş verilerin miktarının çok düşük olması sebebiyle görsel olarak yorumda bulunmak oldukça zor olmasına karşın özellikle 20 ve 60 bant değerlerinde 5 banda göre daha yüksek sınıflama isabeti görülmektedir.



(a)




(b)




(c)


Şekil 4.11 KSC verisi üzerinde a) DKA b) Gruplama tabanlı DKA c) Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 5 banda ait doğrulama haritası



(a)




(b)




(c)


Şekil 4.12 KSC verisi üzerinde a) DKA b) Gruplama tabanlı DKA c) Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 20 banda ait doğrulama haritası



(a)



(b)



(c)

Şekil 4.13 KSC verisi üzerinde a) DKA b) Gruplama tabanlı DKA c) Spektral Kümelemeye dayalı DKA ile elde edilen en iyi 60 banda ait doğrulama haritası

Çizelge 4.23 KSC verisi üzerinde farklı bant değerlerinde ki çok sınıflı DVM süreleri
(sn) kıyaslaması

Bant Sayısı					
5	10	20	40	60	176
25.78	28.93	39.67	57.29	74.85	183.98

KSC verisi üzerinde farklı bant değerlerinde ki çok sınıflı DVM süreleri Çizelge 4.23'te verilmiştir. Veriyi 176 bant yerine 5 bant ile temsil edebilmemiz durumunda sınıflandırma işlem süresini 1/7'e düşürmüş oluyoruz. 176 bandı diğer bant değerlerine indirgediğimizde de işlem sürelerinin kısaldığı ve boyut indirgemenin işlem hızına olan katkısı irdelenmiştir.

BÖLÜM 5

SONUÇ VE ÖNERİLER

Bu çalışmada hiperspektral görüntülerde sınıflandırma başarımını arttırmak için Sezgisel Yöntemler tabanlı boyut indirgeme yöntemleri önerilmiştir. Karşılıklı Bilgi, Korelasyon Spektral Kümeleme yaklaşımlarının ise hiperspektral görüntülerde bantlar arası benzerlik tespiti amaçlı kullanılabilirliği incelenmiştir.

Hiperspektral görüntüler üzerinde, 4 farklı Sezgisel Yöntem ile bant seçme işlemi gerçekleştirilmiştir. Seçilen en iyi bantların veriyi temsil gücünü ölçmek için DVM kullanılmıştır. Kullanılan KSC verisinde özellikle görece düşük bant değerlerinde DGA'nın daha başarılı olduğu ancak 40 ve 60 bant gibi görece yüksek bantlara indirgemedede ise 4 yönteminde başarımlarının birbirine benzer olduğu görülmüştür. Çatalca02 verisinde ise DKA yönteminin diğer yöntemlere göre daha başarılı olduğu görülmüştür. Sınıflama başarımları sınıf bazında değerlendirildiğinde ise, özellikle KSC veri setinin 1, 9 ve 11 nolu sınıflarında ve Çatalca02 veri setinin 1, 2, 6 ve 7 nolu sınıflarında tam bant ile gerçekleştirilen sınıflandırma başarımına 5 bant ile dahi ulaşılabilirdiği ve hatta bu başarımın geçildiği görülmüştür. Ayrıca düşük bant değerleri ile gerçekleştirilen sınıflandırma işlemlerinde sınıflandırma işlem hızının da arttığı görülmüş ve böylelikle boyut indirgemenin işlem hızına olan katkısı irdelenmiştir.

Bant gruplama tabanlı boyut indirgeme ile ise, hem daha yüksek sınıflandırma başarımı hem de daha yüksek hız hedeflenmiştir. Bantlar arası benzerliğe dayalı gruplama hem Karşılıklı Bilgi hem Korelasyon hem de Spektral Kümeleme ile gerçekleştirilmiş ve ardından aynı sezgisel yöntemler ile bant seçimi gerçekleştirilmiştir. Kullanılan 4 sezgisel yöntem ile bulunan en iyi bantların sınıflandırma başarımında, özellikle görece düşük bant değerleri için bir yükseliş hesaplanmıştır. Ayrıca gruplama tabanlı boyut indirgeme yöntemlerinin işlem hızlarının normal boyut indirgemeye göre daha yüksek

olması da gruplama tabanlı boyut indirgemenin, bundan sonraki çalışmalarda tercih sebebi olabileceğini göstermektedir.

Tüm bu bilgiler ışığında, Sezgisel Algoritmaların HSG üzerinde boyut indirgeme problemi için tercih edilebilir olduğu görülmektedir. Gruplama için kullanılan Karşılıklı Bilgi ve Korelasyon yöntemleri de hem hesap maliyetinin düşük olması hem de görece düşük bantlarda daha elverişli olması avantajıyla hiperspektral görüntü sınıflandırma alanında tercih edilebileceği görülmektedir.

Yapılan çalışmada yukarıda değinilen sonuçlar elde edilmiştir. Çalışma sonrasında ileriye dönük üzerinde çalışılabilecek yeni konuların da ortaya çıktığı görülmüştür.

HSG üzerinde spektral bantların seçim yöntemini değiştirmek ve güçlü bir bant seçim yöntemi kullanmak sınıflandırma performansına etki eden önemli bir işlemdir. Bölüm 2’de değinildiği gibi HSG’de her bir piksel için yüzlerce eleman bulunmaktadır. Ancak bu bantların bir kısmı anlamlı bilgi içermemektedir. Anlamlı bilgi içermeyen bu bantların sayısında azaltmaya gitmek, sonrasında kullanılacak tespit ve tanıma algoritmalarının performansını daha da artıracaktır. Bunun yanında işlem yükü de azalacak ve bu sayede çalışma zamanında da belirgin bir düşüş gözlenecektir. Bu nedenlerden dolayı daha iyi bir bant seçim yöntemi kullanmak ya da bu çalışmada kullanılan algoritmalarından yeni hibrit bir algoritma oluşturmak yerinde bir devam çalışması olarak gözükmemektedir.

Bu tez kapsamında, kullanılan sezgisel algoritmaların uyumluluk fonksiyonları üzerinde durulmamıştır. Ayrıca, sınıflandırma problemine büyük katkısı olan bu yöntemlerin aynı katkıyı çeşitli hedef tanıma algoritmaları için uygun olup olmadığı da irdelenmemiştir. Bu iki konunun da çalışılması ileriki aşamalara bırakılmıştır.

KAYNAKLAR

- [1] Gass, S.I., Making Decisions with Precision, Business Week October 30, <http://www.bloomberg.com/bw/stories/2000-10-29/making-decisions-with-precision#B37051>, 02.03.2015.
- [2] Balasubramanian, G. ve Shettigara V.K. (2007). "Band Selection Using Support Vector Machines for Improving Target Detection in Hyperspectral Images", Digital Image Computing Techniques and Applications, 9th Biennial Conference of the Australian Pattern Recognition Society, 446 - 453.
- [3] Kozal, A., Teke, M. ve Ilgin, H. (2013). "Comparative analysis of hyperspectral dimension reduction methods", IEEE 21st Signal Processing, Communication and Applications Conference, 1 - 4.
- [4] Sığırcı İ. ve Bilgin G. (2014). "Dirichlet Karışım Modelleriyle Hiperspektral Görüntülerin Bölütlenmesi", IEEE 22. Sinyal İşleme ve Uygulamaları Kurultayı, 983-986.
- [5] Blum, C. ve Roli, A. (2003). "Metaheuristics in combinatorial optimization: Overview and conceptual comparison", ACM Computing Surveys-CSUR, 35 (3): 268-308.
- [6] Chang, Y. L. (2011). "A simulated annealing feature extraction approach for hyperspectral images", Future Generation Computer Systems, 27(4): 419-426.
- [7] Li, S., Wu, H., Wan, D. ve Zhu, J. (2011). "An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine", Knowledge-Based Systems, 24(1): 40-48.
- [8] Ghosh, A., Datta, A. ve Ghosh, S. (2013). "Self-adaptive differential evolution for feature selection in hyperspectral image data", Applied Soft Computing, 13(4): 1969-1977.
- [9] Shippert P. (2003). "Introduction to Hyperspectral Image Analysis", Online Journal of Space Communication, 3.
- [10] Görünen ışığın dalga boyu aralığı, <http://www.overidon.com/wp-content/uploads/2010/06/wavelength-light1.jpg>, 24 Mart 2012.
- [11] Mantis karidesinin göz yapısı, <https://www.youtube.com/watch?v=G1k6FHqwGVs>, 08.10.2015.
- [12] Foody G., Warner T. ve Nellis D., (2009). SAGE Handbook of Remote Sensing, SAGE Publications.

- [13] Hiperspektral k p, http://akademikpersonel.kocaeli.edu.tr/deniz.gercek/diger/deniz.gercek16.04.2013_23.41.15diger.pdf, 08.10.2015.
- [14] Hiperspektral g r nt leme sistemi, <http://www.kocaeli.edu.tr/universitemizden-haberler.php?Haber=102.htm>, 11.02.2015.
- [15] Pearlman J.S., Barry P.S., Segal C.C., Shepanski J., Beiso D. ve Carman S.L. (2003). "Hyperion, a Space-based Imaging Spectrometer", IEEE Transactions on Geoscience and Remote Sensing, 41(6): 1160- 1173.
- [16] Vagni, F. (2007). Survey of hyperspectral and multispectral imaging technologies. TR-SET-065-P3, 31-35.
- [17] Manolakis, D., Marden, D. ve Shaw, G. A. (2003). "Hyperspectral image processing for automatic target detection applications", Lincoln Laboratory Journal, 14(1): 79-116.
- [18] Barnsley M.J., Settle J.J., Cutter M.A., Lobb D.R ve Teston F. (2004). "The PROBA/CHRIS Mission: A low-cost SmallSat for Hyperspectral Multi-angle Observations of the Earth Surface and Atmosphere", IEEE Transactions on Geoscience and Remote Sensing, vol. 42(7): 1512- 1520.
- [19] Hiperspektral kamera, <http://www.gildenphotonics.com/hyperspectral-imaging-/hyperspectral-imaging-technology.aspx>, 15.10.2015.
- [20] HSG, http://tr.wikipedia.org/wiki/Hiperspektral_G r nt leme, 13 Şubat2015.
- [21] Kim, M. S. ve Chen, Y. R., (2001). "Hyperspectral Reflectance and Fluorescence Imaging System for Food Quality and Safety", American Society of Agricultural Engineers, 44: 721-729.
- [22] Plaza, A. ve Martinez P., (2003). "A New Method for Target Detection in Hyperspectral Imagery Based on Extended Morphological Profiles", IEEE Geoscience and Remote Sensing Symposium, 3772-3774.
- [23]  etin M. ve Musaaog lu N. (2008). " breli orman t rlerinin Hiperspektral uydu g r nt s  ile ayırt edilebilirli inin arařtırılması", it dergisi/d m hendislik, 7(5).
- [24] Clark, R. N., Swayze, G. A., Leifer, I., Livo, K. E., Kokaly, R., Hoefen, T., ... ve Team, A. V. I. I. S. A. (2010). "A method for quantitative mapping of thick oil spills using imaging spectroscopy", US Geological Survey Open-File Report, 1167(2010): 1-51.
- [25] Talbi, E.G. (2009). Metaheuristics: From Design To Implementation. John Wiley & Sons, Hoboken, New Jersey.
- [26] Blum, C. ve Roli, A. (2003). "Metaheuristics in combinatorial optimization: Overview and conceptual comparison", ACM Computing Surveys-CSUR, 35 (3): 268-308.
- [27] Hertz, A. ve Widmer, M. (2003). "Guidelines for the use of meta-heuristics in combinatorial optimization", European Journal of Operational Research, 151 (2): 247-252.

- [28] Tarantilis, C. D., Ioannou, G. ve Prastacos, G. (2005). "Advanced vehicle routing algorithms for complex operations management problems", Journal of Food Engineering, 70(3): 455-471.
- [29] Onan A. (2010). "Metaheuristic Methods and Their Application Areas", Çukurova Üniversitesi İİBF Dergisi, 17(2): 113-128.
- [30] Kirkpatrick, S., Gelatt, C. D. ve Vecchi, M. P. (1983). "Optimization By Simulated Annealing", Science, 220(4598): 671-680.
- [31] Michiels, W., Aarts, E. ve Korst, J. (2007). Theoretical aspects of local search, Springer Science & Business Media.
- [32] BT'de ısıtıl işlem basamakları, <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-8.Hafta-IsilislemlerAlgoritmasi.pdf>, 11.11.2015.
- [33] Busetti, F., Simulated Annealing Overview, <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.66.5018>, 16.02.2015.
- [34] Russell, S. ve Norvig, P. (1995). Artificial intelligence: a modern approach, Prentice Hall.
- [35] Dumitrescu, I. ve Stützle, T. (2003). "Combinations of Local Search and Exact Algorithms", Applications of Evolutionary Computing. Springer Berlin Heidelberg, 211-223.
- [36] Obitko, M., Introduction to Genetic Algorithms with Java Applets, <http://www.obitko.com/tutorials/genetic-algorithms/index.php>, 16.02.2015.
- [37] J.H. Holland (1975). Adaptation In Natural And Artificial Systems, Mit Pres.
- [38] Zeyveli, M. (2005). Genetik Algoritma İle Hız Kutusu Dışlı Tasarımı, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü.
- [39] Elmas, Ç. (2010). Yapay Zeka Uygulamaları Yapay Sinir Ağları – Bulanık Mantık – Genetik Algoritma, Seçkin Yayıncılık.
- [40] Aktürk, F. (2013). Genetik Algoritma ile Büyükbaş Süt Hayvanlarında Süt Verimi Maksimizasyonu, Yüksek Lisans Tezi, Gazi Üniversitesi Sosyal Bilimler Enstitüsü.
- [41] Siriwardene, N.R. ve Perera, B.J.C. (2006). "Selection of Genetic Algorithm Operators for Urban Drainage Model Parameter Optimization", Mathematical and Computer Modelling, 44: 415-429.
- [42] Kemer, B. (2010). Araç Rotalama Problemlerine Genetik Algoritma Yaklaşımı: Bir Gıda Dağıtım Firması Uygulaması, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü.
- [43] Sivanandam, S.N. ve Deepa, S.N. (2008). Introduction to Genetic Algorithm, Berlin: Springer-Verlag.
- [44] GA Akış Şeması, https://tr.wikipedia.org/wiki/Genetik_algoritma, 11.11.2015.
- [45] Szeeto, W.Y., Wu, Y. ve Ho, S.C. (2011). "An Artificial Bee Colony Algorithm for the Capacitated Vehicle Routing Problem", European Journal of Operational Research, 215:126-135.

- [46] Uçaner, M.E. ve Özdemir, O.N. (2002). “Genetik Algoritmalar ile İçme Suyu Şebekelerinde Ek Klorlama Optimizasyonu”, Gazi Üniv. Müh. Mim. Fak. Der, 17(4): 157-170.
- [47] Storn, R. ve Price, K. (1995). “Differential evolution: a simple and efficient adaptive scheme for global optimization over continuous spaces”, Technical Report TR-95-012, University of California, Berkeley, International Computer Science Institute.
- [48] Hrstka, O. ve Kucerovala, A. (2004). “Improvement of real coded genetic algorithms based on differential operators preventing premature convergence”, Advances in Engineering Software 35: 237-246.
- [49] Meyer, C. P., Geller, J. B. ve Paulay, G. (2005). “Fine scale endemism on coral reefs: archipelagic differentiation in turbinid gastropods”, Evolution, 59(1): 113-125.
- [50] Keskinürk T. (2006). “Diferansiyel Gelişim Algoritması”, İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 9: 85-99.
- [51] Mayer, D.G., Kinghorn, B.P. ve Archer, A.A. (2005). “Differential evolution – an easy and efficient evolutionary algorithm for model optimisation”, Agricultural Systems, 83(3): 315–328.
- [52] McMurry, J., Ballantine, D. S., Hoeger, C. A. ve Peterson, V. E. (2009). Fundamentals of General, Organic and Biological Chemistry, Pearson Prentice Hall, New Jersey.
- [53] Kruse, F. A., Lefkoff, A. B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J. ve Goetz, A. F. H. (1993). “The spectral image processing system (SIPS) interactive visualization and analysis of imaging spectrometer data”, Remote sensing of environment, 44(2): 145-163.
- [54] Manning, C. D., Raghavan P. ve Schütze, H. (2008). Introduction to Information Retrieval, Cambridge University Press.
- [55] Pan, B., Qian, K., Xie, H. ve Asundi, A. (2009). “Two-dimensional digital image correlation for in-plane displacement and strain measurement: a review”, Measurement science and technology, 20(6): 062001.
- [56] Chen W., Song Y., Bai H., Lin C. ve Chang E.Y. (2011). “Parallel Spectral Clustering in Distributed Systems”, Pattern Analysis and Machine Intelligence, IEEE Transactions, 33(3): 568 – 586.
- [57] Hunter B. , Lou Y. ve Bertozzi A.L., A spectral graph based approach to analyze hyperspectral data, http://www.math.ucla.edu/~bertozzi/papers/2012_HyperspectralHunterLouBertozzi_AIPR.pdf, 01.09.2015.
- [58] White S. ve Smyth P. (2005). “A spectral clustering approach to finding communities in graphs”, SIAM International Conference on Data Mining, 5: 76-84.
- [59] Padhye, A. (2006). Comparing Supervised and Unsupervised Classification of Messages in the Enron Email Corpus, Doktora Tezi, University Of Minnesota.

- [60] Guerra, L., McGarry, L. M., Robles, V., Bielza, C., Larranaga, P. ve Yuste, R. (2011). "Comparison between supervised and unsupervised classifications of neuronal cell types: a case study", *Developmental neurobiology*, 71(1): 71-82.
- [61] Press, W. H., Teukolsky, S. A., Vetterling, W. T. ve Flannery, B. P. (1992). *Numerical Recipes: The art of scientific computing*, Cambridge.
- [62] Martin Law, A Simple Introduction to Support Vector Machines, Notes, www.cise.ufl.edu/class/cis4930sp11dtm/notes/intro_svm_new.pdf, 01.03.2015.
- [63] DVM ile iki sınıfın ayrımı, https://en.wikipedia.org/wiki/Support_vector_machine, 11.11.2015.
- [64] Soman, K.P., Loganathan, R. ve Ajay, V. (2011). *Machine learning with SVM and other kernel methods*, PHI Learning Pvt. Ltd.
- [65] Elkan C., Nearest Neighbor Classification, Lecture Notes, <http://cseweb.ucsd.edu/~elkan/151/nearestn.pdf>, 02.03.2015.
- [65] Ham, J., Chen, Y., Crawford, M. M. ve Ghosh, J. (2005). "Investigation of the random forest framework for classification of hyperspectral data", *Geoscience and Remote Sensing, IEEE Transactions on*, 43(3): 492-501.
- [66] Dinç S., Çok Sınıflı Çekirdek Fukunaga-Koontz Dönüşümü Kullanarak Hiperpektral Görüntülerde Hedef Tanıma (Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi Elektrik-Elektronik Fakültesi, 2011.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hüseyin Çukur
Doğum Tarihi ve Yeri : 01.03.1988 – İZMİR
Yabancı Dili : İngilizce
E-posta : hcukur@yildiz.edu.tr

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Elektronik Müh.	İstanbul Teknik Üniversitesi	2012
Lise	Fen Bilimleri	Yamanlar Anadolu Lisesi	2006

İŞ TECRÜBESİ

Yıl	Kurum	Görevi
2013 – Devam Ediyor	Yıldız Teknik Üniversitesi	Araştırma Görevlisi

YAYINLARI

Bildiri

1. **Çukur, H.**, Binol, H., & Bal, A. (2015, Mayıs). Hiperspektral Görüntülerde Sınıflama Başarısını Artırmaya Yönelik Sezgisel Band Seçimi Yaklaşımı. IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU2015). Malatya, Türkiye.
2. **Çukur, H.**, Binol, H., Uslu, F. Ş., & Bal, A. (2015, Eylül). An Effective Band Selection Approach for Classification in Remote Sensing Imagery. The 22nd SPIE Symposium on Remote Sensing. Toulouse, Fransa.
3. Binol, H., Bal, A., & **Çukur, H.** (2015, Eylül). Differential evolution algorithm-based kernel parameter selection for Fukunaga-Koontz Transform Subspaces Construction. The 22nd SPIE Symposium on Remote Sensing. Toulouse, Fransa.
4. **Çukur, H.**, Binol, H., Uslu, F. Ş., Kalaycı, Y., & Bal, A. (2015, Kasım). Cross Correlation Based Clustering for Feature Selection in Hyperspectral Imagery. 9th International Conference on Electrical and Electronics Engineering (ELECO 2015). Bursa, Türkiye.

PROJE

1. Hiperspektral Görüntülerde Uzamsal ve Spektral Öznitelikler Kullanarak Yüksek Hızda Hedef Tespiti ve Sınıflama Yapan Algoritmaların Geliştirilmesi.

Projedeki Görevi: Araştırmacı

Destekleyen Kurum: TÜBİTAK