

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



BOYUT İNDİRGEME VE HİPERSPEKTRAL VERİ
SINIFLANDIRMASINDAKİ ETKİLERİ

YÜKSEK LİSANS TEZİ

Lina YOUNUS

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ PROGRAMI

AĞUSTOS 2018

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



BOYUT İNDİRGE ME VE HİPERSPEKTRAL VERİ
SINIFLANDIRMASINDAKİ ETKİLERİ

YÜKSEK LİSANS TEZİ

Lina YOUNUS
(Y1613.100001)

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ PROGRAMI

Tez Danışmanı: Dr. Öğr. Üyesi Necip Gökhan KASAPOĞLU

AĞUSTOS 2018



T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ

Yüksek Lisans Tez Onay Belgesi

Enstitümüz Elektrik- Elektronik Mühendisliği Ana Bilim Dalı Elektrik- Elektronik Mühendisliği Tezli Yüksek Lisans Programı Y1613.100001 numaralı öğrencisi **LINA GHAZWAN YOUNUS YOUNUS**' un “**BOYUT İNDİRGEME VE HİPERSPEKTRAL VERİ SINIFLANDIRMASINDAKİ ETKİLERİ**” adlı tez çalışması Enstitümüz Yönetim Kurulunun 28.08.2018 tarih ve 2018/16 sayılı kararıyla oluşturulan jüri tarafından **g.b.i.t.j** ile Tezli Yüksek Lisans tezi olarak **kabul** edilmiştir.

Öğretim Üyesi Adı Soyadı

İmzası

Tez Savunma Tarihi : 26/09/2018

1) **Tez Danışmanı:** Dr. Öğr. Üyesi Necip Gökhan KASAPOĞLU

2) **Jüri Üyesi :** Dr. Öğr. Üyesi Evrim TETİK

3) **Jüri Üyesi :** Prof. Dr. Hasan Hüseyin BALIK

N. Gökhan
.....
E. Tetik
.....
H. Balık
.....

Not: Öğrencinin Tez savunmasında **Başarılı** olması halinde bu form **imzalanacaktır**. Aksi halde geçersizdir.

YEMİN METNİ

Yüksek lisans tezi olarak sunduğum “Boyut İndirgeme Ve Hiperspektral Veri Sınıflandırmasındaki Etkileri” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (15/08/2018)

Lina YOUNUS





Tez çalışmamı annem, babam ve kardeşlerime adıyorum ...



ÖNSÖZ

İlk ve en önemlisi, tüm dualarımda mezuniyetimden dolayı her yerde Allah'a şükran duyuyorum.

Tez danışmanım Dr. Öğr. Üyesi Necip Gökhan KASAPOĞLU' na bu tezi yaparken rehberlik, ilham ve değerli tavsiyeleri ve katkıları için teşekkürlerimi ifade etmek isterim. Ayrıca, destekleri için İstanbul Aydın Üniversitesi Elektrik-Elektronik Mühendisliği Bölümüne teşekkür ederim.

Çalışmam boyunca bana destek olan, tüm sevdiğime ve sevgili aileme olan sonsuz sevgimi ve şükranlarımı ifade etmek isterim.

Ayrıca, tez çalışmam sırasında destekledikleri için kardeşlerime özellikle de erkek kardeşim Luay YOUNUS' a teşekkür ederim.

Son olarak sevgili arkadaşlarıma bu tezin başarılı bir şekilde tamamlanabilmesi için desteklerinden dolayı iyi dileklerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	IX
İÇİNDEKİLER	XI
XII	
KISALATMALAR.....	XIII
TABLO LİSTESİ	XV
ŞEKİLLER LİSTESİ.....	XVII
ABSTRACT	XXI
ÖZET.....	XXIII
1. GİRİŞ.....	1
1.1 Çalışma Konusu	1
1.2 Tezin Amacı	1
1.3 Literatür İncelemesi.....	1
1.4 Hipotez	4
2. BOYUTLUK İNDİRGEME	7
2.1 Boyutsal İndirmeye Giriş.....	7
2.2 Hiperspektral Uzaktan Algılama	7
2.3 Temel Bileşen Analizi Tabanlı Boyut İndirgeme.....	8
2.3.1 PCA Yöntemi.....	9
2.3.2 Bilgisayarlı Görüde PCA.....	13
2.3.2.1 Temsilcilik	13
2.3.2.2 Model Bulmak İçin PCA.....	13
2.3.2.3 Görüntü Sıkıştırma İçin PCA.....	15
2.4 İzometrik Özellik Haritalama Tabanlı Boyut İndirgeme	15
2.4.1 ISOMAP Yöntemi	16
2.4.2 Çok Boyutlu Ölçekleme	18
2.4.2.1 Klasik Çok Boyutlu Ölçeklendirme	18
3. DESTEK VEKTÖR MAKİNELERİ VE K-EN YAKIN KOMŞULUK SINIFLANDIRICILARI	21
3.1 Giriş	21
3.2 Destek Vektör Makinelerine Giriş.....	21

3.3 Destek Vektör Makinesi Sınıflandırıcısı	23
3.4 K-En Yakın Komşuluk Sınıflandırıcısına Giriş.....	25
3.5 K-En Yakın Komşular Sınıflandırıcı	26
4. DENEYLER VE SONUÇLAR.....	29
4.1 Giriş	29
4.2 İş İçeriği	29
4.2.1 Geliştirme Ortamı	29
4.2.2 AVIRIS Indian Pines Veri Seti.....	29
4.3 Deney.....	30
4.3.1 PCA Yöntemi	34
4.3.2 ISOMAP Yöntemi	47
5. SONUÇLAR VE ÖNERİLER.....	73
KAYNAKLAR.....	75
ÖZGEÇMİŞ.....	79

KISALATMALAR

MVR	: Missing Values Ratio
FFC	: Forward Feature Construction
LVF	: Low Variance Filter
HCF	: High Correlation Filter
RF	: Random Forests
ET	: Ensemble Trees
BFE	: Backward Feature Elimination
PCA	: Principal Component Analysis
ISOMAP	: Isometric Mapping
PPA	: Principal Polynomial Analysis
KPCA	: Kernel principal component analysis
SRGAE	: Sample-Dependent Repulsion Graph Regularized Auto- Encoder
PKPCA	: Parallel Kernel Principal Component Analysis Algorithm
SKPCA	: Serial Kernel Principal Component Analysis Algorithm
MKPCA	: Multilevel Hybrid Parallel
GSP	: Graph Signal Processing
FMRI	: Functional Magnetic Resonance Imaging
ICA	: Independent Component Analysis
SD	: Standard Deviation
SNR	: Signal-To-Noise Ratio
MDS	: Multi-Dimensional Scaling
SVM	: Support Vector Machines
KNN	: K nearest neighbors
ML	:Maximum Likelihood
RBF	: Radial Basis Functions
MNF	: Minimum Noise Fraction
JM	: Jeffries–Matusita
SA	: Steepest Ascent
BP	: Back Propagation



ÇİZELGE LİSTESİ

Çizelge 4.1: AVIRIS Indian Pines 17 ve 16 sınıflı veri kümeleri için örnek sayısı.. 33

Çizelge 4.2: AVIRIS Indian Pines 9 sınıflı veri kümesi için örnek sayıları..... 34





ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1: PCA iki boyutlu veri kümesine uygulandı	13
Şekil 2.2: PCA akış şemasıdır	15
Şekil 2.3: ISOMAP iki boyutlu veri kümesine uygulanır.....	16
Şekil 2.4: Yerel komşuluk grafiğinin oluşturulması.....	17
Şekil 2.5: ISOMAP'a dayalı $dG_{i,j}$ tahmini	17
Şekil 2.6: ISOMAP akış şemasıdır	18
Şekil 3.1: SVM Genel prensip	24
Şekil 3.2: SVM prensip	25
Şekil 3.3: KNN çalışma prensibi	27
Şekil 4.1: AVIRIS Indian Pines veri kümesinin (a) Örnek bandı ve (b) referans yer verisi.....	30
Şekil 4.2: PCA ve SVM kullanarak veri sınıflandırması.....	30
Şekil 4.3: ISOMAP ve KNN kullanarak veri sınıflandırması	31
Şekil 4.4: Geleneksel PCA yöntemi	32
Şekil 4.5: PCA gruplama yöntemi	32
Şekil 4.6: 17 sınıflı veri eğitim örnekleri için PCA-SVM sınıflandırma başarımı....	35
Şekil 4.7: 17 sınıflı veri test örnekleri için PCA-SVM sınıflandırma başarımı.....	36
Şekil 4.8: 17 sınıflı tüm veri için PCA-SVM sınıflandırma başarımı	37
Şekil 4.9: 17 sınıflı AVIRIS veri seti 100 öznitelik için PCA-SVM sınıflandırma başarımı.....	38
Şekil 4.10: 17 sınıflı AVIRIS veri seti 200 özellik için PCA-SVM sınıflandırma başarımı.....	38
Şekil 4.11: 16 sınıflı eğitim verisi için PCA-SVM sınıflandırma başarımı.....	39
Şekil 4.12: 16 sınıflı test verisi için PCA-SVM sınıflandırma başarımı	40
Şekil 4.13: 16 sınıflı veri için tüm görüntü PCA-SVM sınıflandırma.....	40
Şekil 4.14: 16 sınıflı durum 100 öznitelik için PCA-SVM sınıflandırma sonucu.....	42
Şekil 4.15: 16 sınıflı durum 200 öznitelik için PCA-SVM sınıflandırma sonucu.....	42
Şekil 4.16: 17 ve 16 sınıflı durumda sınıflandırma başarımlarının karşılaştırılması.	43
Şekil 4.17: 9 sınıflı durum eğitim örnekleri için PCA-SVM sınıflandırma başarımı	43
Şekil 4.18: 9 sınıflı durum test verisi için PCA-SVM sınıflandırma başarımı.....	44
Şekil 4.19: 9 sınıflı durum tüm görüntü için PCA-SVM sınıflandırma başarımı.....	45
Şekil 4.20: İlk 100 temel bileşen için PCA-SVM sınıflandırma sonucu.....	46
Şekil 4.21: İlk 200 temel bileşen için PCA-SVM sınıflandırma sonucu.....	46
Şekil 4.22: 17, 16 ve 9 sınıflı durum için PCA-SVM sınıflandırma başarımlarının karşılaştırılması	47
Şekil 4.23: 17 sınıflı durumda test örnekleri için ISOMAP-KNN sınıflandırma başarımı.....	48

Şekil 4.24: 17 sınıflı durumda tüm görüntü için ISOMAP-KNN sınıflandırma başarımı	48
Şekil 4.25: 17 sınıflı durum ve ilk 50 ISOMAP öznitelik için KNN sınıflandırma sonucu.....	49
Şekil 4.26: 17 sınıflı durum ve ilk 100 ISOMAP öznitelik için KNN sınıflandırma sonucu.....	49
Şekil 4.27: 17 sınıflı durum ve ilk 200 ISOMAP öznitelik için KNN sınıflandırma sonucu.....	50
Şekil 4.28: 16 sınıflı durumda test örnekleri için ISOMAP-KNN sınıflandırma başarımı	51
Şekil 4.29: 16 sınıflı durumda tüm görüntü için ISOMAP-KNN sınıflandırma başarımı	51
Şekil 4.30: 16 sınıflı durumda ilk 50 ISOMAP özniteliği için KNN sınıflandırma sonucu.....	52
Şekil 4.31: 16 sınıflı durumda ilk 94 ISOMAP özniteliği için KNN sınıflandırma sonucu.....	52
Şekil 4.32: 16 sınıflı durumda tüm ISOMAP özniteliği için KNN sınıflandırma sonucu.....	53
Şekil 4.33: 9 sınıflı durumda test örnekleri için ISOMAP-KNN sınıflandırma başarımı	54
Şekil 4.34: 16 sınıflı durumda tüm görüntü için ISOMAP-KNN sınıflandırma başarımları.....	54
Şekil 4.35: 9 sınıflı durumda ilk 50 ISOMAP özniteliği için KNN sınıflandırma sonucu.....	55
Şekil 4.36: 9 sınıflı durumda ilk 100 ISOMAP özniteliği için KNN sınıflandırma sonucu.....	55
Şekil 4.37: 9 sınıflı durumda ilk 200 ISOMAP özniteliği için KNN sınıflandırma sonucu.....	56
Şekil 4.38: 17, 16 ve 9 sınıflı durumlar için ISOMAP-KNN sınıflandırma doğruluklarının test örnekleri ve tüm görüntü için karşılaştırılması	57
Şekil 4.39: ISOMAP ve SVM kullanarak veri sınıflandırması	57
Şekil 4.40: 17 sınıflı durumda eğitim örnekleri için ISOMAP-SVM sınıflandırma başarımı	58
Şekil 4.41: 17 sınıflı durumda test örnekleri için ISOMAP-SVM sınıflandırma başarı	59
Şekil 4.42: 17 sınıflı durumda tüm görüntü için ISOMAP-SVM sınıflandırma başarımı	59
Şekil 4.43: İlk 80 ISOMAP özniteliğinin SVM sınıflandırma sonucu	60
Şekil 4.44: İlk 103 ISOMAP özniteliği için SVM sınıflandırma sonucu	61
Şekil 4.45: İlk 200 ISOMAP özniteliği için SVM sınıflandırma sonucu	61
Şekil 4.46: 16 sınıflı durumda eğitim verisi için ISOMAP-SVM sınıflandırma başarımı	62
Şekil 4.47: 16 sınıflı durumda test örnekleri için ISOMAP-SVM sınıflandırma başarımı	62
Şekil 4.48: 16 sınıflı durumda tüm görüntü için ISOMAP-SVM sınıflandırma başarımı	63
Şekil 4.49: İlk 50 ISOMAP özniteliği için SVM sınıflandırma sonucu	63

Şekil 4.50: İlk 95 ISOMAP özniteliği için SVM sınıflandırma sonucu	64
Şekil 4.51: İlk 200 ISOMAP özniteliği için SVM sınıflandırma sonucu	64
Şekil 4.52: 9 sınıflı durum için eğitim örnekleri ISOMAP-SVM sınıflandırma başarımı	65
Şekil 4.53: 9 sınıflı durum için test örnekleri ISOMAP-SVM sınıflandırma başarımı	65
Şekil 4.54: 9 sınıflı durumda tüm görüntü için ISOMAP-SVM sınıflandırma doğruluğu	66
Şekil 4.55: İlk 80 ISOMAP özniteliği için SVM sınıflandırma sonucu	67
Şekil 4.56: İlk 100 ISOMAP özniteliği için SVM sınıflandırma sonucu	67
Şekil 4.57: İlk 200 ISOMAP öznitelikleri için SVM sınıflandırma sonucu	68
Şekil 4.58: Test verileri için SVM ve KNN arasındaki sınıflandırma başarımlarının karşılaştırılması	68
Şekil 4.59: PCA-SVM ve ISOMAP-SVM yöntemlerinin karşılaştırılması	69
Şekil 4.60: 17 sınıflı durumda test örnekleri sınıflandırma başarımlarının karşılaştırılması	70
Şekil 4.61: 16 sınıflı durumda test örnekleri için sınıflandırma başarımlarının karşılaştırılması	71
Şekil 4.62: 9 sınıflı durumda test örnekleri için sınıflandırma başarımlarının karşılaştırılması	72



DIMENSION REDUCTION AND ITS EFFECTS IN HYPERSPECTRAL DATA CLASSIFICATION

ABSTRACT

In recent years dimension reduction and hyperspectral data imaging systems have gained significant attention from various research experts and institutions. By active acquisition of data through the use of data sensors, the middle infrared wavelengths can be altered and captured through various existing spectral channels from a particular defined interface within the surface of the earth. The hyperspectral sensors are quite crucial in the provision of detailed spectral information and this is quite priceless in as far as the increase in accuracy and the discrimination of materials of interest are concerned. In most instances, the hyperspectral solutions for imaging as well as the systems for spatial resolutions can be simply operated by application of sensors which ultimately enhance the process by playing two crucial roles; enhancing the provision of finer imaging details and enabling the analysis of even much smaller spatial structures that may be found within the images.

As a consequence of consideration, it is invaluable to note the significant contribution of data classification and mapping in remote sensing and interpretation. One of the primary roles played by supervised classification of data is the use of classification input to observe or understand the implied spectral information about a given data. These includes information such as the value of the intensity for all the pixels used in achieving the grayscale images as well as the intensity vector for the RGB or even the images of high dimensions. This consequently leads to the production of data classification map which helps in the discrimination of different interests by the use of a representative sample. The central focus of this thesis, however, is to analyse the effect of dimension reduction in the said hyperspectral data classification systems. In the thesis, emphasis will be made on two important aspects of dimension reduction in hyperspectral data classification. These includes dimension reduction in PCA and ISOMAP then, decision making through the application of the Support Vector Machine (SVM), K-Nearest Neighbors (KNN) and the related MATLAB experiments for ISOMAP, PCA, SVM and KNN as desired.

Keywords: *Hyperspectral Imaging Data, Dimension Reduction, PCA, ISOMAP, SVM, KNN.*



BOYUT İNDİRGE ME VE HİPERSPEKTRAL VERİ SINI FLANDIRMASINDAKİ ETKİLERİ

ÖZET

Boyut indirgeme ve hiperspektral veri görüntüleme sistemleri arařtırmacılar ve arařtırma kurumlarından büyük ilgi görmüřtür. Veri sensörlerinin kullanımı yoluyla verilerin aktif olarak alınmasıyla, orta ve kızılötesi dalga boylarında, dünyanın yüzeyindeki belirli bir bölgeden çeřitli mevcut spektral bandlar yoluyla görüntüler alınabilir. Hiperspektral sensörler, detaylı spektral bilginin sağlanmasında oldukça önemlidir ve bu ayrıntılı veriden dolayı doğruluktaki artış ve ilgili materyallerin ayrımcılığına ilişkin olarak oldukça pahalıdır. Çoğu durumda, görüntüleme için hiperspektral çözümler ve uzamsal kararlar için sistemler basitçe iki önemli rol oynayarak süreci ayrımcılığı artıran sensörlerin uygulanmasıyla çalıştırılabilir; Daha hassas görüntüleme ayrıntılarının sağlanmasını geliřtirmek ve görüntüler içinde bulunabilecek çok daha küçük mekansal yapıların analizini sağlamak hiperspektral verilerin önemli özellikleri olarak sayılabilir.

Sonuç olarak, uzaktan algılama ve yorumlamada veri sınıflandırmanın önemli katkısı vardır. Denetimli öğrenme ile verilerin sınıflandırılmasıyla oynanan birincil rollerden biri, belirli bir veri hakkında spektral bilgileri modellemek için eğitim örneklerinin kullanılmasıdır. Bu örnekler, gri tonlamalı görüntülerin elde edilmesinde kullanılan tüm piksellerin yoğunluğunun yanı sıra, RGB'nin yoğunluk vektörü ve hatta yüksek boyutlardaki görüntülerin değeri gibi bilgileri içerir. Bu sonuç olarak, temsili bir örneklem kullanılarak farklı çıkarların ayrımcılığına yardımcı olan veri sınıflandırma sonuçlarının üretilmesine yol açmaktadır. Bununla birlikte, bu tezin amacı, söz konusu hiperspektral veri sınıflandırma sistemlerinde boyut indirgemenin etkisini analiz etmektir. Bu tezde hiperspektral veri sınıflamasında boyut indirgemenin iki önemli yönü üzerinde durulacaktır. Bunlar, PCA ve ISOMAP ile boyut indirgeme olup, daha sonra da boyut indirgemenin Destek Vektör Makinesi (SVM) ve K en yakın komşuluk (KNN) gibi sınıflayıcılara olan etkilerini incelemektedir.

Anahtar Kelimeler: *Hiperspektral Görüntüleme Verileri, Boyut İndirgeme, PCA, ISOMAP, SVM, KNN.*



1. GİRİŞ

1.1 Çalışma Konusu

Bu tezin ana amacı hiperspektral veri sınıflama sistemlerinde boyut indirgemenin etkisini analiz etmektir. Hiperspektral verilerdeki boyut indirgeme PCA ve ISOMAP yöntemleriyle gerçekleştirilecek olup boyut indirgemenin sınıflandırma başarımlarına etkisi karşılaştırılacaktır. Sınıflandırma yani karar verme işlemi Destek Vektör Makinesi (SVM) veya K en yakın komuluk (KNN) yöntemlerinin uygulanmasıyla yapılacaktır.

1.2 Tezin Amacı

Bu tezin temel amacı hiperspektral verilerdeki boyut indirgemenin etkilerini belirlemektir. PCA ve ISOMAP gibi boyut indirgeme teknikleriyle, boyut indirgemenin sınıflandırma başarımlarına olan etkilerini analiz etmek mümkündür. Bu tez çalışmasının özel hedefleri şunlardır:

- Hiperspektral very sınıflandırma tekniklerinin doğruluk düzeylerini karşılaştırmak.
- Hiperspektral very sınıflamasında boyutsal azalmanın etkilerini açıklamak.
- Hiperspektral verilerdeki boyut indirgeme için RBF- SVM tabanlı algoritmayı ve K en yakın komşuluk (KNN) yöntemini parametrik olmayan sınıflayıcılar olarak kullanmaktır.

1.3 Literatür İncelemesi

Teknolojideki hızlı ilerleme, yakın geçmişte, özellikle hiperspektral verilerin kullanımı, uzaktan algılamada, birçok önemli gelişmeye katkıda bulunmuştur. Hiperspektral uzaktan algılama yoluyla, uzaktan algılama teknolojisinin gelişmesinin yanı sıra, varolan hassas ayıricılıkta daha doğru karar almak mümkündür. Hiperspektral görüntüleme, görüntüleme spektroskopisi olarak da bilinir ve hiperspektral uzaktan algılama, bir hedef noktadan veya kaynaktan ışık ışınlarının. elektromanyetik radyasyonunun sonucu elde edilen spektrum sayısını ölçer. Çeşitli

spektroskopi ve görüntüleme elemanlarının birleştirildiği ve daha sonra tek bir veri kümesine indirgenmiş olan hiperspektral uzaktan algılamada, X-Y düzleminde ve bir Z-yönünde toplanan veriler daha sonra bir spektral imzayı temsil edecek şekilde hiperküüp olarak temsil edilir.

Hiperspektral veriler, bir görüntüde tipik olarak birbirine komşu küçük dalga boylarını kapsayan komşu spektral bantlarla temsil edilir. Bunun neticesi, farklı multispektral görüntülerin farklı spektral bantlara sahip olmasıdır. Ancak çoğu durumda, Hiperspektral görüntüler, kızıl ötesi bölgelerin termal aralığına bağlı olarak 5 mikrometre ile 20 mikrometre arasında değişen dar aralığa sahiptir. Hiperspektral görüntülerin, multispektral görüntülere göre çok yüksek spektral çözünürlüklere sahip olması bu dar bantların bir sonucudur. Böyle bir yüksek spektral çözünürlük gücüyle, hiperspektral sensörler, spektral hedef görüntülerin daha ayrıntılı tanımlanmasını ve çözülmesini sağlar. Hiperspektral görüntüleme çoğunlukla jeolojik amaçlar, atmosferin analizi, arazi örtüsünün analizi, ormanların analizi, haritalama ve tarımsal uygulamalar ile askeri ve madencilik gibi gözetim faaliyetleri ve uygulamalarında kullanılır.

Hiperspektral görüntülerin sınıflandırması, sınıflandırıcının doğruluğunu arttırmak için bazen çok sayıda bandın eklenmesini gerektirir. Bu bant ilavesinden dolayı, "Hughes Etkisi" olarak bilinen bir süreçte sınıflandırıcının doğruluğu azalabilir. Ancak bu süreç, bazen "yüksek boyut zorluğu" adı verilen bir süreçte veri setlerine önemli sayıda eğitim örneklerinin sağlanmasını gerektirebilir. Orijinal boyuttaki veri analiz başarımı korunurken, hiperspektral görüntülerin boyutunun indirgenmesi özellikle sınırlı sayıda eğitim örneğinin olduğu çoğu durumda özellikle parametrik sınıflayıcılar için yapılması gereken kritik bir işlemdir.

Son yıllarda laboratuvarların veri analizleri, hiperspektral verilerde olduğu gibi büyük veriler için karmaşık araçlara ihtiyaç duyan devasa bir veriden muzdarip olduğu fark edilmiştir. Buna ek olarak, istatistik teknikleri bu kadar büyük veriyi işlerken daha fazla zorluklarla karşılaşır. Yüksek boyutlu verilerin yüksek oranda artacağı ve dolayısıyla bu yüksek-boyutlu verilerin büyük bir bilgi kaybı olmaksızın çok daha küçük boyutlara indirgenebildiği fark edilmektedir.

Son günlerde, boyut küçültme teknikleri olarak birçok teknik önerilmiştir meselâ eksik değerler oranı (MVR), düşük varyans filtresi (LVF), yüksek korelasyon filtresi

(HCF), rastgele ormanlar (RF) veya topluluk ağaçları (ET), geriye doğru özellik eliminasyonu (BFE), ileri özellik yapımı (FFC), temel bileşen analizi (PCA), izometrik haritalama (ISOMAP) ve daha fazlası. Ancak, PCA en çok kullanılan doğrusal boyutsallık azaltma tekniklerinden biridir, ISOMAP ise doğrusal olmayan boyut azaltma tekniklerinden biridir

[2]'de, hiperspektral görüntüleme boyutunun azaltılması için ayırıcı bir grafik tabanlı boyut azaltımı ve çok ölçekli uzatma tekniği önerilmiştir. Elde edilen sonuçlar, önerilen tekniğin, sabit özellik boyutunun azaltılması ile sınıflandırma doğruluğunu iyileştirmede hiperspektral görüntüleme için içsel bir gelişmeye sahip olduğunu kanıtlamaktadır. [3]'de, boyut indirgeme için işbirlikçi bir grafik tabanlı ayırıcılık analizi önerilmiştir. İşbirlikçi formu yakınlık matrisine yaklaşmak için uygulanır. Ek olarak, işbirlikçi grafik tabanlı ayırıcılık analizi, sınıf arası işbirlikçi grafik tabanlı ayırıcılık analizi için modifiye edilmiştir. Deneysel sonuçlar, sınıflar arası işbirlikçi grafik tabanlı ayırıcılık analizinin performansının ve doğruluğunun, her ikisinin de kısıtlılığı koruyan grafik yerleştirme ve seyrek grafik tabanlı ayırıcılık analizinden daha iyi olduğunu göstermektedir.

[4]'de, boyut küçültme için regresyona dayanan geliştirilmiş bir teknik önerilmiştir. Yöntem, PCA skorlarının varyansının azaltılmasına dayanmaktadır. Bu tekniğin, uygulanması kolay, tersine çevrilebilir ve dönüştürülmesi kolay olan doğrusal olmayan boyutsal indirgeme teknikleri üzerindeki avantajları korunur. Boyutsal indirgeme regresyonu ile elde edilen sonuçlar lineer PCA ve ana polinom analizi (PPA) ile karşılaştırıldığında daha az tekrar oluşturma hatası göstermiştir.

[5]'de, hiperspektral verileri analiz etmek için boyutsal indirgeme için ölçeklendirilebilen doğrusal olmayan bir teknik olarak bir randomize özellik haritası çizilmiştir. Dahası, verilerdeki değişkenler arasındaki doğrusal olmayan bağımlılığı belirlemek için ve ayrıca hiperspektral görüntü sınıflandırması için geleneksel çekirdek bileşen analizinin sınırlamalarının üstesinden gelmek üzere bir randomize minimum gürültü fraksiyonu önerilmiştir. Önerilen yöntem, hem çekirdek temel bileşen analizi (KPCA) hem de doğrusal PCA'ya göre daha kaliteli bir bileşen sunmaktadır.

[6]'da, grafik teori ve makine öğreniminin avantajları arasında birleştirilerek, hiperspektral verilerin yüksek sınıflandırma doğruluğunu elde etmek için örneklem

bağımlı itme grafiği düzenli hale getirilmiş otomatik kodlayıcı (SRGAE) boyutsallık azaltma algoritması önerilmiştir. SRGAE'nin, en yakın komşuluk grafikte mevcut olan mahalle parametresi seçim problemini önleyebilecek diğer sınıflandırma teknikleri üzerindeki ana avantajıdır.

[7]'de, CPU / GPU heterojen sistemine dayanan bir paralel çekirdek ana bileşen analizi algoritmasının (PKPCA), sınıflandırma doğruluğunu arttırmak için yüksek boyutlu verileri düşük boyutlu verilere indirilmesi önerilmektedir. PKPCA, seri çekirdek ana bileşen analizi algoritması (SKPCA) ile karşılaştırılır ve sonuçlar, daha sonraki olanın hızının yaklaşık 173 katı kadar PKPCA'dan daha az olduğunu kanıtlar. Ek olarak, bellek sınırlamalarının üstesinden gelmek için çok çekirdekli CPU'lar, düğüm içi paralelleştirmeyi kullanmak için kullanılır. Ayrıca, PKPCA ile karşılaştırıldığında 2.56 ~ 9.03 hıza ulaşan çok düzeyli hibrid paralel (MKPCA) önerilmiştir.

[8]'de, çok boyutlu nörogörüntüleme verilerini analiz etmek için Grafik Sinyal İşleme (GSP) önerilmiştir. Yöntem, simüle edilmiş ve gerçek fonksiyonel manyetik rezonans görüntüleme (fMRI) verileri üzerinde beyin aktivitesinin geometrik bağımlılıklarını modelleyen grafikler oluşturur. Deney sonuçları GSP'nin performansının PCA bandı Bağımsız Bileşen Analizi (ICA) 'dan daha iyi olduğunu kanıtlamaktadır.

[9]'da, veriler arasındaki doğrusal olmayan ilişkilerden yararlanmaya dayalı olarak, grafiklerin doğrusal olmayan boyutsal indirgenmesi için genel bir çerçeve ortaya konmuştur. Ek olarak, doğrusal olmayan korelasyonların korunması, düşük boyutlu temsillere dayanarak elde edilir. Önerilen çerçeve, muazzam gerçek veriler üzerinde test edilmiştir ve sonuçlar, bu çerçevenin doğrusal olmayan korelasyonları sıklıkla göz ardı eden diğer doğrusal yöntemlerle karşılaştırıldığında etkinliğini göstermektedir.

1.4 Hipotez

Hiperspektral veri görüntüleme sistemlerinin boyut indirgenmesi, PCA ve ISOMAP olmak üzere iki indirgeme tekniği ile gerçekleştirilecektir. PCA, lineer bir indirgeme tekniği olarak kabul edilirken ISOMAP, doğrusal olmayan bir tekniktir. PCA

geleneksel PCA yöntemi ve önerilen bant grupları yöntemi olarak uygulanacaktır. Bant grupları yöntemine bağlı olarak PCA'nın doğruluğu, geleneksel PCA yönteminden daha iyidir. Ek olarak, ISOMAP, PCA'dan daha iyi bir doğruluk sağlayabilir.





2. BOYUTLUK İNDİRGE ME

2.1 Boyutsal İndirgemeye Giriş

Son yıllarda laboratuvarların veri analizleri üzerinde çalıştığı, bu verileri analiz etmek için çok karmaşık araçlara ihtiyaç duyan devasa bir veriden muzdarip olduğu fark edilmiştir. Buna ek olarak, istatistik teknikleri bu kadar büyük veriyi işlerken daha fazla zorluklarla karşılaşmaya başladı. Yüksek boyutlu verilerin yüksek oranda artacağı ve dolayısıyla bu yüksek-boyutlu verilerin büyük bir bilgi kaybı olmaksızın çok daha küçük boyutlarda azaltılabildiği fark edilmektedir. Son günlerde, boyut indirgeme teknikleri olarak birçok teknik önerilmiştir meselâ eksik değerler oranı (MVR), düşük varyans filtresi (LVF), yüksek korelasyon filtresi (HCF), rastgele ormanlar (RF) veya topluluk ağaçları (ET), geriye doğru özellik eliminasyonu (BFE), ileri özellik yapımı (FFC), müdür bileşen analizi (PCA), izometrik haritalama (ISOMAP) ve diğer daha fazlası. Ancak, PCA en çok kullanılan doğrusal boyutsallık azaltma tekniklerinden biridir, ISOMAP ise doğrusal olmayan boyut indirgeme tekniklerinden biridir.

Bu tezde, geleneksel PCA ve band gruplarına uygulanan PCA doğrusal boyutsallık indirgemesi, ISOMAP ise doğrusal olmayan boyutsal indirgeme teknikleri olarak aşağıdaki bölümlerde detaylı olarak ele alınacaktır.

2.2 Hiperspektral Uzaktan Algılama

Hiperspektral sensörler uçak ve uydu platformlarında olmak üzere, yeryüzeyine ait spektral çözünürlüğü yüksek veriler sağlarlar. Dar frekans bandlarından sağlanan bu detaylı spektral veriler hedeflere ilişkin spektral imzaları oluştururlar. Bu çok sayıda ayrıntılı verilerde komşu bandlara ait olanlar birbirleriyle ilişkili olup, bu ilişki sınıflandırma başarımını özellikle parametrik sınıflayıcılar için düşürür. Bununla

birlikte bazı bandlar bulunduğu frekans bandı özelliklerinden dolayı gürültüdür. Boyut indirgeme ile çok sayıda band sınıflayıcıların karar başarımlarını düşürmeden azaltılabilir. Bu şekilde genelde az sayıda bulunan örnekler olaylar uzayını modellemek için daha etkin bir şekilde kullanılabilir.

2.3 Temel Bileşen Analizi Tabanlı Boyut İndirgeme

Temel bileşen analizi (PCA), veri analizi teknikleri içinde güçlü bir araçtır ve lineer cebirden elde edilen en değerli sonuçlardan biridir [10]. PCA, lineer dönüşüme dayanan basit bir istatistiksel tekniktir ve görüntü sıkıştırma, gen verileri analizi, bilgisayar grafikleri, meteoroloji, borsa tahminleri, yüz tanıma ve daha birçok veri analizi alanında uygulamaya sahiptir. PCA'nın önemi, ilgili bilgileri büyük verilerinden çıkarabilmesinden kaynaklanır, daha sonra önemli verileri, gizli dinamikleri ortaya çıkarmak ve gürültüyü çok fazla bilgi kaybı olmadan süzmek için bu verileri basitleştirir. Ek olarak, grafiksel temsile dayalı herhangi bir verinin yapısı sadece üç boyutla sınırlanırken, PCA tekniği yüksek boyutlu veri modelini bulabilir [11]. [12] 'de PCA, hem yüzü hem de cinsiyetini saptamak için bir teknik olarak önerilmiştir. Karmaşık görev, yüzün erkek mi dişi mi olduğunu tespit edebilen, ortalama kare hatası azaltarak sağlanır. [13] 'te, PCA'ya dayalı SNR'yi geliştirerek zayıf sinyal-gürültü-oranı (SNR) altında olgunlaşmamış hata taleplerini tespit etmenin bir yolunu önermiştir. [13] 'te PCA, sinyali filtreleyip SNR'yi geliştirebilen bir bant geçiren filtre gibi çalışmaktadır. [14] 'te, PCA, kolonun durumunu incelemek için özellik çıkarıcı olarak kullanılır. [15] 'te, yüz tanıma işleminde güvenlik düzeyini arttırmak için PCA'nın filigran tekniği ile birlikte kullanılması önerilmiştir. PCA'nın tamamlayıcısı olarak, filigran teknikleri sıralanırsa: ayrık kosinüs dönüşümü, en az anlamlı bitler ve ayrık dalgacık dönüşümü teknikleri sayılabilir. [16] 'da, görüntüyü kaynaştırmak için durağan dalgacık dönüşümü bir karma teknik olarak PCA ile birlikte kullanılır. Temel tekniklere dayanan önerilen teknikler: (1) görüntülerin dört alt gruba ayrıldığı sabit dalgacık dönüşümü kullanarak orijinal görüntülerin ayrıştırılması, (2) Özvektörler ve özdeğerler, her bir alt bantta PCA uygulanarak hesaplanır, (3) Yeni alt bantlar ters sabit dalgacık dönüşümü ile oluşturulmuştur. [16] 'daki melez teknikle elde edilen sonuçlar çok odaklı görüntü birleştirilmesi için etkilidir ve odak görüntü kolayca işlenebilir.

2.3.1 PCA Yöntemi

Temel bileşen analizi uygulaması bu bölümde adımlar halinde gösterilmiştir.

Adım 1: Sıkıştırma veya doku analizi için gereken verileri alın

Adım 2: Her bir boyut için verilerin ortalamasını hesaplayın, ve sonra $(X_i - \bar{X})$ her bir boyut için hesaplayın

Herhangi bir örnek verinin ortalamasını hesaplamak için aşağıdaki formül kullanılabilir:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (2.1)$$

Adım 3: Kovaryans matrisini hesapla

Veri kümesinin Standart Sapması (SD), verilerin yayılımının ve matematiksel olarak nasıl tanımlanabileceğinin bir ölçütüdür “Veri kümesinin ortalamasından bir noktaya [11] ortalama mesafe” ve aşağıdaki formülle hesaplanabilir:

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1}} \quad (2.2)$$

Varyans, veri kümesindeki verilerin yayılmasının başka bir ölçüsüdür ve SD ile hemen hemen aynıdır ve aşağıdaki formülle hesaplanabilir:

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1} \quad (2.3)$$

SD ve varyans sadece 1 boyut için geçerli olduğundan, SD ve veri setinin her boyutu için diğer boyutlardan bağımsız olarak varyansı hesaplamak için kullanılabilir. Ancak, farklılık boyutları arasındaki ilişkiyi incelemek için benzer bir ölçüye sahip olmak önemlidir. Bu nedenle, böyle bir ölçüm tekniği, kovaryans denilen gereklidir. Kovaryans her zaman iki farklı boyut arasında ölçülür. Kovaryans bir boyut ile kendisi arasında hesaplanırsa, Bu varyansı hesaplamak anlamına gelir. Matematiksel olarak kovaryans aşağıdaki formülle hesaplanır:

$$cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n - 1} \quad (2.4)$$

İkiden fazla boyutta bir veri kümemiz varsa, daha sonra, hesaplanabilen ve kovaryans matrisi olarak adlandırılan birden fazla kovaryans vardır. n boyutuna sahip bir veri kümesi için kovaryans matrisi aşağıdaki gibi yazılır:

$$C^{m \times n} = (c_{i,j}, c_{i,j} = cov(Dim_i, Dim_j)) \quad (2.5)$$

Burada $C^{m \times n}$ satır ve sütun içeren bir matris, ve Dim_i veya i^{th} boyuttur.

Üç boyutlu veri seti için kovaryans matrisi, normal boyutları kullanarak x, y ve z aşağıdaki gibi yazılmıştır:

$$C = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix} \quad (2.6)$$

Kovaryansın kesin değeri onun işareti kadar önemli değildir, ki bu değerler pozitif, negatif veya sıfır. Eğer kovaryans değeri pozitif ise, o zaman her iki boyutun birlikte artmakta olduğunu gösterir. Kovaryans değeri negatif ise, bir boyut arttıkça diğeri azalır. Son olarak, eğer kovaryans sıfır ise, bu iki boyutun birbirinden bağımsız olduğunu gösterir.

Adım 4: Kovaryans matrisinin özvektörlerini ve özdeğerlerini hesaplayın

Özvektörlerin ve öz değerlerin önemi, bize verilerimiz hakkında yararlı bilgiler verdikleri gerçeğinden kaynaklanmaktadır. Özvektörler üzerinde PCA tekniğini uygulamak için, özvektör matrisini normalleştirmek önemlidir. MATLAB'deki normalizasyon, “norm” komutu kullanılarak hesaplanabilir.

Tam sıralama N 'nin kare matrisini A düşünün. Bir vektör y , matris A 'nın bir özvektörü olduğu söylenir karşılık gelen bir özdeğer ile λ

$$A y = \lambda y \quad (2.7)$$

Denklemden verilen özdeğer problemi (2.7) aşağıdaki formüle göre analitik olarak çözülebilir:

$$(A - I \lambda)y = 0 \quad (2.8)$$

Denklemin her iki tarafının determinantını almak (2.8) λ cinsinden bir N^{th} düzen polinomu verir A 'nın karakteristik polinomu denir,

$$det(|A - I \lambda|)y = 0 \quad (2.9)$$

Denklem çözüme (2.9) N kökleri özdeğerlerini verir, ve her bir özdeğer λ_k karşılık gelen bir özvektöre y_k sahiptir. Dolayısıyla, özvektör probleminin çözümü, özdeğer ve karşılık gelen özvektör çiftini verir (λ_k, y_k) . Genelliği kaybetmeden, özvektörler genellikle aşağıda verildiği gibi ölçeklendirilir [17]:

$$|y| = \sqrt{y^T y} = 1 \quad (2.10)$$

Eğer özdeğerler λ_k ise, sonra her bir özdeğer için eşsiz bir özvektör vardır. (Normalize) özvektörler y_k ortonormaldir.

$$y_j^T y_k = \delta_{jk} \quad (2.11)$$

Denklemin ortonormalite durumu (2.11) aşağıdaki gibi yeniden yazılabilir:

$$Y^T Y = Y Y^T = I \quad (2.12)$$

Modal matrisi Y sütunları A'nın normalleştirilmiş özvektörleri olan matris olarak tanımlayın,

$$Y = [y_1 \ y_2 \ y_3 \ \dots \ y_N] \quad (2.13)$$

Genel olarak, özvektörlerin N! permütasyonu vardır. Genelliği kaybetmeden, özdeğerlerin azalan şekilde özvektörleri sıralanır,

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N \quad (2.14)$$

A matrisinin özdeğeri özdeğerlerinden oluşan bir ana diyagonal olan matris olarak köşegen matrisi Λ olarak (2.14) denklemde gösterildiği gibi tanımlanır.

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_N \end{bmatrix} \quad (2.15)$$

Özdeğer problemi matris notasyonunda yeniden yazılabilir,

$$A = Y \Lambda Y^T \quad (2.16)$$

(16) denkleminde , A'nın köşegenleştirilebilir matris olduğunu sonucuna varılır

Adım 5: Bileşenleri seçme ve dönüşüm matrisi oluşturma

Veri sıkıştırma ve boyut indirgeme kavramı burada açıklanacaktır. Bu adımda, veri kümesinin temel bileşeni olan en yüksek özdeğerlere sahip özvektörlerin belirlenmesi işlemi gerçekleştirilir [11]. Genel olarak, kovaryans matrisinden

özvektörler bulunduğunda, bir sonraki adım, onları özdeğer olarak en yüksekten en düşüğe doğru sıralamaktır. Bu sıralama, önem sırasına göre bileşenleri gösterir. Daha sonra, daha az önem taşıyan bileşenler göz ardı edilebilir ve bu göz ardı edilen bilgi küçük öz değerlere karşılık gelir. En yüksek değerlere karşılık gelen özvektörler, aşağıda verilen dönüşüm matrisini oluşturmak için kullanılır:

$$\text{Dönüşüm matrisi} = (eig_1 \ eig_2 \ eig_3 \ \dots \ eig_n) \quad (2.17)$$

Adım 6: Yeni veri kümesinin türetilmesi

Bu PCA'da son adım olarak kabul edilir, bileşenleri seçtikten sonra bir özellik vektörü oluşturduk, sadece vektörün aktarımını almak ve onu, aktarılan orijinal veri kümesinin solunda çarpma zorundadır. Son veri kümesi, sütunlardaki veri öğeleri ve satırlar boyunca boyutlardır ve aşağıdaki gibi hesaplanabilir:

$$\text{Dönüştürülmüş veri} = \text{Dönüşüm matrisi} \times \text{Veri} \quad (2.18)$$

Burada dönüşüm matrisi satırlarını özvektörler oluşturur, veri sıfır ortalamalı hale getirilmiş veridir. Sıkıştırma tekniği olarak PCA 'nın en önemli özelliği aşağıdaki formülleri kullanarak özgün verilere geri dönme becerisidir:

$$\text{Veri} = \text{Dönüşüm matrisi}^{-1} \times \text{Dönüştürülmüş veri} \quad (2.19)$$

Burada $\text{Dönüşüm matrisi}^{-1}$ Dönüşüm matrisi tersidir.

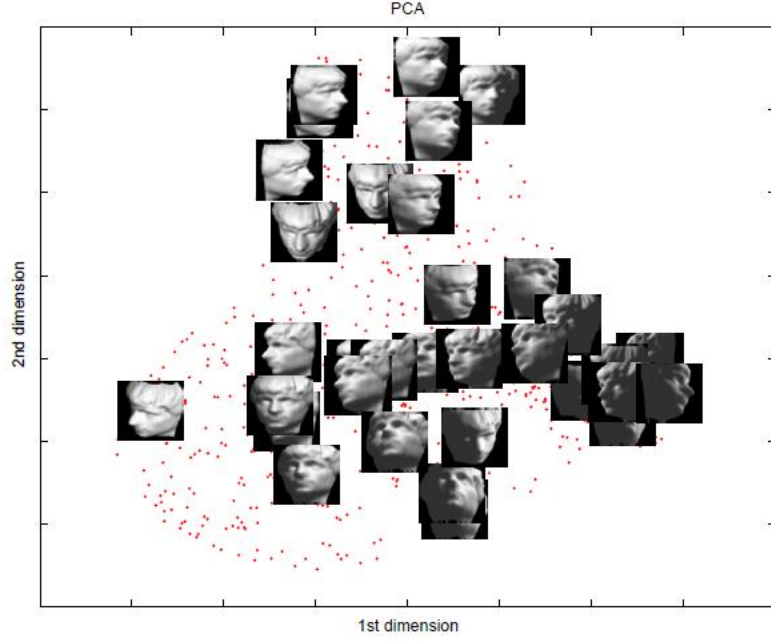
Dönüşüm matrisini oluşturan özvektörler ortonormal olduğundan Dönüşüm matrisin tersi Dönüşüm matrisinin transpozuna eşittir. Denklem (2.19) aşağıdaki şekilde yeniden yazılabilir:

$$\text{Veri} = \text{Dönüşüm matrisi}^T \times \text{Dönüştürülmüş veri} \quad (2.20)$$

Bu dönüşüm işleminden sonra orijinal verileri geri almak için, formül tarafından verilen orijinal verilerin ortalamasını eklemek önemlidir:

$$\begin{aligned} &\text{Original Veri} \\ &= (\text{Dönüşüm matrisi}^T \times \text{Dönüştürülmüş veri}) \\ &+ \text{Orijinal veri ortalaması} \end{aligned} \quad (2.21)$$

n boyutlarında bir dizi veri verildiğinde, PCA, n 'den daha düşük bir boyutun d doğrusal bir alt uzayını bulmayı amaçlamaktadır. Veri noktaları, Şekil 2.1'de gösterildiği gibi, bu doğrusal alt uzayda esas olarak yer alır. Böyle bir azaltılmış alt uzayda verilerin değişimlerinin çoğunu korunması amaçlanır.



Şekil 2.1: PCA iki boyutlu veri kümesine uygulandı

Şekil 2.2 PCA akış şemasını göstermektedir.

2.3.2 Bilgisayarlı Görüde PCA

2.3.2.1 Temsilcilik

Görüntüler bilgisayarda matris olarak temsil edilir. Bu görüntüler $N \times N$ boyutuna sahip bir kare matris olarak ifade edilebilir, bu nedenle, bir resim aşağıdaki gibi bir N^2 -boyutlu vektör olarak gösterilebilir:

$$X = (x_1 \quad x_2 \quad x_3 \quad \dots \quad x_{N^2}) \quad (2.22)$$

Bilgisayarlı görüde, tek boyutlu bir görüntü oluşturmak için görüntüdeki piksel satırları birbiri ardına yerleştirilir, böylece ilk N elemanı ilk satır ve son satır N^2 'dir.

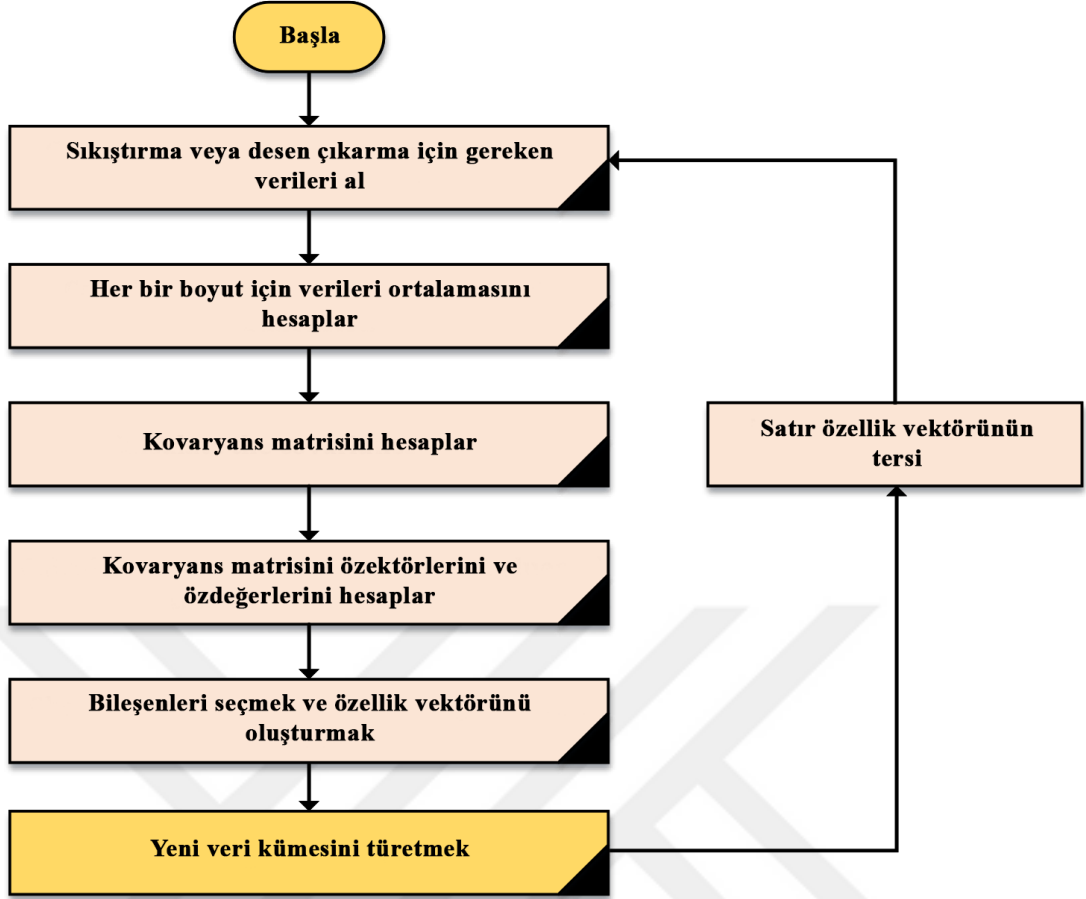
2.3.2.2 Model Bulmak İçin PCA

Her biri $N \times N$ boyutuna sahip m adet görüntü olduğunu varsayalım. Her görüntüyü (2.22) denkleminde verilen bir görüntü vektörüyle ifade edebiliriz. Daha sonra, tüm görüntü vektörleri denkleminde verildiği gibi bir arttırılmış görüntü-matrisinde birleştirilebilir (2.23).

$$\text{Görüntüler – Arttırılmış matris} = \begin{pmatrix} X_1 \\ X_2 \\ \cdot \\ \cdot \\ X_m \end{pmatrix} \quad (2.23)$$

Görüntü-matrisinin önemi bilgisayar görüntülemesinde kullanılacak yeni görüntü ile orijinal görüntüler arasındaki farkı ölçmekten kaynaklanmaktadır.





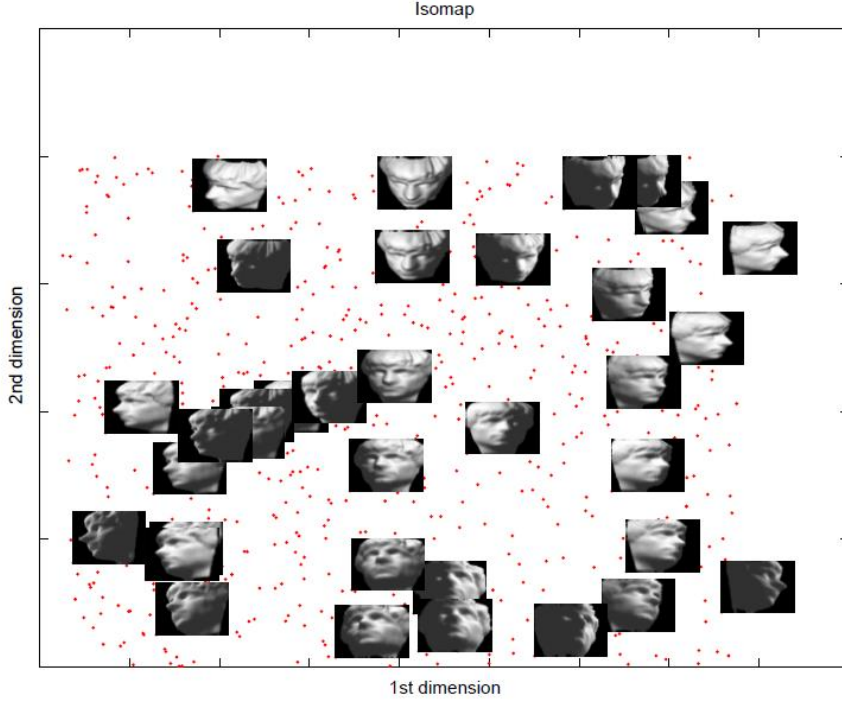
Şekil 2.2: PCA akış şemasıdır

2.3.2.3 Görüntü Sıkıştırma İçin PCA

PCA görüntü sıkıştırma kullanıldığında, aynı zamanda Hotelling veya Karhunen ve Leove dönüşümü olarak da adlandırılır. PCA'nın her biri N^2 piksel olan I adet görüntüden oluştuğunu düşünürsek ve bu veri kümesinde dönüşüm sonrası O adet verinin seçilinde sıkıştırma oranı O/I olarak gerçekleşmiş olur.

2.4 İzometrik Özellik Haritalama Tabanlı Boyut İndirgeme

PCA'dan farklı olarak izometrik özellik haritalama (ISOMAP), doğrusal olmayan bir boyut (öznitelik) indirgeme yöntemidir. ISOMAP Şekil 2.3'te gösterildiği gibi, yüksek boyutlu doğrusal olmayan bir manifold üzerindeki noktaları daha düşük boyutlu bir koordinat kümesine eşlemeye çalışır. Ek olarak, ISOMAP yüksek sinyal-gürültü oranına (SNR) sahip sistemlerle uğraşırken güçlüdür. ISOMAP görselleştirme ve sınıflandırma olmak üzere iki şekilde kullanılabilir.



Şekil 2.3: ISOMAP iki boyutlu veri kümesine uygulanır

2.4.1 ISOMAP Yöntemi

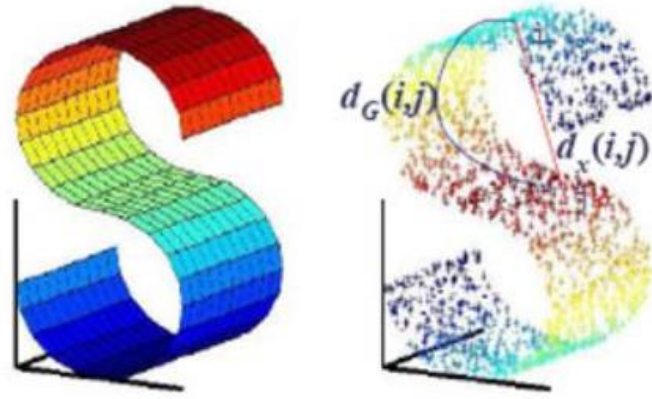
ISOMAP kullanarak yüksek boyutlu verileri işlemek için adımlar aşağıdaki gibi özetlenebilir:

Adım 1: Komşuluk grafiği

Tüm veri noktaları veya veri kümesinden bitişik matris için bir Komşuluk grafiği oluşturun. Bu adımda, M manifoldundaki komşuları belirlemek gereklidir. Bunun için iki yöntem vardır, ilk olarak maksimum Öklid arama mesafesi, herhangi bir noktanın küçük yarıçaplı ϵ ile çevresindeki tüm noktalara bağlanması ve ikinci olarak en yakın komşu κ sayısını kullanılmasıdır. Komşuluk ilişkileri, veri noktaları üzerinde ağırlıklı bir grafik olarak oluşturulmuştur. Komşu noktalar arasındaki ağırlık kenarları $d_x(i, j)$ olarak tanımlanır. Şekil 2.4 yerel Komşuluk grafiğinin nasıl oluşturulacağını gösterir.

Adım 2: Jeodezik mesafelerin hesaplanması

G grafiği küçük atlamalardan oluşur. M manifoldundaki tüm noktalar arasındaki tüm jeodezik mesafeler $d_G(i, j)$ küçük öklid mesafelerin birleştirilmesiyle yaklaşık olarak hesaplanır ve sonra en kısa yol mesafesi $d_G(i, j)$ grafik G 'de hesaplanır. Şekil 2.5 ISOMAP'a dayalı $d_G(i, j)$ tahminini gösterir.




Şekil 2.4: Yerel komşuluk grafiğinin oluşturulması


Adım 3: Düşük boyuta indirgeme

küçük boyuta indirmek için çok boyutlu ölçekleme (MDS) tekniği, $d_G(i,j)$ grafik uzaklığı matrisine uygulanır.

Tüm ISOMAP adımları Şekil 2.6'da açıklanmıştır.



Şekil 2.5: ISOMAP'a dayalı $d_G(i,j)$ tahmini



Şekil 2.6: ISOMAP akış şemasıdır

2.4.2 Çok Boyutlu Ölçekleme

Çok boyutlu ölçekleme (MDS), bir çok nesnenin göreceli konumlarını gösteren bir harita oluşturan bir tekniktir, ve aralarındaki mesafeleri tablo olarak verir. Harita bir boyutlu veya çok boyutlu olabilir. Mesafeler tablosu yakınlık matrisi olarak bilinir. MDS'yi çözmek için metrik (klasik), ve metrik olmayan şekilde iki yöntem vardır. Klasik çok boyutlu ölçekleme (CMDS), orijinal metriği veya mesafeleri oluşturmaya çalışır. Bununla birlikte, metrik olmayan çok boyutlu ölçekleme (NMMDS) yalnızca mesafelerin derecesinin bulunduğunu bildiğinden, mesafelerin sıralarını oluşturmaya çalışır.

2.4.2.1 Klasik Çok Boyutlu Ölçeklendirme

CMDS, bu tekniğin temellerini açıklamak için tekniğin öncülerinden Torgerson (1952) nın yöntemini açıklamak yararlıdır. Torgerson'un algoritmasında bir uzaklık

matrisinin olan D , X boyutlarının bir konfigürasyonunun noktalar arası mesafelerine, düşük boyutlu bir boşlukta n ($n = 1, 2, \text{ or } 3$) yaklaştığını varsayar. Yani, D uzaklık matrisini oluşturan unsurlar d_{ij} , aşağıdaki formül kullanılarak X 'den hesaplanabilir:

$$d_{ij} = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (2.24)$$

CMDS adımları aşağıdaki gibidir:

1. Matris D 'dan $A = \left\{ -\frac{1}{2} d_{ij}^2 \right\}$ hesaplanır.
2. A 'dan B matrisi $B = \{a_{ij} - a_{i.} - a_{.j} - a_{..}\}$, şeklinde hesaplanır, burada $a_{i.}$ tüm a_{ij} 'in bütün j ler için ortalamasıdır.
3. B 'nin en büyük n özdeğerini bulun $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_n$ şeklinde sıralanır ve ilgili özvektörler $L = (L_{(1)}, L_{(2)}, \dots, L_{(n)})$ normalize edildiği için $L_{(i)}' L_{(i)} = \lambda_i$ dır.
4. Nesnelerin koordinatları L 'in satırlarıdır.



3. DESTEK VEKTÖR MAKİNELERİ VE K-EN YAKIN KOMŞULUK SINIFLANDIRICILARI

3.1 Giriş

Bu bölümde, Destek Vektör Makineleri (SVM) açıklanmaktadır. SVM ile birlikte bu tezde sınıflayıcı olarak kullanılan K- en yakın komşuluk yöntemi de kullanıldığından K-en yakın komşuluk sınıflandırma yönteminden bahsedilmiştir.

3.2 Destek Vektör Makinelere Giriş

Veri sınıflandırması çok karmaşık hale geldiğinden, genellikle zor ve bazen de görüntüleme, mühendislik, iş vb. karmaşık sistemler için imkansızdır. Bununla birlikte araştırmacıların veri sınıflandırma tekniklerini geliştirmedeki ilgileri gün geçtikçe artmaktadır. Buna göre, birçok araştırmacı, SVM kullanarak hiperspektral görüntünün sınıflandırılmasıyla ilgilenmiş ve birçok çalışmada, bunun güçlü bir araç olduğunu kanıtlamıştır.

[18]'te, T. A. Moughal, hiperspektral imgelerin çok-sınıflı sınıflandırma problemini çözmek için farklı sınıflayıcılar arasında karşılaştırmalı bir çalışma sunmaktadır; Karşılaştırma iyi bilinen yöntemler Destek Vektör Makinesi, Maksimum Olabilirlik (ML) ve Spektral Açık Haritası (SAM) arasında yapılmıştır. Sınıflandırma görevinden önce, yazar hiperspektral görüntüden mümkün olan en iyi özellikleri çıkarmak için veri ön işleme yöntemi olarak Minimum Parazit Kestirimini (MNF) uygulamıştır. Ve orijinal bilgiyi kaybetmeden veri boyutunun azaltılmasını sağlamıştır. Bu çalışmada kullanılan veriler havadan Hiperspektral Dijital Görüntü Toplama Deneyi (HYDICE) tarafından Washington DC Mall bölgesinden alınmıştır ve.

Bu çalışmada elde edilen bazı sonuçlar:

- Maksimum Olabilirlik (ML) ve Spektral Açık Haritası (SAM) ile karşılaştırıldığında, SVM, sınıflandırma doğruluğu, hesaplama süresi ve parametre ayarlarında kararlılık açısından en iyi sınıflandırıcıydı.
- SVM %78.39'luk gibi bir doğruluk elde etmiş ve en yüksek sınıflandırma doğruluğunu sağlamıştır.

- SVM, diğer iki sınıflandırıcıya kıyasla iyi performansını göstermiştir.
- SVM'in başarısı sınıflar arası mesafeyi en üst düzeye çıkarmak ve sınıflandırma görevini kolaylaştırmak ve düzeltmek için en iyi hiper düzlemin kullanılmasıyla açıklanabilir.

Ek olarak, yazarlar [19]'da, hiperspektral görüntülerin sınıflandırılmasında SVM'nin etkinliğini kanıtlamışlardır; Bu araştırmada, yazarlar SVM sınıflandırma yöntemini, havadaki CASI sensöründen, 450 ila 950nm arası 17 spektral bant ile hiperspektral bir görüntüye uyguladılar. Bu araştırmanın amacı, orman, su, yollar ve çorak arazileri, vb. tespit etmek ve ayırmaktır, yazarlar, klasik yöntemlerin yanlış sınıflandırma oranını azaltmada SVM'nin etkinliğini kullanılan farklı hiperspektral görüntüleri de doğru şekilde sınıflandırarak göstermişlerdir.

[20]'de, yazarlar hiperspektral görüntü sınıflandırması alanında SVM'nin önemini tartışır; Bu araştırmada kullanılan veriler, 1992 yılında kuzeybatı Indiana'dan AVIRIS sensörü tarafından alınan Indian Pines verisidir. Bu araştırmada, yazarlar, SVM'nin etkililiğini, radyal temel fonksiyonları (RBF'ler) sinir ağı ve K-en yakın komşular (K-NN) sınıflandırıcısı olan iki klasik sınıflandırma yöntemi ile karşılaştırmışlardır. Yazarlar, SVM'ni ilk olarak RBF sinir ağı ile karşılaştırmayı iki yönteminde çekirdek tabanlı sınıflayıcı olması yüzünden tercih etmişlerdir ve ikinci olarak da KNN yöntemi ile model tanıma alanında bir referans yöntem olması dolayısıyla karşılaştırma yapmışlardır. Ayrıca, araştırmasını geliştirmek için, yazar iki tip SVM yöntemi kullanmıştır: doğrusal ve doğrusal olmayan tip. Bu araştırmanın sonuçları SVM yönteminin ve özellikle doğrusal olmayan yöntemin %87.76'lık bir doğruluğu sağlayarak etkinliğini kanıtlamıştır. KNN sınıflandırıcı ise %61.16 ile en kötü sınıflandırma doğruluğunu elde etmiştir. Bu sonuçları tekrar geliştirmek için, yazar Jeffries – Matusita (JM) arası mesafe ölçümünü [13] ve En dik çıkış (Steepest Ascent -SA) hata en aza indirme stratejisini kullanarak boyut indirgeme yöntemini veri kümesine uygulamışlardır. Elde edilen sonuçlar, lineer olmayan SVM'lerin etkililiğini, bir önceki sınıflandırıcılar ile karşılaştırıldığında %8 daha fazla doğruluk oranına sahip olduğunu göstermektedir; Sonuç olarak, bu araştırmada, yazar sadece SVM yönteminin önemini değil, aynı zamanda hiperspektral görüntü sınıflandırmasında lineer olmayan SVM'in etkin ve başarımı yüksek bir yöntem olduğunu doğrulamaktadır.

[21]'de, yazarlar karar ağacı, Geri Yayılım (BP) ve sinir ağı sınıflandırıcıları ile hiperspektral görüntü sınıflandırmasında SVM yöntemini karşılaştırmışlardır; yazarlar, 16 sınıf bir AVIRIS görüntüsünü sınıflandırmışlar ve sınıflandırmada nöral ağ sınıflandırıcısının radyal temel fonksiyonunu (RBF) seçmişlerdir. Elde edilen sonuçlara göre SVM ile %96.94 'lük başarımla çok iyi bir doğruluk elde edilmiş olup bu başarımla SVM'nin etkinliğini kanıtlanmıştır. SVM'in ardından ise karar ağacının elde ettiği doğruluk oranı %74.75 olup en düşük sınıflandırma başarımla BP RBF sinir ağı ile elde edilen %38,03 'lük başarımla olmuştur.


[22]'de, Yazarlar, zaman ve maliyetin düşürülmesi amacıyla sınıflandırma görevinden önce veri boyutunun azaltılmasının önemine olan ilgilerini göstermişlerdir; Yazarlar boyut azaltma yöntemi olarak PCA yöntemini ve sınıflandırma yöntemi olarak SVM yöntemini seçmişlerdir. Bu araştırmada, Bir Dünya Gözleme-1 (EO-1) Hyperion görüntüleri üzerinde sayısal örnek kullanıldı. Yazarlar hiperspektral görüntü sınıflandırmasını boyut küçültme ve boyut küçültme olmadan karşılaştırmış ve veri boyutunun azaltılmasının elde edilen doğruluğu etkilediğini ve elde edilen sonuçları iyileştirdiğini doğrulamıştır.

3.3 Destek Vektör Makinesi Sınıflandırıcısı

Destek Vektör Makineleri (SVM) veya Geniş Kenar Boşluklu Ayırıcılar (SVM), Vapnik tarafından sunulan ve genellikle büyük öznelik boyutuna sahip veriler için görüntüleme, konuşmacı tanıma, veri madenciliği, tıbbi analiz gibi çeşitli alanlarda kullanılan bir sınıflandırma yöntemidir [23-27].

Şekil 3.1'de gösterilen, SVM'nin fikri, doğrusal olmayan uzaya ait verilerin, iki önemli koşulu dikkate alarak bu verileri doğru bir şekilde ayırabilen bir hiper düzlem kullanılarak verilerin doğrusal olarak ayrılabilmesi için yeni bir alana aktarılmasını içerir [28]:

- Farklı sınıfların örnek vektörleri karar yüzeyinin farklı yönlerde olacaktır.
- Vektörler ve hiper düzlem arasındaki mesafe maksimize edilmelidir.



Şekil 3.1: SVM Genel prensip

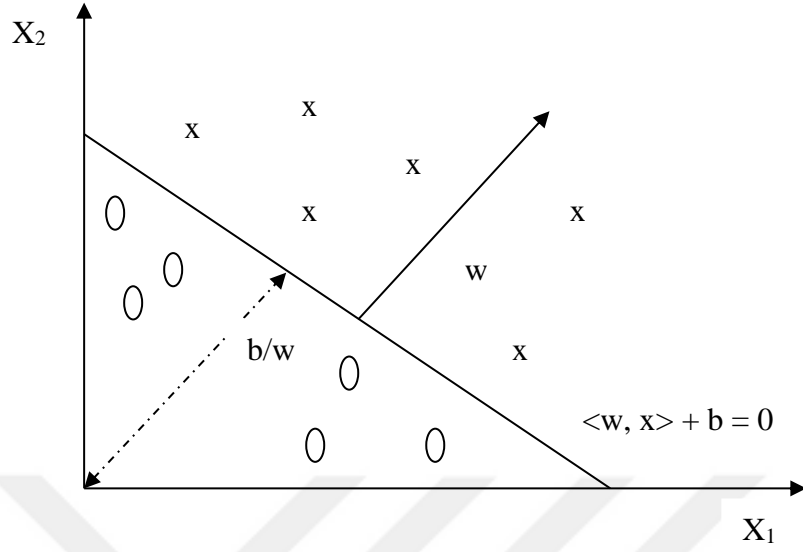
Veri setinin D olduğunu varsayarak $D = \{(x_1, y_1) \in R^d\}$, x bir gözlem, yise x gözlemlerinin hangi sınıfa ait olduğunu gösteren etikettir. SVM prensibi uygulayarak, (3.1) denklemi çözerek verileri ayırabilen hiper düzlemi bulmaktır: [29-31].

$$H(x) = w^T x + b = 0 \quad x, w \in R^d \quad b \in R \quad (3.1)$$

Denklem (3.1)'i optimize ederek, aşağıdaki sistem problemini dönüştürülebilir: En uygun hiperdüzlemi bulmak için denklem (3.3) marjı maksimize eden denklem (3.2) koşulu altında çözülebilir.

$$\begin{cases} \text{Min} \frac{1}{2} \|w\|^2 & (3.2) \\ y_i (w^T x_i + b) \geq 1 \quad \forall i = 1, \dots, m & (3.3) \end{cases}$$

Şekil 3.2'de, Verileri en uygun şekilde ayıran bir hiper düzlemin temsili gösterilmiştir.



Şekil 3.2: SVM prensip

Genel olarak, veriler doğrusal olarak ayrılabilir değildir, Böylece SVM'nin ikinci fikri, doğrusal ayırmanın mümkün olabileceği daha yüksek boyutlu bir uzaya orijinal uzayı transfer eden çekirdek prensibini kullanarak verileri doğrusal olmayan alandan yeni bir doğrusal alana transfer etmektir [32].

En çok kullanılan çekirdek fonksiyonları:

Doğrusal çekirdek: $K(x_i, x_j) = x_i^T x_j$

Polinom çekirdeği: $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$

RBF çekirdeği: $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$

Sigmoid çekirdeği: $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Bu tezde RBF SVM kullanılmıştır.

3.4 K-En Yakın Komşuluk Sınıflandırıcısına Giriş

Birçok araştırmacı, KNN yöntemini en temel parametrik olmayan yöntem olarak kullanarak hiperspektral görüntünün sınıflandırılmasıyla da ilgilenmiş ve KNN yönteminin çeşitli çalışmalarda etkinliğini kanıtlamıştır.

[33]'te, yazar tarımsal faaliyetlerini haritalamak için hiperspektral uzaktan algılama görüntüleri kullanmada KNN ve SVM yöntemleri arasında karşılaştırmalı bir çalışma önermiştir. Yazarlar, AVIRIS sensörü tarafından toplanan veri kümesini kullanmışlardır.

SVM ve KNN tarafından elde edilen doğruluk sonuçları sırasıyla %93.62 ve %92.31'dir. Burada sonuçlar çok iyi olup her iki yöntemin de etkinliği bu çalışmada bu veri seti için gösterilmiştir.

[34]'te, yazarlar ayrıca hiperspektral görüntüleri bir spektroskopik sensörden sınıflandırmak için KNN yönteminin etkinliğini göstermişlerdir. Bu çalışmadaki amaç, daha iyi sınıflandırma sonuçları elde etmek ve aynı zamanda yöntemlerin çalışma süresini azaltmak için PCA yöntemini ve KNN'yi birleştirmektir.

3.5 K-En Yakın Komşular Sınıflandırıcı


Farklı sınıflandırma yöntemleri arasında, K-En Yakın Komşular (K-NN) algoritması, veri sınıflandırmasının en basit algoritmaları olarak kabul edilir.

KNN Fix ve Hodges tarafından sunulmuştur [35]; KNN'yi diğer yöntemlerle karşılaştırarak, KNN'nin belleğe dayandığı ve karar vermek için bir model oluşturmayı gerektirmediği söylenebilir.

KNN prensibi aşağıda açıklanmıştır:

Belirli bir D veri seti için, d bir mesafe fonksiyonu, K bir tam sayı (komşu sayılarını temsil eder), ve x sınıflandırılacak yeni bir örnek olmak üzere; KNN yöntemi, D veri seti içerisinde x'e en yakın K örneğinin aranmasını içerir, ve K komşular arasında en yaygın elemanları içeren sınıfı x örneğinin sınıfı olarak atar.

KNN çalışma prensibi Şekil 3.3'te açıklanmıştır [35].



Şekil 3.3: KNN çalışma prensibi

KNN yönteminin etkinliği, en yakın kaç komşunun karar verileceğini belirleyen K 'nin seçimine bağlıdır; Yöntemin kullanılmaya başladığı günden beri K 'yi tanımlayabilecek genel bir kural yoktur ve kullanılan veri tabanı boyutlarını dikkate alarak uygulamaya bağlı olarak K kullanıcılar tarafından seçilir.



4. DENEYLER VE SONUÇLAR

4.1 Giriş

Bu bölümde, tezde tasarlanan deneyler ve deney sonuçları verilmektedir; İlk olarak veri boyut indirgeme teknikleri kullanarak elde edilen sonuçlar SVM sınıflandırma yönteminde kullanılmış ve boyut indirgemek için ise PCA ve ISOMAP kullanılmıştır daha sonra ise ikinci sınıflandırma yöntemi olan KNN ile birleştiren ikinci veri azaltma tekniği olan ISOMAP ile elde edilen sonuçlar verilmiş ve yorumlanmıştır.

4.2 İş İçeriği

4.2.1 Geliştirme Ortamı

Deneylemizimizin uygulanması MATLAB “R2016b” kapsamında gerçekleştirilmiştir. MATLAB bilimsel problemleri çözmek için geliştirilen vektör, matris ve temel işlemleri sağlayan bir dördüncü nesil programlama dilidir.

4.2.2 AVIRIS Indian Pines Veri Seti

Bu tezde 1992 yılında ABD'nin Kuzeybatı Indiana bölgesinin Indian Pines tarım alanı üzerinden alınan, literatürde yaygın olarak kullanılan Havadan Görünebilir / Kızılötesi Görüntüleme Spektrometresi (AVIRIS) ile alınan verilerle uygulama yapılmıştır.

Bu veri kümesi, 145×145 piksel boyutunda bir alan için olup piksel başına 20 m uzamsal çözünürlüğü bulunmaktadır. AVIRIS Indian Pines verisi 220 banttır ve 220 bandttan gürültülü ve düşük işaret gürültü oranlı bantlarını çıkararak 200 bant 17'ye kadar sınıf içerecek şekilde deneylerde kullanılmıştır. [36, 38].

AVIRIS Indian Pines veri seti Şekil 4.1 bir örnek bandıyla birlikte referans yer verisiyle birlikte kullanılmaktadır.




Şekil 4.1: AVIRIS Indian Pines veri kümesinin (a) Örnek bandı ve (b) referans yer verisi

Deneylerde AVİRİS veri seti kullanılmasının nedeni bu veri setinin literatürde bilinen ve güvenilir bir veri seti olduğundan önerilen yöntemlerin başarımlarını analizlerini doğru şekilde yapılmasına imkan verdiği içindir.


4.3 Deney

Bu tezde tasarlanan deneylerin blok şemaları aşağıdaki şekillerde açıklanmıştır; Tasarlanan ilk deney Şekil 4.2'de gösterilmiş olup burada ilk olarak PCA boyut indirgemek için kullanılmıştır; İndirgenmiş verilerin sınıflandırılmasında ise RBF-SVM sınıflayıcı olarak kullanılmıştır.



Şekil 4.2: PCA ve SVM kullanarak veri sınıflandırması

İkinci olarak tasarlanan deneyde ise Şekil 4.3'te gösterdiği gibi ISOMAP yöntemi boyut indirgeme tekniği olarak kullanılmış ve sınıflandırma yöntemi olarak da KNN sınıflandırıcı kullanılmaktadır. Bu nedenle uygulamada ilk önce AVIRIS Indian Pines veri kümesi ISOMAP ile boyut indirgenir ve indirgenmiş verilerin sınıflandırılması için ise KNN sınıflandırıcı kullanılacaktır.




Şekil 4.3: ISOMAP ve KNN kullanarak veri sınıflandırması

Uygulamada, PCA tabanlı boyut azaltma doğruluğunu araştırmak için, geleneksel PCA yöntemi ve PCA gruplama yöntemi olmak üzere iki farklı PCA uygulaması kullanılmıştır. Bu uygulamadan PCA bant gruplama yöntemi bu tezde özellikle Hiperspektral veri sınıflandırmada boyut indirgeme için önerilmiştir. Bu temel deneylerin yanında İSOMAP boyut indirgemesi sonrasında RBF-SVM sınıflandırması başarımı da araştırılmıştır.

Durum 1: Geleneksel PCA yöntemi

Geleneksel PCA yönteminde 200 bandın tamamına PCA uygulanmış ve dönüşüm uzayında bantlar en anlamlı temel banttan en az anlamlı banda sıralanmıştır. Sınıflayıcıya en anlamlı temel banttan başlayarak her bir adımda 1 adet temel bant eklenerek öznelik sayısı bir arttırılmış ve her bir adımda RBF-SVM başarımı test edilmiştir. Diğer bazı çalışmalarda da rapor edildiği gibi PCA'nın tüm veriye uygulanarak dönüşüm uzayındaki bileşenlerin birer eklenmesi durumunda başarımın çok düşük olduğu görülmüştür PCA'nın geleneksel biçimde kullanılmasıyla iyi bir

sınıflandırma başarımı elde edilememiştir. Bu durumu düzeltmek için bu tezde PCA gruplama yöntemi önerilmiştir.

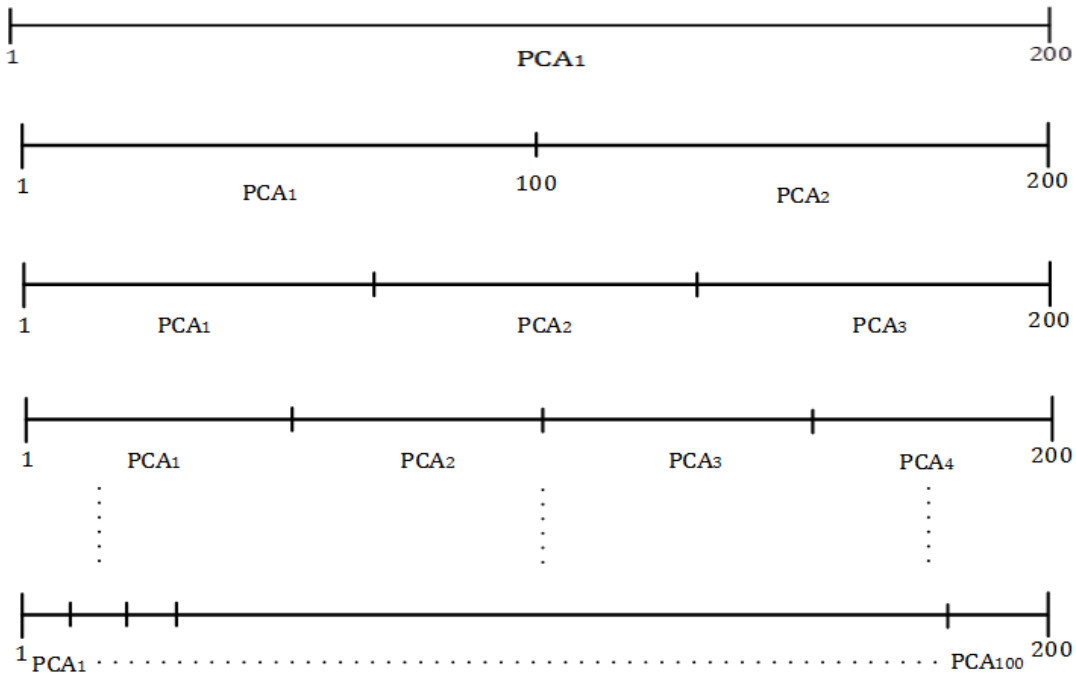


Şekil 4.4: Geleneksel PCA yöntemi

Durum 2: PCA gruplama yöntemi

Hiperspektral verilerde komşu bandlar arasında ilişki yüksek olduğundan PCA'nin hiperspektral verinin tamamına uygulanması başarılı sonuç vermediğinden PCA gruplama yöntemi kullanılmıştır.

PCA gruplama yönteminde, ilk 200 banda PCA uygulanır, ve en anlamlı temel bileşen ilk öznelik olarak alınır ve sınıflandırıcının girişine uygulanır. Şekil 4.5'de gösterildiği gibi tüm 200 bant 2, 3, 4 ve 200 gruplara ayrılarak her bir gruba ayrı ayrı PCA uygulanır ve her bir gruptan elde edilen 1. Temel bileşen alınarak elde edilen öznelik vektörü kullanılarak RBF-SVM sınıflayıcının başarımı ölçülür. Bu durumda elde edilen sınıflandırma başarımlarının kabul edilebilecek düzeyde iyi olduğu görülmüştür. Yapılan deneylerde belirli bir seviyeye kadar öznelik sayısının artışına paralel olarak sınıflandırma doğruluğunun da arttığını fark edilmiştir.



Şekil 4.5: PCA gruplama yöntemi

Bizim çalışmamızda temel fikir AVIRIS Indian Pines veri setinde varolan tüm sınıflarla yani 17 sınıfla çalışmaktır, ancak 17 sınıflı veri kümesinde azınlık ve çoğunluk sınıflarının yanında karışık sınıf olan arka plan sınıfıda yer almaktadır. Bu yüzden arka plan sınıfının hariç tutulduğu 16 sınıflı veri setinde test edilmesi gerçekleştirilmiştir. 16 sınıflı veri setinde bazı sınıfların az sayıda örneğe sahip olması dolayısıyla istatistiksel olarak yeterli sayıda olmaması yüzünden bu örnekler azınlık sınıfları olarak adlandırılarak kalan sınıfları içeren 9 sınıflı AVIRIS Indian Pines veri seti de oluşturulmuş ve bu veri setine ilişkin deneylerde yapılmıştır.

Özetle bu tezdeki deneylerde 17, 16 ve 9 sınıf olmak üzere üç farklı sınıf kombinasyonu içeren veri seti kullanılmıştır.

Tablo 4.1, eğitim ve test örnekleri 17 sınıf ve 16 sınıflı veri kombinasyonu için sınıf tanımlarıyla verilmektedir.

Çizelge 4.1: AVIRIS Indian Pines 17 ve 16 sınıflı veri kümeleri için örnek sayısı

LABEL	17 Class Data Set			16 Class Data Set		
	Class	Training	Testing	Class	Training	Testing
Background	w1	719	2627	-	-	-
Alfalpa	W2	16	39	w1	16	39
Corn-Notill	W3	201	720	W2	201	720
Corn-Min	W4	157	498	W3	157	498
Corn	W5	63	117	W4	63	117
Grass/Pasture	W6	112	265	W5	112	265
Grass/trees	W7	207	409	W6	207	409
Grass/Pasture moved	W8	12	24	W7	12	24
Hay-Windowed	W9	196	374	W8	196	374
Oats	W10	14	16	W9	14	16
Soybeans-Notill	W11	255	519	W10	255	519
Soybeans-Min	W12	545	1302	W11	545	1302
Soybeans-Clean	W13	128	310	W12	128	310
Wheat	W14	102	132	W13	102	132
Woods	W15	546	870	W14	546	870
Bldg-Grass-Tree	W16	109	229	W15	109	229
Stone Steel Towers	W17	21	44	W16	21	44
Total Number of Samples		3403	8495		2684	5868
Whole Scene		21065			10366	

Tablo 4.2'de ise eğitim ve test örnekleri 9 sınıflı veri seti için tablolanmıştır.

Bir önceki bölümde açıkladığımız gibi, tezin amacı sınıflandırma görevlerinde boyut küçültme tekniklerinin başarıma etkilerini ve önemini açıklamaktır.

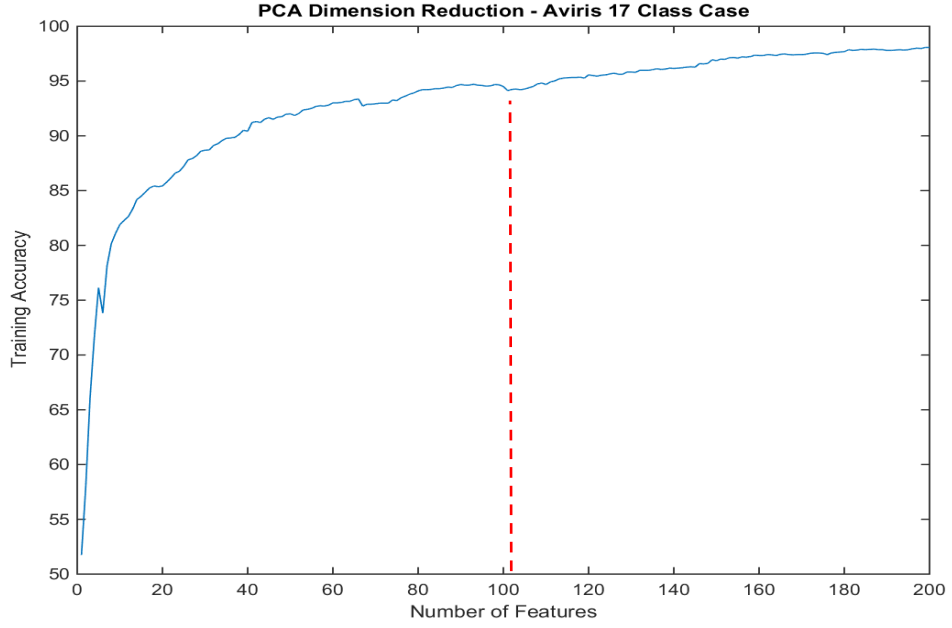
Bu nedenle, PCA ve ISOMAP olan iki farklı boyut indirgeme tekniğini test edilmiştir.

Çizelge 4.2: AVIRIS Indian Pines 9 sınıflı veri kümesi için örnek sayıları

LABEL	17 Class Data Set		
	Class	Training	Testing
Corn-Notill	W1	288	288
Corn-Min	W2	200	200
Grass/Pasture	W3	197	197
Grass/trees	W4	200	200
Hay-Windowed	W5	209	209
Soybeans-Notill	W6	193	193
Soybeans-Min	W7	493	493
Soybeans-Clean	W8	199	199
Woods	W9	258	258
Total Number of Samples		2237	5809
Total Number of Samples		9345	


4.3.1 PCA Yöntemi

PCA metodu kullanılarak, eğitim, test ve tüm veri doğruluğu için 17 sınıf örneğinden elde edilen sonuçlar sırasıyla Şekil 4.6, Şekil 4.7 ve Şekil 4.8'de gösterilmiştir.



Şekil 4.6: 17 sınıflı veri eğitim örnekleri için PCA-SVM sınıflandırma başarımı

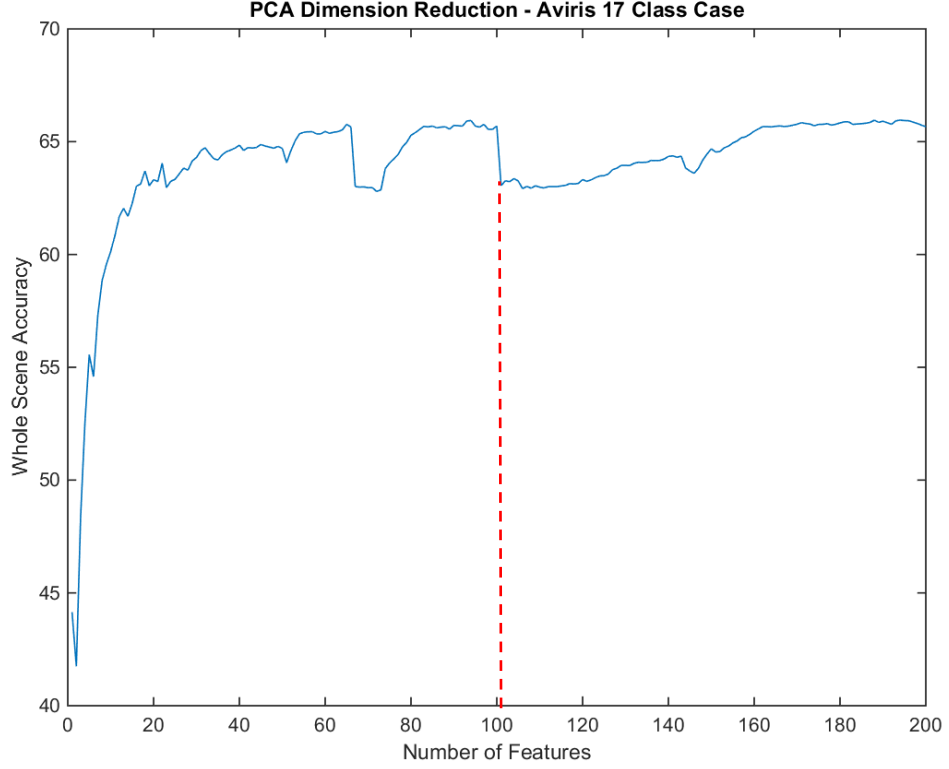
Şekil 4.6'dan, elde edilen sınıflandırma doğruluklarının genellikle iyi olduğunu ve %51.74 ile %98.06 arasında değiştiğini görüyoruz. Özniteliklerin sayısı 100 öznitelik için %94.50'ye ulaştığı ve öznitelik sayısı arttıkça aynı zamanda eğitim sınıflandırma başarımında arttığı görülmektedir. Özniteliklerin 101 ile 200 arasında, sınıflandırma doğruluğu %94.12 ve %98.06 arasında değişmektedir.



Şekil 4.7: 17 sınıflı veri test örnekleri için PCA-SVM sınıflandırma başarımı

Şekil 4.7'den, elde edilen sınıflandırma doğruluklarının genellikle kabul edilebilir düzeyde olduğu ve %45.63 ile %80.52 arasında değiştiğini tespit edilmiştir. Özniteliklerin sayısı 0 ile 100 arasında, 100 öznitelik için %79.75'e ulaşmaktadır ve öznitelik sayısı 100'e ulaşıncaya kadar sınıflandırma başarımında arttığı görülmektedir. Öznitelik 101 için sınıflandırma başarımı aniden %75,79'a düşer. Özelliklerin sayısı 102'den 200'e kadar, artıtıldığında sınıflandırma başarımı %80,52'ye kadar ulaşmaktadır. Şekil 4.8'de ise 17 sınıflı tüm veri için sınıflandırma başarımının öznitelik sayısı ile değişimi gösterilmiştir. Şekil 4.8'de görüldüğü üzere başarımlar %44.14 ile %65.66 arasında değişmektedir. Özniteliklerin sayısı 0 ile 100 arasında, sınıflandırma başarımı 100 öznitelik için %65.69'a ulaşmakta ve daha sonra yeni öznitelikler eklendiğinde öznitelik değişiminin yavaşça arttığı görülmektedir. Öznitelik sayısı 101'e ulaştığında sınıflandırma başarımı %63,04'e düşer. Özniteliklerin sayısı 102'den 200'e kadar arttığında, sınıflandırma başarımı %65.66'ya ulaşması için öznitelik sayısında artmalıdır. Fakat bu şekilde sağlanan artış ilk yüz bant için sağlanan artıştan daha az miktarda olmaktadır. Bu nedenle, 17 sınıflı AVIRIS Indian Pines verisi eğitim, test ve tüm görüntü için yapılan deneylerden 100 öznitelik seviyesinden elde edilen sonuçların kararlı ve yüksek

kaldığı sonucuna varılmıştır, Bu yüzden, 200 bant ile çalışmak yerine, bir boyut indirgeme yaparak bize istikrarlı başarımlar veren 100 bantla çalışmak seçilebilir .




Şekil 4.8: 17 sınıflı tüm veri için PCA-SVM sınıflandırma başarımı

Daha önceki bölümde açıkladığımız gibi, deneylerden boyut indirgemeyi kullanarak, modelleme sürecinde sınıflandırma işleminde daha doğru sonuçlar elde edilir.


Buna ek olarak, 100 PCA ve 200 PCA kullanarak 17 sınıfın durumu için elde edilen sonuçlar sırasıyla Şekil 4.9 ve Şekil 4.10'da gösterilmiştir. Her iki Şeklin 100 ve 200 özniteliği kullanarak elde edilen sonuçlarda özellikle homojen bölgelerde gürültüye benzer sınıflandırma sonuçlarının yer aldığı görülmektedir. Bu durumun bir nedeni arka plan sınıfının bir karışık sınıf olmasıyla açıklanabilir. Bununla birlikte spektral sınıflandırmanın yanında uzamsal sınıflandırmanın da uygulanması bu tür gürültüye benzer kararların azalmasında yardımcı olabilir.

Classification result for 17 class case and 100 PCA features



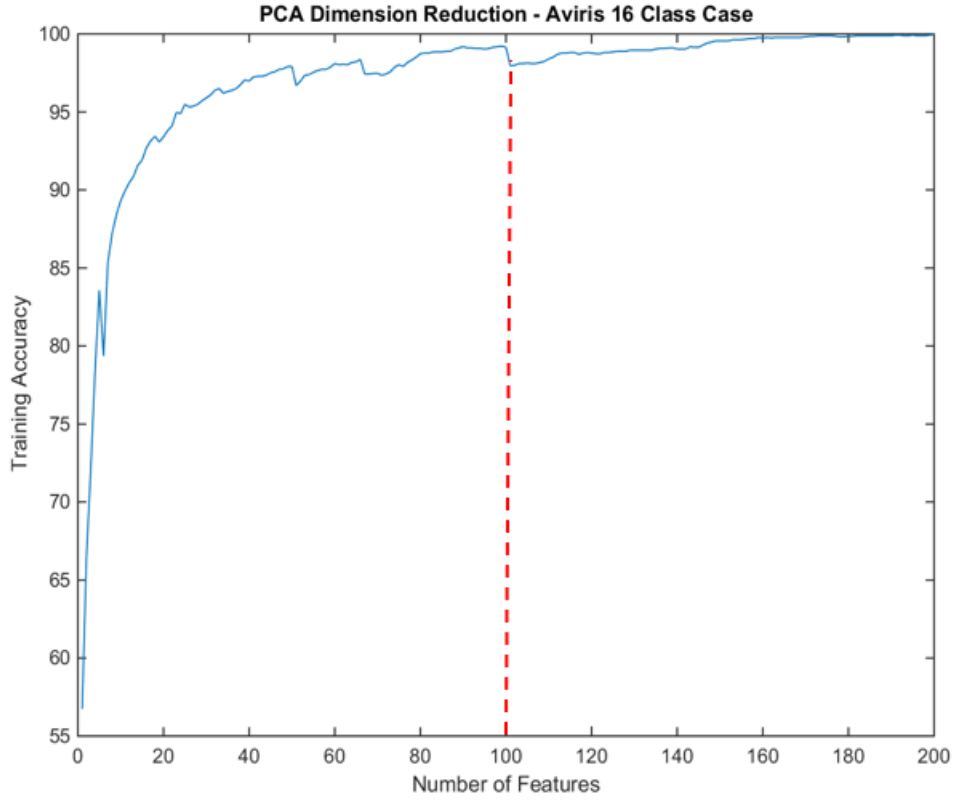
Şekil 4.9: 17 sınıflı AVIRIS veri seti 100 öznelik için PCA-SVM sınıflandırma başarımı

Classification result for 17 class case and 200 features



Şekil 4.10: 17 sınıflı AVIRIS veri seti 200 özellik için PCA-SVM sınıflandırma başarımı

PCA metodu kullanılarak, eğitim, test ve tüm görüntü doğruluğu için 16 sınıf örnekleme için elde edilen sonuçlar sırasıyla Şekil 4.11, Şekil 4.12 ve Şekil 4.13'de gösterilmiştir.



Şekil 4.11: 16 sınıflı eğitim verisi için PCA-SVM sınıflandırma başarımı


Şekil 4.11'den elde edilen sınıflandırma başarımlarının genellikle çok iyi olduğunu ve %56.74 ile %99.96 arasında değiştiğini görülmektedir.

Öznitelikler 0'dan 100'e kadar incelenirse, 100 öznitelik için sınıflandırma başarımının eğitim örnekleri için %99.14'e ulaştığı ve bu artışın öznitelik sayısı arttıkça arttığı söylenebilir.


Öznitelikler 101 ile 200 arasında, sınıflandırma başarımı %97.95 ve %99.96 arasında değişmektedir. Şekil 4.12'den, elde edilen test örnekleri sınıflandırma başarımlarının genellikle kabul edilebilir olduğunu ve %48.00 ile %85.95 arasında değiştiğini görülmektedir.

Öznitelikler 0'dan 100'e kadar, 100 öznitelik için %86.31'e ulaştığı ve sınıflandırma başarısının özellikler sayısı ile paralel olarak arttığı tesbit edilmiştir.

Öznitelikleri sayısı 100 için, sınıflandırma başarımı aniden %79.63'e düşer. Özniteliklerin sayısı 102'den 200'e kadar, sınıflandırma başarımı %85,95'e ulaşmak için öznitelik sayısı artmaktadır. Fakat burada öznitelik sayısındaki artışla elde edilen başarımdaki değişim daha az olmaktadır.



Şekil 4.12: 16 sınıflı test verisi için PCA-SVM sınıflandırma başarımı



Şekil 4.13: 16 sınıflı veri için tüm görüntü PCA-SVM sınıflandırma


Şekil 4.13'ten elde edilen sınıflandırma başarımlarının makul seviyede olduğunu ve %45.70 ile %81.34 arasında değiştiğini tespit edilmiştir. Öznitelikler 0'dan 100'e kadar değiştiğinde, 100 özellik için %82.28'e ulaşan sınıflandırma başarımları özelliklerin artmasıyla artar. Öznitelik sayısı 101 için, sınıflandırma başarımları %74.30'a düşer. Özniteliklerin sayısı 102'den 200'e kadar, sınıflandırma başarımları %81,34'e ulaşmak için öznitelik sayısı artmalıdır fakat öznitelik sayısı ile elde edilen artış 102-200 öznitelik sayısı için yeterli olmayabilir. Bu yüzden 200 öznitelikten daha az sayıda öznitelik kullanarak yaklaşık benzer sınıflandırma başarımlarına ulaşmak mümkün olmaktadır.

Böylece önceki 17 sınıf vakası ve önceki farklı deneylerden eğitim, test ve tüm görüntü için, 100 öznitelik seviyesinden, elde edilen başarımların yeterli düzeyde olduğu görülür. Bu nedenle, boyut indirgeme yöntemini uygulayarak, iyi sınıflandırma sonuçları elde edildiğinden ve ayrıca azaltılmış bir boyutta çalışmanın karar işleminde işlem süresini azaltacağından 200 yerine 100 öznitelik kullanımı tatminkar sonuçlar elde etmek için yeterli olacaktır.


Ayrıca, 100 PCA özniteliği ve 200 PCA özniteliği kullanılarak 16 sınıfın durumu için elde edilen sonuçlar sırasıyla Şekil 4.14 ve Şekil 4.15'de gösterilmiştir.

Bu şekilleri 17 sınıflı durum kullanılarak elde edilenlerle karşılaştırarak, 16 sınıf kullanarak görüntünün daha az sayıda gürültüye benzer sonuçların yer aldığı söylenebilir.

Bu, 16 sınıflı durumda sınıfların göreceli olarak saf olduğu gerçeğiyle açıklanabilir.

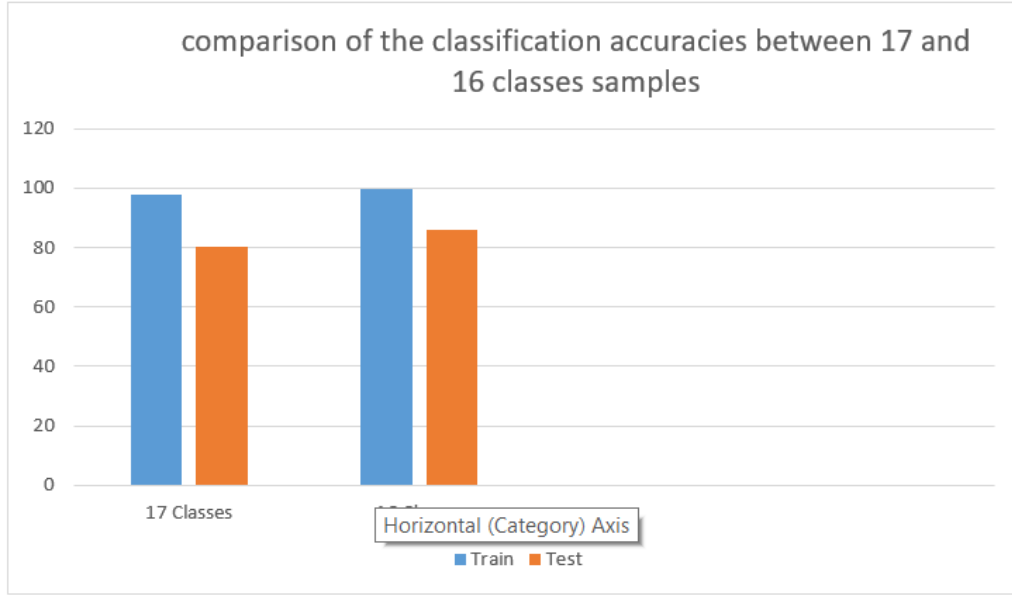


Şekil 4.14: 16 sınıflı durum 100 öznitelik için PCA-SVM sınıflandırma sonucu




Şekil 4.15: 16 sınıflı durum 200 öznitelik için PCA-SVM sınıflandırma sonucu

Şekil 4.16'da gösterildiği gibi, 17 sınıflı ve 16 sınıflı durum için hem eğitim hem de test verileri için sınıflandırma başarımı karşılaştırılmış, 16 sınıflı durumda elde edilen başarımların 17 sınıflı durumdan daha yüksek olduğu görülmektedir. Bu sonuçtan, 17 sınıflı durumda bulunan sınıflardan birinin (arka plan) karışık bir sınıf olması dolayısıyla gerçekleştiği yorumu yapılabilir.

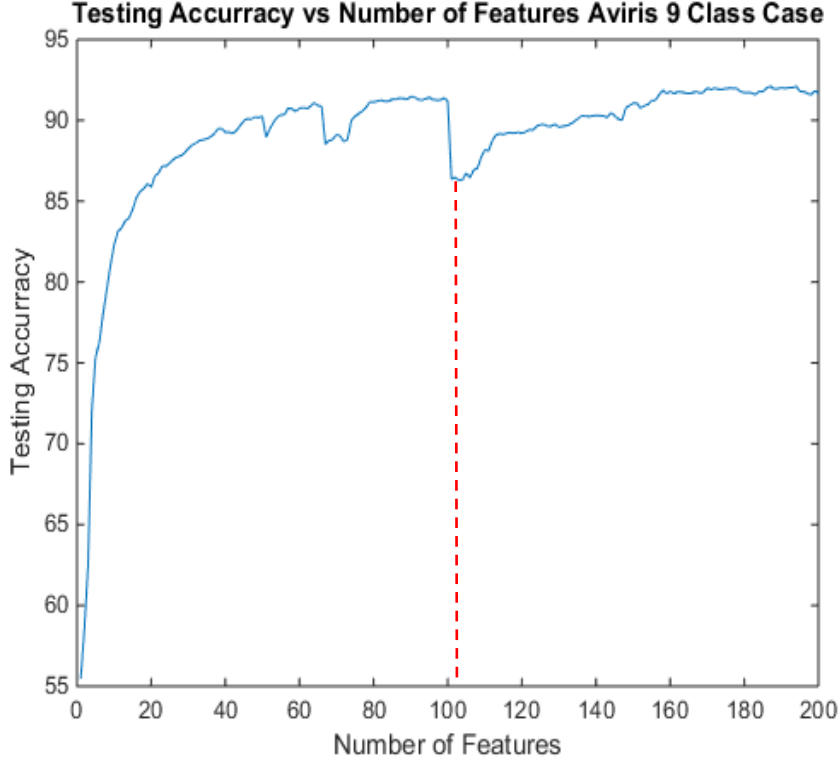


Şekil 4.16: 17 ve 16 sınıflı durumda sınıflandırma başarımlarının karşılaştırılması

PCA metodu kullanılarak, eğitim, test ve tüm veri doğruluğu için 9 sınıflı durumda elde edilen sonuçlar sırasıyla Şekil 4.17, Şekil 4.18 ve Şekil 4.19'da gösterilmiştir.

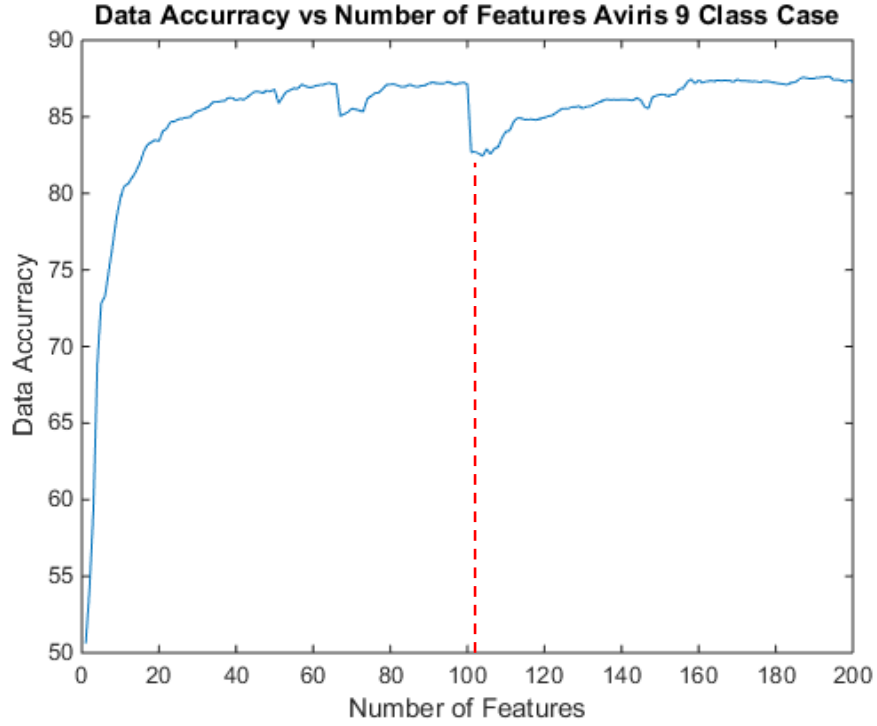


Şekil 4.17: 9 sınıflı durum eğitim örnekleri için PCA-SVM sınıflandırma başarımı



Şekil 4.18: 9 sınıflı durum test verisi için PCA-SVM sınıflandırma başarımı

Şekil 4.17'den elde edilen sınıflandırma başarımlarının genellikle iyi olduğunu ve %49,26 ile % 100 arasında değiştiğini tespit edilmiştir. Özniteliklerin 0'dan 100'e kadar değiştiği aralıkta, 100 öznitelik için başarımın %98.21'e ulaştığı görülebilir. Bu aralıkta kullanılan öznitelik sayısı arttıkça başarımında artmaktadır. Öznitelikler 101 ile 200 arasında, sınıflandırma doğruluğu %95,48 ve %100 arasında değişmektedir. Şekil 4.18'den, elde edilen sınıflandırma doğruluklarının genellikle kabul edilebilir düzeyde olduğunu ve %55.44 ile %91.65 arasında değiştiğini tespit edilmiştir. Özniteliklerin 0'dan 100'e kadar, 100 özellik için %91,18'e ulaşmak için Öznitelik sayısı ile paralel olarak sınıflandırma doğruluğunun arttığı görülebilir. Özniteliklerin sayısı 101 olduğunda ise sınıflandırma başarımı aniden %86.36'ya düşer. Özniteliklerin sayısı 102'den 200'e kadar, eklenen özniteliklerin sınıflandırma doğruluğu arttırması sınırlı olup 200 öznitelik için %91,65'e başarıma ulaşılır.




Şekil 4.19: 9 sınıflı durum tüm görüntü için PCA-SVM sınıflandırma başarımı

Şekil 4.19'dan elde edilen sınıflandırma başarımlarının %50.61 ile %87.26 arasında değiştiğini görülmektedir. Özniteliklerin sayısı 0 ile 100 arasında, sınıflandırma başarımı %87,12'ye ulaşması için öznitelik sayısının 100'e ulaşması gerekir. Özniteliklerin 101 olması durumu için, sınıflandırma başarımı %82.67'ye düşmektedir. Özniteliklerin sayısı 102'den 200'e kadar arttığında öznitelik sayısı 200 için %87,26 sınıflandırma başarımına ulaşmak için eklenmesi gereken öznitelik sayısı fazla olup göreceli olarak her eklenen öznitelikten dolayı artan başarımlar azdır.


Böylece önceki 17 ve 16 sınıflı durumları için eğitim, test ve tüm görüntü deneylerinden elde edilen sonuçlara göre, elde edilen sınıflandırma başarımının, 100 öznitelik seviyesinde elde edildiği ve daha sonra eklenen özniteliklerin yeteri başarı artışı getirmediğinden 200 öznitelik yerine 100 öznitelik kullanımı yeterli olacaktır. Ayrıca, 100 temel bileşen ve 200 temel bileşen kullanılarak 9 sınıflı durum için elde edilen sonuçlar sırasıyla Şekil 4.20 ve Şekil 4.21'deki görüntü ile gösterilmiştir.

Classification result for 9 class case and 100 PCA features



Şekil 4.20: İlk 100 temel bileşen için PCA-SVM sınıflandırma sonucu


Classification result for 9 class case 200 features



Şekil 4.21: İlk 200 temel bileşen için PCA-SVM sınıflandırma sonucu

9 sınıflı durumda, sınıflandırma başarımlarının iyi olması 9 sınıfın istatistiksel anlamlı sınıflardan olması yani istatistiksel olarak yeteri kadar örneğe sahip sınıflardan oluşmasıdır. 9 sınıflı durum için elde edilen sonuç şekilleri 16 ve 17 sınıflı durum için olanlarla karşılaştırarak, 9 sınıflı durumda elde edilen başarımların daha fazla olduğu söylenebilir. Bu durum 9 sınıflı durumdaki sınıfların istatistiksel anlamlı olacak sayıda yeteri örneğe sahip olmasından kaynaklanmaktadır.

Şekil 4.22'deki grafikte 17, 16 ve 9 sınıflı durum için elde edilen sınıflandırma başarımları gösterilmektedir.



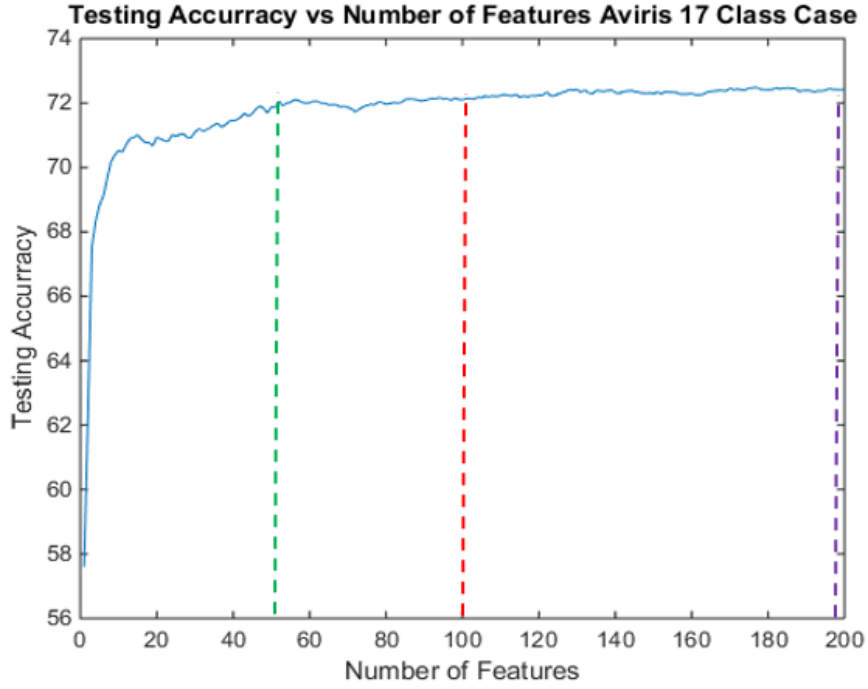
Şekil 4.22: 17, 16 ve 9 sınıflı durum için PCA-SVM sınıflandırma başarımlarının karşılaştırılması

Şekil 4.22'de gösterilen sonuçları karşılaştırırsak 17 ve 16 sınıflı durumlara nazaran 9 sınıflı durumda en yüksek test başarımının elde edildiği görülebilir.

4.3.2 ISOMAP Yöntemi


Bu bölümde elde edilen sonuçları ISOMAP boyut indirgeme ve KNN sınıflandırma yöntemi kullanılarak elde edilmiştir.

Hem test hem de tüm görüntü başarımı için 17 sınıflı durumdan elde edilen sonuçlar sırasıyla Şekil 4.23 ve Şekil 4.24'te gösterilmiştir.



Şekil 4.23: 17 sınıflı durumda test örnekleri için ISOMAP-KNN sınıflandırma başarımı

Şekil 4.23'ten, elde edilen sınıflandırma başarımlarının %57.59 ile %72.43 arasında değiştiğini tespit ettik. Özniteliklerin sayısı 0 ila 100 arasında, sınıflandırma başarımı 50 öznitelik için %71.87 ve 100 öznitelik için %72.10 dir. Özniteliklerin sayısının 101'den 200'üne kadar değiştiği durumda ise sınıflandırma başarımları artışı göreceli olarak düşük olmuştur.




Şekil 4.24: 17 sınıflı durumda tüm görüntü için ISOMAP-KNN sınıflandırma başarımı

Şekil 4.24'ten ise tüm görüntü için sınıflandırma başarımlarımızın %40.51 ile %75.07 arasında değiştiğini görülmektedir. Özniteliklerin sayısı 0 ila 100 arasında, sınıflandırma doğruluğu 50 öznitelik için %56,69 ve 100 öznitelik için ise %56,96 olarak yavaşça artar. Özniteliklerin sayısı 100'den 200'e kadar olduğu durumlarda ise sınıflandırma başarımları fazlaca değişmeyip %56 civarında bir sınıflandırma başarımlarında kalmıştır.


50, 100 ve 200 ISOMAP'ın öznitelik olarak kullanılmasıyla 17 sınıflı durum için elde edilen sonuçları Şekil 4.25, 4.26 ve 4.27'de gösterilmektedir.

KNN Classification Result for 17 class case and first 50 Isomap features




Şekil 4.25: 17 sınıflı durum ve ilk 50 ISOMAP öznitelik için KNN sınıflandırma sonucu

KNN Classification Result for 17 class case and first 100 Isomap features




Şekil 4.26: 17 sınıflı durum ve ilk 100 ISOMAP öznitelik için KNN sınıflandırma sonucu

KNN Classification Result for 17 class case and 200 Isomap features




Şekil 4.27: 17 sınıflı durum ve ilk 200 ISOMAP öznelik için KNN sınıflandırma sonucu

ISOMAP boyut indirgeme metodu PCA boyut indirgemesinde olduğu gibi 16 sınıflı AVIRIS veri kümesi için de test edilmiştir. Bu başarımların analizi hem test hem de tüm görüntü için sınıflandırma sonuçları sırasıyla Şekil 4.28 ve Şekil 4.29'da gösterilmiştir.



Şekil 4.28: 16 sınıflı durumda test örnekleri için ISOMAP-KNN sınıflandırma başarımı


Şekil 4.28'den, elde edilen sınıflandırma başarımlarının genellikle çok iyi olmadığını ve %64.53 ile %78.80 arasında değiştiğini görülmektedir. Özniteliklerin sayısı 0'dan 94'e kadar, sınıflandırma doğruluğu 50 öznitelik için %78,30'a, 94 öznitelik için ise %78.51'e ulaşmaktadır. Özniteliklerin sayısı 94'den 200'e kadar, sınıflandırma başarımının artmadı ve sonuç olarak %78'civarında sabit kaldığı görülmektedir.



Şekil 4.29: 16 sınıflı durumda tüm görüntü için ISOMAP-KNN sınıflandırma başarımı

Şekil 4.29'dan inceleceği gibi elde edilen sınıflandırma başarımlarının %51.66 ile %70.15 arasında değiştiğini görülmektedir. Özniteliklerin sayısı 0'dan 94'e kadar, sınıflandırma başarımı 50 öznitelik için %69.43, 94 öznitelik için ise %69.81'e ulaşmaktadır.

KNN Classification Result for 16 class case and first 50 Isomap features




Şekil 4.30: 16 sınıflı durumda ilk 50 ISOMAP özneliği için KNN sınıflandırma sonucu

Özneliklerin 94 ila 200 arasındaki ISOMAP özneliği için, sınıflandırma başarımı %69 ve %70 civarında bir sınıflandırma başarımında kalmıştır.


Bu deney için elde edilen sonuçlar ilk 50, 94 ve 200 ISOMAP özneliği için Şekil 4.30, 4.31 ve 4.32'de gösterilmiştir.

KNN Classification Result for 16 class case and first 94 Isomap features



Şekil 4.31: 16 sınıflı durumda ilk 94 ISOMAP özneliği için KNN sınıflandırma sonucu


KNN Classification Result for 16 class case and 200 Isomap features



Şekil 4.32: 16 sınıflı durumda tüm ISOMAP özneliği için KNN sınıflandırma sonucu

Elde edilen sınıflandırma başarımlarını 17 ve 16 sınıflı durum için karşılaştırırsak 16 sınıflı durumun başarımlarının 17 sınıflı durumun başarımlarından daha iyi olduğu ve bu durumun daha fazla sınıflandırma hatasına neden olabilecek bir karışım tipi olan bir arka plan sınıfını (birinci sınıf) içermesiyle açıklayabilir.


ISOMAP boyut indirgeme yöntemini kullanarak, hem test hemde tüm görüntü doğruluğu için 9 sınıflı durumdan elde edilen sonuçlar sırasıyla Şekil 4.33 ve Şekil 4.34'te gösterilmiştir.



Şekil 4.33: 9 sınıflı durumda test örnekleri için ISOMAP-KNN sınıflandırma başarımı

Şekil 4.33'ten, elde edilen sınıflandırma başarımlarının genellikle iyi düzeyde olduğunu ve %61.57 ile %83.33 arasında değiştiğini tespit edilmiştir. Özniteliklerin sayısı 0 ila 100 arasında olduğunda, sınıflandırma başarımı 50 öznitelik için %82,56 ve 100 öznitelik için %82.85'e ulaşmaktadır.


Özniteliklerin sayısı 101 ile 200 arasında olduğunda ise, sınıflandırma başarımı %82 ve %83 civarında fazla değişmeden sabit kalmaktadır. Şekil 4.34'ten, elde edilen sınıflandırma başarımlarının kabul edilebilir düzeyde olduğunu ve %53.71 ile %77.30 arasında değiştiğini görülmektedir. Özniteliklerin sayısı 0 ila 100 arasında olduğunda, sınıflandırma başarımı 50 öznitelik için %76.36 ve 100 öznitelik için %76.86'ya ulaşmaktadır. Özniteliklerin sayısı 101'den 200'e kadar olduğunda, sınıflandırma başarımı %76'civarında sabit kalmaktadır.



Şekil 4.34: 16 sınıflı durumda tüm görüntü için ISOMAP-KNN sınıflandırma başarımları

Şekil 4.35, Şekil 4.36 ve Şekil 4.37'de 9 sınıflı durum için 50, 100 ve 200 ISOMAP özniteliği kullanarak elde edilen sonuçlar gösterilmiştir.


KNN Classification Result for 9 class case and first 50 Isomap features



Şekil 4.35: 9 sınıflı durumda ilk 50 ISOMAP özneliği için KNN sınıflandırma sonucu


Yapılan deneylerden ISOMAP özneliklerinin 50 civarı olduğunda sınıflandırma başarımının göreceli olarak yüksek bir değere ulaştığı ve daha sonra eklenen ISOMAP özneliklerinin elde edilen başarıyı çok fazla arttırmadığı görülmektedir. PCA ve SVM deneyinde ise ilk 100 PCA özneliğinin kullanılması gerektiği sonucuna varılmıştı. Burada ISOMAP-KNN ilk 50 öznelikte göreceli yüksek başarıma ulaşırken PCA-SVM'de bu başarımın 100 öznelikte ulaşıldığı düşünülürse ISOMAP'in hiperspektral veri için PCA gruplama yönteminden daha fazla miktarda sıkıştırdığı ve düşük boyutlarda temsil edebildiği düşünülebilir.

KNN Classification Result for 9 class case and first 100 Isomap features



Şekil 4.36: 9 sınıflı durumda ilk 100 ISOMAP özneliği için KNN sınıflandırma sonucu

KNN Classification Result for 9 class case and 200 Isomap features




Şekil 4.37: 9 sınıflı durumda ilk 200 ISOMAP özneliği için KNN sınıflandırma sonucu

Şekil 4.38'de 17, 16 ve 9 sınıflı durumlar için test ve tüm görüntü sınıflandırma başarımları ISOMAP boyut indirgeme ve KNN sınıflandırması için verilmiştir.


Sonuçlar karşılaştırıldığında 16 ve 9 sınıflı durumlarda elde edilen başarımın 17 sınıflı duruma göre daha iyi olduğu görülmüştür. Bu durum 17 sınıflı durumda bulunan karışık tip sınıf olan arka plan sınıfından kaynaklandığı söylenebilir.

PCA'in boyut indirgeme ve SVM'in sınıflandırma yöntemi olarak kullanıldığı durumla ISOMAP'in boyut indirgeme ve KNN'in sınıflandırma yöntemi olarak kullanıldığı durumlar karşılaştırıldığında ise PCA-SVM'in daha iyi sonuç verdiği görülmektedir. Bu durumun boyut indirgeme yönteminden mi yoksa sınıflandırma yönteminden mi kaynaklandığını anlamak için ISOMAP-SVM deneyleri tasarlanmıştır.




Şekil 4.38: 17, 16 ve 9 sınıflı durumlar için ISOMAP-KNN sınıflandırma doğruluklarının test örnekleri ve tüm görüntü için karşılaştırılması

Bununla birlikte, bu durum KNN yönteminin model oluşturmadan eğitim örneklerinin tümünü kullanarak karar vermesi durumuyla açıklanabilir. Bu nedenle ISOMAP yöntemini tekrar test etmek için, aşağıdaki şemalarda açıklandığı gibi, KNN yerine SVM ile ISOMAP yöntemini test etmek ISOMAP ve PCA gruplama yöntemleri arasında yansız karşılaştırma yapmak için gereklidir.



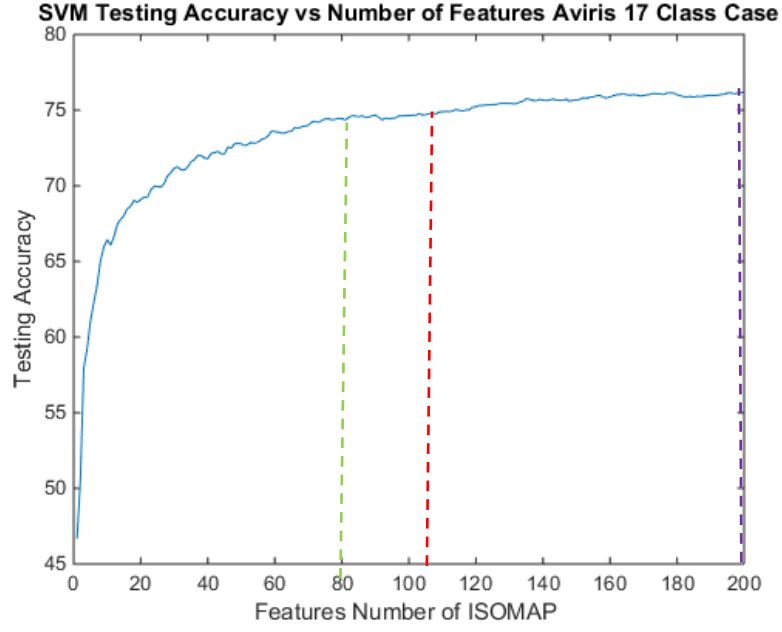
Şekil 4.39: ISOMAP ve SVM kullanarak veri sınıflandırması

Eđitim, test ve tm grnt dođruluđu iin 17 sınıf rneklemini iin elde edilen sonular sırasıyla Őekil 4.40, 4.41 ve 4.42'de gsterilmiŐtir.




Őekil 4.40: 17 sınıflı durumda eđitim rneklemleri iin ISOMAP-SVM sınıflandırma baŐarımı

Őekil 4.40'dan elde edilen sonulara gre, eđitim rneklemleri iin elde edilen sınıflandırma dođruluđu %55,24 ile %100 arasında deđiŐmektedir. zniteliklerin sayısı 0'dan 103'e kadar olan blgede, 80 znitelik iin %99,94'e ve 103 znitelik iin ise %100'e sınıflandırma baŐarımına ulaŐmaktadır. znitelik sayısı 103'den 200'ne kadar deđiŐtiđinde ise sınıflandırma baŐarımı beklendiđi Őekilde %100 olarak sabit kalmaktadır.




Şekil 4.41: 17 sınıflı durumda test örnekleri için ISOMAP-SVM sınıflandırma başarı

Şekil 4.41'den elde edilen sınıflama başarı oranlarının %46.67 ile %76.15 arasında değiştiği görülmektedir. Özniteliklerin sayısı 0'dan 103'e kadar, sınıflandırma başarıyı öznitelik sayısı arttıkça artar, 80 öznitelik için %74.45 ve 103 öznitelik için %74.78 sınıflandırma başarıma ulaşır. Sınıflandırma başarıyı öznitelik sayısı 104 ile 200 arasında değiştiğinde %74 - %76 civarında çok fazla değişmeden biraz arttığı görülmektedir.



Şekil 4.42: 17 sınıflı durumda tüm görüntü için ISOMAP-SVM sınıflandırma başarıyı

SVM Classification Result for 17 class case and first 80 Isomap features




Şekil 4.43: İlk 80 ISOMAP özniteliğinin SVM sınıflandırma sonucu

Şekil 4.42'den, elde edilen sınıflandırma başarımlarının kabul edilebilir düzeyde olduğunu ve %45 ile %68 arasında değiştiğini tespit edilmiştir. Öznitelik sayısı 0'dan 103'e kadar değiştiğinde, 80 öznitelik sayısı için %61.20 sınıflandırma başarımına ve 103 öznitelik için ise %61.91'e ulaşan sınıflandırma başarımına ulaşıldığı görülmektedir. Özniteliklerin 103'den 200'e kadar, arttığında ise sınıflandırma başarımının çok fazla artmadığı belirlenmiştir.


Şekil 4.43, Şekil 4.44 ve Şekil 4.45' te, elde edilen sonuçlar. 80, 103 ve 200 ISOMAP özniteliği ve 17 sınıflı durum için gösterilmektedir.

SVM Classification Result for 17 class case and first 103 Isomap features




Şekil 4.44: İlk 103 ISOMAP özneliği için SVM sınıflandırma sonucu

SVM Classification Result for 17 class case and 200 Isomap features




Şekil 4.45: İlk 200 ISOMAP özneliği için SVM sınıflandırma sonucu

ISOMAP boyut indirgeme yöntemini kullanarak, eğitim, test ve tüm görüntü örnekleri için sınıflandırma başarımı sırasıyla Şekil 4.46, Şekil 4.47 ve Şekil 4.48'de gösterilmiştir.



Şekil 4.46: 16 sınıflı durumda eğitim verisi için ISOMAP-SVM sınıflandırma başarımı

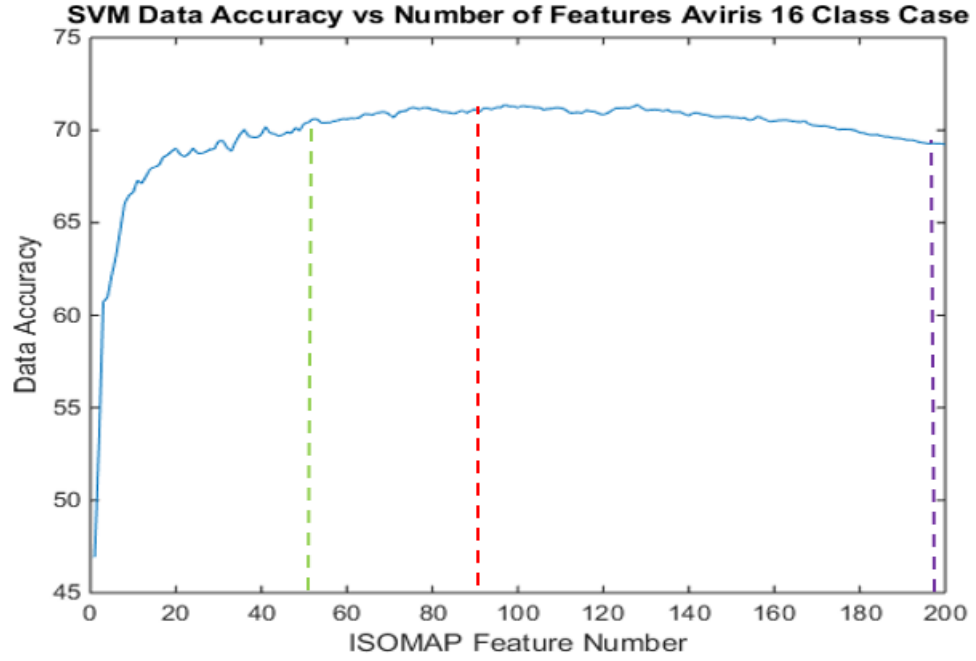
Şekil 4.46'dan, 16 sınıflı durum için elde edilen ISOMAP-SVM sınıflandırma başarımlarının %62 ile %100 arasında değiştiği görülmektedir. Özniteliklerin sayısı 0 ile 95 arasında olduğunda, sınıflandırma başarımı ilk 50 ISOMAP özneliği için %99,92'ye ve 95 özneliği için ise %100 başarıma ulaşmaktadır.



Şekil 4.47: 16 sınıflı durumda test örnekleri için ISOMAP-SVM sınıflandırma başarımı


Şekil 4.47'den, elde edilen sınıflandırma başarımlarının genel olarak kabul edilebilir olduğunu ve %49 ile %79 arasında değiştiğini tespit edilmiştir. Özniteliklerin 0'dan

95'ine kadar olan bölgede, sınıflandırma doğruluğu, ilk 50 ISOMAP özneliği için %78,97'ye ve ilk 95 ISOMAP özneliği için ise %79.03'e ulaştığı görülmektedir. Özneliklerin sayısı 96 ile 200 arasındaki bölgede ise, sınıflandırma doğruluğu %77'ye düşmektedir.



Şekil 4.48: 16 sınıflı durumda tüm görüntü için ISOMAP-SVM sınıflandırma başarımı


SVM Classification Result for 16 class case and first 50 Isomap features



Şekil 4.49: İlk 50 ISOMAP özneliği için SVM sınıflandırma sonucu


Şekil 4.48'den elde edilen sınıflandırma doğruluk oranlarının %46 ile %71 arasında değiştiğini görülmektedir. Özniteliklerin 0'dan 95 adet olduğu bölgede, 50 öznitelik için %70'e ve ilk 95 öznitelik için ise %71.23'e ulaşmaktadır. Özelliklerin sayısının 95 ile 200 arasında değiştiği bölgede ise, sınıflandırma başarımı %69'a düşer. Şekil 4.49, 4.50 Şekil ve Şekil 4.51'de elde edilen sınıflandırma sonuçları ilk 50, 95 ve 200 ISOMAP özniteliği için verilmektedir.

SVM Classification Result for 16 class case and first 95 Isomap features




Şekil 4.50: İlk 95 ISOMAP özniteliği için SVM sınıflandırma sonucu

SVM Classification Result for 16 class case and 200 Isomap features




Şekil 4.51: İlk 200 ISOMAP özniteliği için SVM sınıflandırma sonucu

ISOMAP boyut indirgeme yöntemini kullanarak, eğitim, test ve tüm görüntü başarımları 9 sınıflı durum için sırasıyla Şekil 4.52, Şekil 4.53 ve Şekil 4.54'te gösterilmiştir.



Şekil 4.52: 9 sınıflı durum için eğitim örnekleri ISOMAP-SVM sınıflandırma başarımları




Şekil 4.53: 9 sınıflı durum için test örnekleri ISOMAP-SVM sınıflandırma başarımları

Şekil 4.52'den, elde edilen eğitim örnekleri sınıflandırma başarımlarının %48 ile %100 arasında değiştiğini görülmektedir. Özniteliklerin sayısı 0 ila 100 arasında

olduğu bölgede, sınıflandırma başarımı %100'e ilk 80 ISOMAP özneliğiyle ulaşılmaktadır.

Şekil 4.53'ten, elde edilen test örnekleri sınıflandırma başarımlarının %55 ile %85 arasında değiştiğini tespit edilmiştir. Özneliklerinin sayısının 0 ila 100 arasında olduğu bölgede, sınıflandırma başarımı ilk 80 ISOMAP özneliği için %84.43 ve ilk 100 özneliği için ise %84.85'e ulaşmaktadır.

Özneliklerinin 100 ile 200 arasında olduğu bölgede ise, sınıflandırma başarımı %84 ve %85 civarında kalmaktadır.



Şekil 4.54: 9 sınıflı durumda tüm görüntü için ISOMAP-SVM sınıflandırma doğruluğu


Şekil 4.54'ten, elde edilen sınıflandırma başarımlarının %50 ile %79 arasında değiştiğini tespit edilmiştir.

Özneliklerin sayısı 0 ila 100 arasında, sınıflandırma başarımı ilk 80 ISOMAP özneliği için %78,37'ye ve ilk 100 özneliği için ise %78,79'a ulaşmaktadır.

Özneliklerin sayısı 102 ve 200 arasında olduğu bölgede sınıflandırma başarımı artmamıştır.


Şekil 4.55, Şekil 4.56 ve Şekil 4.57'de, elde edilen sonuçları. 9 sınıflı durum için ilk 80, 100 ve 200 ISOMAP özneliği için SVM sınıflandırma sonuç görüntüleri gösterilmiştir.

SVM Classification Result for 9 class case and first 80 Isomap features



Şekil 4.55: İlk 80 ISOMAP özneliği için SVM sınıflandırma sonucu


SVM Classification Result for 9 class case and first 100 Isomap features




Şekil 4.56: İlk 100 ISOMAP özneliği için SVM sınıflandırma sonucu

Şekil 4.57'de test örnekleri için KNN ve SVM sınıflandırma yöntemlerinin ISOMAP özneliklerindeki başarımları 17, 16 ve 9 sınıflı durum için gösterilmiştir.

SVM Classification Result for 9 class case and 200 Isomap features



Şekil 4.57: İlk 200 ISOMAP öznelikleri için SVM sınıflandırma sonucu




Şekil 4.58: Test verileri için SVM ve KNN arasındaki sınıflandırma başarımlarının karşılaştırılması

Bu sonuçları karşılaştırarak, ISOMAP ile kombine edilmiş SVM sınıflandırıcısı ile elde edilen sınıflandırma sonuçlarının, ISOMAP ile birleştirilmiş KNN sınıflandırıcısı ile elde edilen sonuçlardan daha yüksek olduğunu görülebilir. Bu, SVM'nin

hyperspektral verilerde KNN'ye göre daha gürbüz bir algoritma olmasıyla açıklanabilir.

Boyut indirgeme tekniklerini PCA-SVM ve ISOMAP-SVM yöntemlerinin karşılaştırılması yerinde olur.

Şekil 4.59'da PCA-SVM ve ISOMAP-SVM yöntemleri 17,16 ve 9 sınıflı durum için karşılaştırılmıştır.




Şekil 4.59: PCA-SVM ve ISOMAP-SVM yöntemlerinin karşılaştırılması

Bu sonuçları karşılaştırarak, PCA ile kombine edilmiş SVM sınıflandırıcı ile elde edilen sınıflandırma sonuçlarının, 17,16 ve 9 sınıf örnekleri için SVM ile birlikte kullanılan ISOMAP ile elde edilen sonuçlardan daha yüksek olduğunu görülmektedir. Dolayısıyla, PCA bant gruplama'nın performansının, veri sınıflandırması alanında ISOMAP'in performansından daha yüksek olduğu sonucuna varabiliriz. Bununla birlikte ISOMAP'inde performansını arttırmak için band gruplama yöntemiyle uygulanması ISOMAP başarımlarını arttıracığı düşünülmektedir.

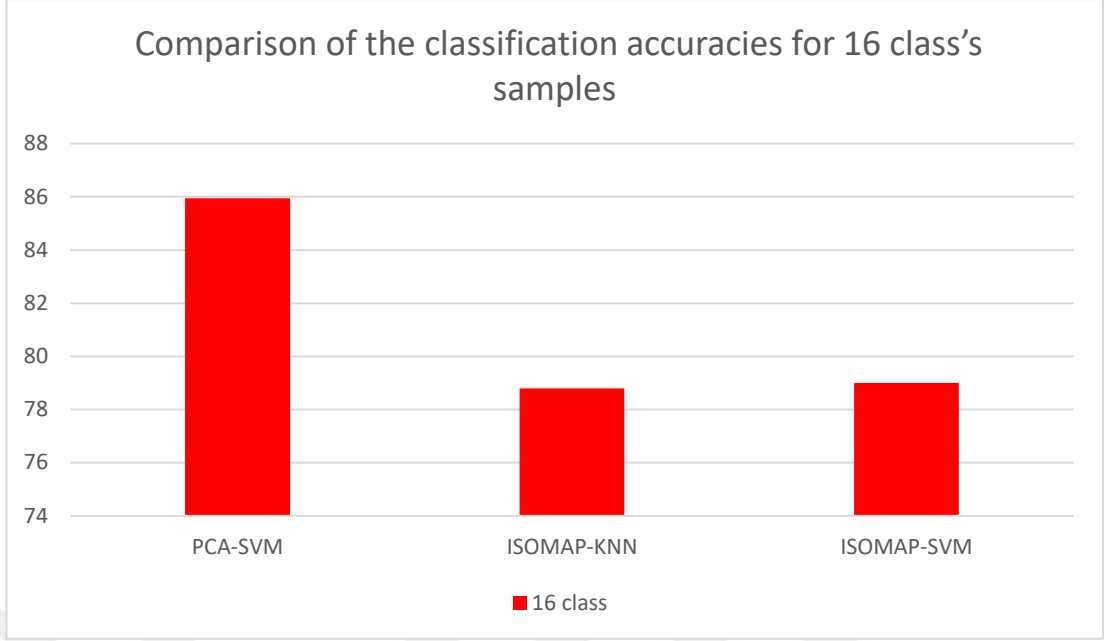
Farklı deney sonuçlarını karşılaştırmak için, test örnekleri için 17, 16 ve 9 sınıflı durumlarda kullanılan farklı yöntemleri ayrı ayrı karşılaştırılmıştır.

Şekil 4.60, 17 sınıflı durumda PCA-SVM, ISOMAP-KNN ve ISOMAP-SVM farklı yöntemleri arasında bir karşılaştırma verilmektedir.



Şekil 4.60: 17 sınıflı durumda test örnekleri sınıflandırma başarımlarının karşılaştırılması


Şekil 4.60'dan, en iyi sonucun, %80.52 ile PCA-SVM kombinasyonu ile elde edildiğini, ayrıca ISOMAP-SVM kombinasyonunun ISOMAP-KNN'den daha iyi bir sonuç verdiğini görüyoruz. Bu nedenle, 17 sınıf örneğinde, çalışmamızda kullanılan en iyi boyut azaltma yönteminin PCA band gruplama yöntemi olduğu ve en iyi sınıflandırma yönteminin SVM olduğu sonucuna varabiliriz. Şekil 4.61, 16 sınıflı örnekleri için PCA-SVM, ISOMAP-KNN ve ISOMAP-SVM farklı yöntemleri arasında bir karşılaştırma sunar.



Şekil 4.61: 16 sınıflı durumda test örnekleri için sınıflandırma başarımlarının karşılaştırılması

Şekil 4.61'den ve 16 sınıflı durumda en iyi sonucun PCA-SVM kombinasyonu ile %85.95 ile elde edildiğini, ayrıca ISOMAP-SVM kombinasyonunun ISOMAP-KNN'den daha iyi bir sonuç verdiğini görüyoruz.

Bu nedenle, 16 sınıf örneğinde, çalışmamızda kullanılan en iyi boyut azaltma yönteminin PCA band gruplama yöntemi olduğu ve en iyi sınıflandırma yönteminin incelenen sınıflandırma yöntemleri dahilinde SVM olduğu sonucuna varabiliriz. Şekil 4.62, 9 sınıflı durum için PCA-SVM, ISOMAP-KNN ve ISOMAP-SVM yöntemleri arasında bir karşılaştırma sunmaktadır.



Şekil 4.62: 9 sınıflı durumda test örnekleri için sınıflandırma başarımlarının karşılaştırılması

Şekil 4.62'den ve 9 sınıflı durumda en iyi sonucun PCA-SVM kombinasyonunun %91.61 ile elde edildiğini, ayrıca ISOMAP-SVM kombinasyonunun ISOMAP-KNN'den daha iyi bir sonuç verdiğini görüyoruz.

Bu nedenle, 9 sınıflı durumda çalışmamızda kullanılan en iyi boyut azaltma yönteminin PCA bant gruplama yöntemi olduğu ve en iyi sınıflandırma yönteminin ise SVM olduğu sonucuna varabiliriz.

Özetlemek gerekirse:

- 16 sınıflı durumda elde edilen sınıflandırma başarımları sonuçları, 17 sınıflı durumda elde edilen sınıflandırma sonuçlarından daha iyidir.
- 9 sınıflı durumda elde edilen sonuçlar, 16 sınıflı durumda elde edilen sonuçlardan daha iyidir.
- SVM sınıflandırıcı ile elde edilen sonuçlar KNN sınıflandırıcı ile elde edilen sonuçlardan daha iyidir.
- Boyut indirgeme tekniği olarak PCA bant gruplama kullanılarak elde edilen sonuçlar, boyut indirgeme tekniği olarak ISOMAP kullanılarak elde edilen sonuçlardan daha iyidir. Bununla birlikte ISOMAP boyut indirgeme yöntemi PCA'daki gibi bant gruplama yöntemiyle uygulanarak başarımının arttırılabileceği öngörülmektedir.

5. SONUÇLAR VE ÖNERİLER

Boyut küçültme ve hiperspektral veri görüntüleme sistemleri yakın geçmişte çeşitli araştırma uzmanlarından ve kurumlardan büyük ilgi görmüştür. Bu tez hiperspektral veri sınıflama sistemlerinde boyut indirgemenin etkisini analiz etmektedir. İki farklı tekniğe dayanan hiperspektral verilerdeki boyut küçültme çalışmaları, PCA bant gruplama ve ISOMAP yöntemleriyle uygulanmıştır. Daha sonra Destek Vektör Makinesi (SVM) ve K en yakın komşuları (KNN) olan iki temel veri sınıflandırma yöntemini uygulanmıştır.

İyi bilinen hiperspektral verilerden olan AVIRIS Indian Pines kullanılarak, sınıflandırma yöntemi olarak SVM'nin ve boyut indirgeme tekniği olarak PCA bant gruplama'nın etkinliği tezin 4. Bölümünde doğrulanmış olup, SVM'nin önceki çalışmalarla karşılaştırıldığında çok kabul edilebilir sonuçlar verdiğini göstermektedir.

İleride yapılması planlanan çalışmalar olarak:

1. ISOMAP boyut indirgeme yönteminin PCA gibi band gruplama tekniği ile kullanılmasının ISOMAP'in sınıflandırma yöntemlerindeki başarımını arttırabileceği öngörülmektedir.
2. Yöntemimizi farklı hiperspektral görüntülerde uygulayarak sonuçların geçerliliğini test edilebilir.
3. Ayrıca literatürde kullanılan diğer boyut indirgeme tekniklerini test etmeyi öneriyoruz.



KAYNAKLAR

- [1] Sorzano, C. O. S., Vargas, J., and Montano, A. P. (2014). A survey of dimensionality reduction techniques. arXiv preprint arXiv:1403.2877.
- [2] Gu, Y., and Wang, Q. (2016). Discriminative graph-based dimensionality reduction for hyperspectral image classification, The 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Los Angeles, CA, USA, 21-24 Aug.
- [3] Ly, N., Du, Q., Fowler, J. E., and Younan, N. (2014). Dimensionality reduction of hyperspectral imagery with sparse and collaborative graphs, The 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Lausanne, Switzerland, 24-27 June.
- [4] Laparra, V., Malo, J., & Camps-Valls, G. (2014). Dimensionality reduction via regression on hyperspectral infrared sounding data, The 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Lausanne, Switzerland, 24-27 June.
- [5] Damodaran, B., Courty, N., and Tavenard, R. (2017). Randomized Nonlinear Component Analysis for Dimensionality Reduction of Hyperspectral Images, In IGARSS 2017-IEEE International Geoscience and Remote Sensing Symposium, Houston, United States, 23 July.
- [6] Wang, X., Kong, Y., and Cheng, Y. (2017). Dimensionality Reduction for Hyperspectral Data Based on Sample-Dependent Repulsion Graph Regularized Auto-encoder. Chinese. Journal of Electronics, 26, 1233-1238.
- [7] Zhou, H., Gao, C., and Liu, X. (2017). Design and Optimization of Nonlinear Dimensionality Reduction Algorithm for Hyperspectral Images on Heterogeneous System, The International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData), Exeter, UK, 21-23 June.
- [8] Ménoret, M., Farrugia, N., Padeloup, B., and Gripon, V. (2017). Evaluating Graph Signal Processing for Neuroimaging Through Classification and Dimensionality Reduction. arXiv preprint arXiv:1703.01842.

- [9] **Shen, Y., Traganitis, P. A., and Giannakis, G. B.** (2017). Nonlinear dimensionality reduction on graphs. The 7th Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP), Curacao, Netherlands Antilles, 10-13 Dec.
- [10] **Shlens, J.** (2014). A tutorial on principal component analysis. arXiv preprint arXiv:1404.1100.
- [11] **Smith, L. I.** (2002). A tutorial on principal components analysis.
- [12] **Suri, P. K., Walia, E., and Verma, E. A.** (2011, May). Face detection and gender detection using principal component analysis (PCA), The 3th International Conference on Communication Software and Networks, Xi'an, China, 27-29 May.
- [13] **Hamadache, M., and Lee, D.** (2014). Improving signal-to-noise ratio (SNR) for inchoate fault detection based on principal component analysis (PCA), The 4th International Conference on Control, Automation and Systems (ICCAS), Seoul, South Korea, 22-25 Oct.
- [14] **Rizanti, N. A., and Setyaningrum, A. H.** (2016). Colon detection using Principal Component Analysis (PCA) and Support Vector Machine (SVM). The 4th International Conference on Cyber and IT Service Management, Bandung, Indonesia, 26-27 April.
- [15] **Isa, M. R. M., Yusoff, Z., Aljareh, S., and Minoi, J. L.** (2016). A watermarking technique to improve the security level in face recognition systems: an experiment with Principal Component Analysis (PCA) for Face Recognition and Discrete Cosine Transform (DCT) for Watermarking, The International Conference on Information and Communication Technology (ICICTM), Kuala Lumpur, Malaysia, 16-17 May.
- [16] **Aymaz, S., and Köse, C.** (2017). Multi-focus image fusion using Stationary Wavelet Transform (SWT) with Principal Component Analysis (PCA), The 10th International Conference on Electrical and Electronics Engineering (ELECO), Bursa, Turkey, 30 Nov.-2 Dec.
- [17] **Brennan, V. L.** (2001). Principal Component Analysis with Multiresolution (Doctoral dissertation, State University System of Florida).
- [18] **Moughal, T. A.** (2013). Hyperspectral image classification using Support Vector Machine. In Journal of Physics: Conference Series, 439, 12-42.
- [19] **Mercier, G., and Lennon, M.** (2003). Support vector machines for hyperspectral image classification with spectral-based kernels. In IEEE International Geoscience and Remote Sensing Symposium. Proceedings, Toulouse, France, 21-25 July.

- [20] **Melgani, F., and Bruzzone, L.** (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on geoscience and remote sensing*, 42, 1778-1790.
- [21] **Watanachaturaporn, P., Arora, M. K., and Varshney, P. K.** (2006). Hyperspectral image classification using support vector machines: A comparison with decision tree and neural network classifiers. In *American Society for Photogrammetry & Remote Sensing (ASPRS) Annual Conference*, Reno, NV.
- [22] **Dong, P., and Liu, J.** (2011). Hyperspectral image classification using support vector machines with an efficient principal component analysis scheme. In *Foundations of Intelligent Systems*, 131-140.
- [23] **Cortes, C., & Vapnik, V.** (1995). Support-vector networks. *Machine learning*, 20, 273-297.
- [24] **Veropoulos, K., Campbell, C., and Cristianini, N.** (1999). Controlling the sensitivity of support vector machines, In *Proceedings of the international joint conference on AI*, 55, 60.
- [25] **Osowski, S., Siwek, K., and Markiewicz, T.** (2004). Mlp and svm networks-a comparative study, *The 6th Nordic Signal Processing Symposium – NORSIG*, Espoo, Finland, June 9 – 11.
- [26] **Osowski, S., Hoai, L. T., and Markiewicz, T.** (2004). Support vector machine-based expert system for reliable heartbeat recognition. *IEEE transactions on biomedical engineering*, 51, 582-589.
- [27] **Çomak, E., Arslan, A., and Türkoğlu, İ.** (2007). A decision support system based on support vector machines for diagnosis of the heart valve diseases. *Computers in Biology and Medicine*, 37, 21-27.
- [28] **Meier, T. B., Desphande, A. S., Vergun, S., Nair, V. A., Song, J., Biswal, B. B., and Prabhakaran, V.** (2012). Support vector machine classification and characterization of age-related reorganization of functional brain networks. *Neuroimage*, 60, 601-613.
- [29] **Osuna, E., Freund, R., and Girosit, F.** (1997, June). Training support vector machines: an application to face detection. In *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Juan, Puerto Rico, USA, USA, 17-19 June.
- [30] **Trabelsi, I., and Ayed, D. B.** (2012). On the use of different feature extraction methods for linear and non linear kernels. *6th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT)*, Sousse, Tunisia, 21-24 March.

- [31] **Bhatia, S., Prakash, P., and Pillai, G. N.** (2008). SVM based decision support system for heart disease classification with integer-coded genetic algorithm to select critical features. In Proceedings of the world congress on engineering and computer science, San Francisco, USA, 22-24 October.
- [32] **Djeffal, A.**(1999). Utilisation de methode support vector machines dans l'analyse des bases de donnees. Mohamed Khider-Biskra University, Biskra, Algeria, PhD thesis.
- [33] **Ran, Q., Li, W., Du, Q., and Yang, C.** (2015). Hyperspectral image classification for mapping agricultural tillage practices. *Journal of Applied Remote Sensing*, 9, 097298.
- [34] **Garcia-Allende, P. B., Conde, O. M., Amado, M., Quintela, A., and Lopez-Higuera, J. M.** (2008). Hyperspectral data processing algorithm combining principal component analysis and K nearest neighbours. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIV*, 6966.
- [35] **Fix, E., and Hodges Jr, J. L.** (1951). Discriminatory analysis-nonparametric discrimination: consistency properties. California Univ Berkeley.
- [36] **Kasapoğlu, N. G.** (2007). Border Feature Detection and Adaptation: A New Algorithm for Classification of Remote Sensing Images (Doctoral dissertation, PhD Thesis, Istanbul Technical University).
- [37] **Imani, M., and Ghassemian, H.** (2013). Boundary based supervised classification of hyperspectral images with limited training samples. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*,3, 203-207.
- [38] **Fu, Y., Zhao, C., Wang, J., Jia, X., Yang, G., Song, X., and Feng, H.** (2017). An improved combination of spectral and spatial features for vegetation classification in hyperspectral images. *Remote Sensing*, 9, 261.

ÖZGEÇMİŞ



Adı Soyadı: Lina YOUNUS

Doğum yeri ve tarihi: İRAK. 03.09.1992

E-Posta: lina.younus@gmail.com

EĞİTİM:

- **Lisans:** 2014, Al-Mansour Üniversitesi, Bilgisayar Telekomünikasyon Mühendisliği, Bağdat, Irak
- **Yüksek Lisans:** 2018, İstanbul Aydın Üniversitesi, Elektrik Elektronik Mühendisliği, İstanbul, Türkiye

PROFESYONEL DENEYİM VE ÖDÜLLER

YAYINLAR / TEZ ÜZERİNDE SUNUMLAR:

- RF Mühendislik ve Tasarımda Sunum
- Mikrodalga Tekniğinde Sunum ve Uygulamalar
- İleri Matematikte Mühendislikte Sunum
- İleri Dijital İletişim Çok Boyutlu Sistemlerde Sunum
- Görüntü İşleme ve Mühendislik Uygulamalarında Sunum
- Kablosuz Ağlarda Sunum
- Uzaktan Algılama Uygulamalarında Sunum

