

T.C.
BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**SEÇİLMEMİŞ VERİ ÖRNEKLERİ SORUNU İÇİN
UYGULANABİLİR BİR BOYUT AZALTMA
ALGORİTMASININ GELİŞTİRİLMESİ**

Doktora Tezi

Tezi Hazırlayan:
Ümit ÖZTÜRK

İstanbul, 2022

T.C.

BEYKENT ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**SEÇİLMEMİŞ VERİ ÖRNEKLERİ SORUNU İÇİN
UYGULANABİLİR BİR BOYUT AZALTMA
ALGORİTMASININ GELİŞTİRİLMESİ**

Doktora Tezi

Tezi Hazırlayan:

Ümit ÖZTÜRK

160821006

0000-0002-5360-1358

Danışman: Dr. Öğr. Üyesi Atınc YILMAZ

İstanbul, 2022

YEMİN METNİ

Doktora Tezi olarak sunduđum ‘Seçilmemiş Veri Örnekleri Sorunu için Uygulanabilir Bir Boyut Azaltma Algoritmasının Geliştirilmesi’ başlıklı bu çalışmamın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiđimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiđini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. 3.../2.../2022(Tarih)

(İmzası)

Adayın Adı Soyadı

Limit Öztürk

TEZ ONAYI

Beykent Üniversitesi Lisansüstü Eğitim Enstitüsü *Bilgisayar Mühendisliği Doktora* öğrencisi *160821006* numaralı *Ümit ÖZTÜRK*'ün hazırladığı *“Seçilmemiş Veri Örnekleri Sorunu için Uygulanabilir Bir Boyut Azaltma Algoritmasının Geliştirilmesi”* konulu DOKTORA TEZİ ile ilgili TEZ SAVUNMA SINAVI Lisansüstü Öğretim ve Sınav Yönetmeliğinin ilgili maddesi uyarınca 11.01.2022 günü saat 13:30'da Zoom programı aracılığıyla on-line olarak yapılmış, sorulan sorulara alınan cevaplar sonucunda adayın tezinin **KABUL**'üne **OYBİRLİĞİ**yle karar verilmiştir.

JÜRİ ÜYESİ	KANAATI	İMZA
Dr. Öğr. Üyesi At*** YI*** (Danışman) (Beykent Üniversitesi)		
Dr. Öğr. Üyesi Ed*** ŞA*** (Üye) (Beykent Üniversitesi)		
Prof. Dr. Ve*** CO*** (Üye) (Beykent Üniversitesi)		
Doç. Dr. Yü*** Ba*** SA*** (Üye) (Bahçeşehir Üniversitesi)		
Dr. Öğr. Üyesi Öm*** ÇE*** (Üye) (Milli Savunma Üniversitesi)		

Adı Soyadı : Ümit ÖZTÜRK
Danışmanı : Dr. Öğr. Üyesi Atınç YILMAZ
Türü ve Tarihi : Doktora Tezi, 2022
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Boyut Azaltma, Manifold Öğrenme, Seçilmemiş Veri Örnekleri Sorunu, Sınıflandırma, Yüz Tanıma, Hiperspektral Görüntüleme, Yapay Zeka

ÖZ

SEÇİLMEMİŞ VERİ ÖRNEKLERİ SORUNU İÇİN UYGULANABİLİR BİR BOYUT AZALTMA ALGORİTMASININ GELİŞTİRİLMESİ

Boyut Azaltma, zaman karmaşıklığı ve depolama sorunları için önemli avantajlar sunar. Geleneksel Manifold Öğrenme ise özellik çıkarma için başarılı kanıtlanmış önemli bir Boyut Azaltma çalışma alanı olmakla beraber Seçilmemiş Veri Örnekleri Sorunu için uygulanabilir olmadığından hızlı ve pratik çalışmamaktadırlar. Literatürde sonradan Manifold Öğrenme tabanlı Seçilmemiş Veri Örnekleri için uygulanabilir doğrusal yöntemler sunulmuştur. Çalışmada hem Seçilmemiş Veri Örnekleri Sorunu için uygulanabilir hem de özellik öğrenme kabiliyeti rakiplerinden daha üstün Doğrusal Manifold Öğrenme tabanlı bir Boyut Azaltma yönteminin geliştirilmesi ve etkinliğinin gösterilmesi amaçlanmıştır.

Önerilen yöntem, veriler arasındaki saçılım bilgisini denetimli bir yolla katsayılandırıp ağırlık matrisi oluşturmak için gereken özel bir fonksiyona vermektedir. Bu yöntem Konum Koruyan Dönüşüm ve Ortogonal Konum Koruyan Dönüşüm algoritmalarına uygulanmıştır. Deneyler Seçilmemiş Veri Örnekleri Sorunu için uygulanabilir olan Konum Koruyan Dönüşüm, Ortogonal Konum Koruyan Dönüşüm, Komşuluk Koruyan Gömüleme, ve Ortogonal Komşuluk Koruyan Gömüleme algoritmaları üzerinde karşılaştırmalı olarak gerçekleştirilmiştir. Yüz tanıma ve hiperspektral görüntüleme alanlarına ait deneylerden elde edilen bulgularda önerilen yöntemin rakiplerine oranla daha üstün sınıflandırma doğruluk performansı gösterdiği görülmüştür. Ayrıca elde edilen ağırlık matrisleri, saçılım grafikleri, bant grafikleri,

korelasyon matrisleri ve anlamlılık matrislerindeki deęişimler sınıflar arasındaki ayırt edicilik bilgisinin daha iyi seviyeye geldiğini göstermiştir. Sonuç olarak, rakiplerine oranla daha üstün özellik öğrenme kapasitesine sahip Seçilmemiş Veri Örnekleri Sorunu için uygulanabilir bir Boyut Azaltma yöntemi sunulmuş ve bu yöntemin etkinliği hem yüz tanıma hem de hiperspektral görüntüleme alanlarında kanıtlanmıştır.



Name and Surname : Ümit ÖZTÜRK
Supervisor : Dr. Lecturer Atınç YILMAZ
Degree and Date : Doctoral Thesis, 2022
Major : Computer Engineering
Keywords : Dimensionality Reduction, Manifold Learning, Out of Sample Problem, Classification, Face Recognition, Hyperspectral Imaging, Artificial Intelligence

ABSTRACT

DEVELOPMENT OF A DIMENSIONALITY REDUCTION ALGORITHM APPLICABLE FOR OUT OF SAMPLE PROBLEM

Dimensionality Reduction provides advantages for time complexity and storage. Traditional Manifold Learning, on the other hand, is an important proven field of Dimensionality Reduction study for feature extraction, but it is not applicable for the Out of Sample Problem, so they cannot work quickly and practically. Afterwards, in the literature, linear methods applicable for out of sample problem on Manifold Learning are presented. In the study, it is aimed to develop a Linear Manifold Learning-based Dimension Reduction method that is both applicable to the Out of Sample Problem and superior to its competitors in feature learning capability and demonstrate its effectiveness.

The proposed method forms the coefficient that carries scattering information among the data and give it to a special function required to create a weight matrix in a supervised way. This method is applied to the Locality Preserving Projection and Orthogonal Locality Preserving Projection algorithms. Experiments are performed comparatively on the Locality Preserving Projection, Orthogonal Locality Preserving Projection, Neighborhood Preserving Embedding, and Orthogonal Neighborhood Preserving Embedding algorithms applicable to the Out of Sample Problem. In the findings obtained from the experiments of face recognition and hyperspectral imaging fields, it was seen that the proposed method showed superior classification accuracy performance compared to its competitors. In addition, the changes in weight matrices, scatterplots, band graphs, correlation matrices and significance matrices showed that

the discrimination information between classes improved. As a result, a Dimensionality Reduction method has been presented for the Out of Sample problem, which has a superior feature learning capacity compared to its competitors, and the effectiveness of this method has been proven in both face recognition and hyperspectral imaging.



İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ.....	iii
ŞEKİLLER LİSTESİ.....	iv
KISALTMALAR	viii
GİRİŞ.....	1

BİRİNCİ BÖLÜM

1. LİTERATÜRÜN İNCELEMESİ.....	4
---------------------------------------	----------

İKİNCİ BÖLÜM

2. BAZI ÖNEMLİ DOĞRUSAL MÖ YÖNTEMLERİ	7
2.1. KKD	7
2.2. KKG	9
2.3. OKKD ve OKKG	11

ÜÇÜNCÜ BÖLÜM

3. ÖNERİLEN YÖNTEM.....	14
3.1. Yaklaşım.....	14
3.2. Önerilen Algoritma.....	14

DÖRDÜNCÜ BÖLÜM

4. DENEYLER.....	18
4.1. Kullanılan Veri Setleri	18
4.2. Deneysel Kurulumlar	24
4.2.1. Sentetik Veriler	24
4.2.2. Parametre Davranışları ve Sınıflandırma	24
4.2.3. İstatistiksel Çıkarımlar için Yapılan Deneyler	26
4.2.4. Verilerin Deneysel Seçimi	27
4.3. Deneyler için Akış Şeması	28

BEŞİNCİ BÖLÜM

5. DENEY SONUÇLARI.....	31
5.1. Sentetik Veriler ile İlgili Sonuçlar.....	31
5.2. Parametre Davranışının İncelenmesi.....	33
5.3. Sınıflandırmaya ve İstatistiksel Deneylere İlişkin Sonuçlar	37
5.3.1. Sınıflandırma Sonuçları.....	37
5.3.1.1. Yüz Verileri için Sınıflandırma Sonuçları.....	37
5.3.1.2. Hiperspektral Veriler için Sınıflandırma Sonuçları.....	40
5.3.2. İstatistiksel Analiz için Sonuçlar	43
5.3.2.1. Yüz Verileri için İstatistiksel Sonuçlar.....	43
5.3.2.2. Hiperspektral Veriler için İstatistiksel Sonuçlar.....	51
5.4. Deney Sonuçlarının Analizi	58
SONUÇ	61
KAYNAKÇA.....	63
ÖZGEÇMİŞ.....	68

TABLÖLAR LİSTESİ

Sayfa No.

Tablo 1. Indian Pines Kesin Referansına ait Sınıflar ve Örnek Sayıları.....	23
Tablo 2. KSC Kesin Referansına Ait Sınıflar ve Örnek Sayıları.....	23
Tablo 3. Yüz Verileri için Deneysel Özellikler.....	27
Tablo 4. Hiperspektral Veriler için Deneysel Özellikler.....	27
Tablo 5. Yüz Verilerinde Sınıflandırma Doğruluk Sonuçları.....	38
Tablo 6. Hiperspektral Verilerde Sınıflandırma Doğruluk Sonuçları.....	41

ŞEKİLLER LİSTESİ

Sayfa No.

Şekil 1. Önerilen Algoritmanın Sözde Kodu	17
Şekil 2. ORL Veri Setinden Bazı Örnek Görüntüler.....	19
Şekil 3. Yale Veri Setinden Bazı Örnek Görüntüler.....	19
Şekil 4. E. Yale Veri Setinden Bazı Örnek Görüntüler.....	20
Şekil 5. (a) Indian Pines Verisinde Örnek Bant Üzerinden Alınan Görüntü, (b) Indian Pines Verisinin Kesin Referans Görseli.....	21
Şekil 6. (a) KSC Verisine Ait Renkli Görüntü, (b) KSC Görüntüsünden Elde Edilen Kesin Referans.....	22
Şekil 7. (a) Indian Pines ve (b) KSC için Azaltılmış Boyut – Sınıflandırma Doğruluk Yüzdesi Grafikleri.....	25
Şekil 8. Deneyler için Akış Şeması.....	30
Şekil 9. ‘3d_clusters’ Sentetik Verisi.....	31
Şekil 10. ‘3d_clusters’ Sentetik Verisi Üzerinden KKD ile Elde Edilen iki Boyutlu Gösterim	32
Şekil 11. ‘3d_clusters’ Sentetik Verisi Üzerinden Önerilen Yöntem + KKD ile Elde Edilen iki Boyutlu Gösterim	32
Şekil 12. ORL Veri setinde KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği.....	33
Şekil 13. ORL Veri setinde Önerilen Yöntem + KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği.....	34
Şekil 14. Yale Veri setinde KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği.....	34

Şekil 15. Yale Veri setinde Önerilen Yöntem + KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği.....	35
Şekil 16. E. Yale Veri setinde KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği.....	35
Şekil 17. E. Yale Veri setinde Önerilen Yöntem + KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği.....	36
Şekil 18. ORL Veri setinde Sınıf Bazında İyileşmeler- μ_c Grafiği.....	39
Şekil 19. Yale Veri setinde Sınıf Bazında İyileşmeler- μ_c Grafiği.....	39
Şekil 20. E. Yale Veri setinde Sınıf Bazında İyileşmeler- μ_c Grafiği.....	40
Şekil 21. Indian Pines Veri Setinde Sınıf Bazında İyileşmeler- μ_c Grafiği.....	42
Şekil 22. KSC Veri Setinde Sınıf Bazında İyileşmeler- μ_c Grafiği.....	42
Şekil 23. ORL Veri Seti için Ağırlık Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD.....	43
Şekil 24. Yale Veri Seti için Ağırlık Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	44
Şekil 25. E. Yale Veri Seti için Ağırlık Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	44
Şekil 26. ORL Veri Seti için OKKD üzerinde Üç Boyutlu Saçılım Grafiği.....	45
Şekil 27. ORL Veri Seti için Önerilen Yöntem + OKKD üzerinde Üç Boyutlu Saçılım Grafiği.....	46
Şekil 28. Yale Veri Seti için KKD üzerinde Üç Boyutlu Saçılım Grafiği.....	46
Şekil 29. Yale Veri Seti için Önerilen Yöntem + KKD üzerinde Üç Boyutlu Saçılım Grafiği.....	47
Şekil 30. E. Yale Veri Seti için KKD üzerinde Üç Boyutlu Saçılım Grafiği....	47

Şekil 31. E. Yale Veri Seti için Önerilen Yöntem + KKD üzerinde Üç Boyutlu Saçılım Grafiği.....	48
Şekil 32. ORL Veri Seti için Korelasyon Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD.....	49
Şekil 33. Yale Veri Seti için Korelasyon Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	49
Şekil 34. E. Yale Veri Seti için Korelasyon Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	50
Şekil 35. Yale Veri Seti için p-Değerleri Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	50
Şekil 36. E. Yale Veri Seti için p-Değerleri Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	51
Şekil 37. Indian Pines Veri Seti için Ağırlık Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	52
Şekil 38. KSC Veri Seti için Ağırlık Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD.....	52
Şekil 39. Indian Pines Veri Setinde ‘Zor Sınıflar’ için Bant 1-2 Bilgisi (a) KKD, (b) Önerilen Yöntem + KKD.....	54
Şekil 40. KSC Veri Setinde ‘Zor Sınıflar’ için Bant 1-2 Bilgisi (a) OKKD, (b) Önerilen Yöntem + OKKD.....	54
Şekil 41. Indian Pines Veri Setinde Rastgele Seçilen Sınıflar için Bant 11-12 Bilgisi (a) KKD, (b) Önerilen Yöntem + KKD.....	55
Şekil 42. KSC Veri Setinde Rastgele Seçilen Sınıflar için Bant 11-12 Bilgisi (a) OKKD, (b) Önerilen Yöntem + OKKD.....	55

Şekil 43. Indian Pines Veri Seti için Korelasyon Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	56
Şekil 44. KSC Veri Seti için Korelasyon Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD.....	57
Şekil 45. Indian Pines Veri Seti için p-Değerleri Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD.....	57
Şekil 46. KSC Veri Seti için p-Değerleri Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD.....	58



KISALTMALAR

- BA:** Boyut Azaltma
DAA: Doğrusal Ayırıcılar Analizi
DBF: Dairesel Baz Fonksiyonları
DVM: Destek Vektör Makinaları
KKD: Konum Koruyan Dönüşüm
KKG: Komşuluk Koruyan Gömüleme
KSC: Kennedy Space Center (Kennedy Uzay Merkezi)
LDG: Lokal Doğrusal Gömüleme
LE: Laplacian Eigenmaps
LLE: Locally Linear Embedding (Lokal Doğrusal Gömüleme)
LPP: Locality Preserving Projections (Konum Koruyan Dönüşüm)
MÖ: Manifold Öğrenme
NPE: Neighborhood Preserving Embedding (Komşuluk Koruyan Gömüleme)
OA: Overall Accuracy (Genel Sınıflandırma Doğruluğu)
OKKD: Ortogonal Konum Koruyan Dönüşüm
OKKG: Ortogonal Komşuluk Koruyan Gömüleme
OLPP: Orthogonal Locality Preserving Projections (Ortogonal Konum Koruyan Dönüşüm)
ONPE: Orthogonal Neighborhood Preserving Embeddings (Ortogonal Komşuluk Koruyan Gömüleme)
ORL: Olivetti Research Laboratory (Olivetti Araştırma Laboratuvarı)
PCA: Principal Component Analysis (Temel Bileşenler Analizi)
SVM: Support Vector Machines (Destek Vektör Makinaları)
SVÖ: Seçilmemiş Veri Örnekleri
TBA: Temel Bileşenler Analizi

GİRİŞ

Boyut Azaltma (BA), yüksek boyutlu verilerin daha düşük boyutlu alt uzaya indirgenmesi anlamına gelir. Belli bir bilgi taşıyan vektörün var olandan daha düşük boyutlu başka bir vektör ile temsil edilebilmesi buna örnek teşkil eder. Bu durum, veri miktarının giderek artmasına paralel hesaplama gücünün daha verimli kullanılabilmesi noktasında önemli katkı sağlamaktadır.

BA algoritmaları global veya lokal olabilmektedirler. Özellik çıkarımı yaparken, global olanlar tüm veriler arasındaki; lokal olanlar ise birbirine en yakın örnekler arasındaki ilişkiyi dikkate almaktadırlar. Ayrıca bu algoritmalar doğrusal veya doğrusal olmayacak şekilde çalışabilmektedirler. Geleneksel doğrusal olmayan BA algoritmaları test verisini değerlendirirken bu veriyi elde olan önceki verilerle birleştirerek bir girdi oluşturmakta ve öğrenme sürecini yinelemektedirler. Bu sorun Seçilmemiş Veri Örnekleri (SVÖ) problemi olarak isimlendirilmektedir ve sınıflandırma amacı için pratik değildir.

BA yöntemlerinin denetimli ve denetimsiz olanları mevcuttur. Denetimsiz olan algoritmalarda özellik çıkarımı için sınıf bilgisi dikkate alınmazken, denetimli olanlarda sınıf bilgisi öğrenmeye katkı sağlamak üzere hesaplama katılmaktadır.

BA alanında Temel Bileşenler Analizi (TBA) ve Doğrusal Ayırıcılar Analizi (DAA) oldukça yaygın kullanılan iki algoritmadır. Manifold Öğrenme (MÖ) ise BA literatüründe ciddi bir yer tutan bir diğer araştırma alanıdır. Ayrıca, MÖ yöntemlerinin TBA ve DAA yöntemlerine kıyasla daha başarılı özellik çıkarımı yapabildiği çeşitli çalışmalarla gösterilmiştir. Ancak geleneksel MÖ yöntemleri doğrusal olarak çalışmamaktadırlar. Bu durum başarılı sonuçlarına rağmen onları seçilmemiş veriler olarak nitelenen test verisini sürekli olarak eğitim sürecine katma zorunlulukları sebebiyle hesaplama karmaşıklığı açısından dezavantajlı duruma sokmaktadır. Bu sebeple geleneksel MÖ algoritmaları yüksek boyutlu veriler üzerinde gerçek zamanlı sınıflandırma görevi için hızlı ve pratik olamamaktadırlar. Bununla beraber, SVÖ problemi için uygulanabilir MÖ yöntemleri de sunulmuştur. Bunlardan bazı önemlileri Konum Koruyan Dönüşüm (KKD), Ortogonal Konum Koruyan Dönüşüm (OKKD), Komşuluk Koruyan Gömüleme (KKG), Ortogonal Komşuluk Koruyan Gömüleme (OKKG) algoritmalarıdır. Bu noktada, hem SVÖ sorunu için uygulanabilir hem de

rakiplerinden daha başarılı sınıflandırma doğruluk performansı sunabilen bir BA algoritması geliştirmek hızlı ve doğru çalışan sınıflandırma sistemleri oluşturabilmek açısından önem kazanmaktadır. Bu doğrultuda çalışmada SVÖ problemi için uygulanabilir ve daha gelişmiş özellik çıkarma kabiliyeti olan doğrusal bir MÖ algoritması geliştirilmesi hedeflenmektedir. Bu hedefle temelde denetimsiz çalışan MÖ yöntemlerinin çalışma esnasında kullandıkları ağırlık matrislerinin denetimli şekilde oluşturulması önerilmiştir. Daha önce ilgili çalışmalarda bu yaklaşımın bazı MÖ yöntemleri üzerindeki uygulamaları ve bu uygulamaların sınıflandırma doğruluk performansındaki gelişmeye olumlu katkıları gösterilmiştir. Bu çalışmada da benzer bir yaklaşım doğrusal MÖ üzerinde uygulanmış, sınıf bilgisi özgün bir yöntemle hesaplamaya katılmıştır.

Çalışmadaki yöntem aynı sınıflara ait örneklerin saçılım bilgisinin ağırlık matrisini belirleyen fonksiyonda dinamik bir parametre olarak hesaba katılması üzerine kurulu denetimli bir yaklaşım içerir. Bu fikir lokal özellikli, doğrusal, denetimsiz ve SVÖ için uygulanabilir olan KKD ve OKKD algoritmaları üzerinde gerçekleştirilmiştir. Önerilen yöntemin gerçekleştirilmesi ile elde edilen yeni algoritmalar diğer rakipleri olan KKD, OKKD, KKG ve OKKG algoritmaları ile sınıflandırma deneyleri üzerinden karşılaştırılmıştır. Çalışmada azaltılmış boyutlar üzerinden elde edilen sınıflandırma performansları, ağırlık matrisleri, saçılım grafikleri, bant analizleri, korelasyonlar ve bu korelasyonların ne kadar anlamlı olduğuna dair görselleştirmeler sunulmuştur.

Çalışma, hem doğrusal yöntemlerin sunduğu uygulamadaki pratikliğe ve hıza sahip hem de geometrik yapıyı saklayabilme kapasiteli, MÖ tabanlı çalışabilen, buna ilaveten doğrusal MÖ tabanlı rakiplerinden daha etkin sınıflandırma doğruluk sonuçları verebilen bir BA yöntemi araştırmaktadır. Ayrıca çalışma sınıflandırma temelli deney sonuçlarının istatistiksel unsurlarla desteklenip desteklenmediğini araştırmaktadır. Sınıflandırma performansları ile analitik bulgular beraber değerlendirilmiştir. Önerilen yöntemin etkinliği hem yüz tanıma hem de hiperspektral görüntüleme alanı üzerinde araştırılmıştır. Önerilen yöntem ile elde edilen yeni özellikler üzerinden yapılan sınıflandırma doğruluk oranlarının diğer önemli doğrusal MÖ tabanlı rakiplerinden her iki alanda da daha üstün olması beklenmektedir.

Birinci bölümde literatür araştırması yapılmıştır. Çalışma bütünlüğünde tarama yapılmıştır. İkinci bölümde var olan ve deneylerde kullanılan algoritmalar sunulmuştur. Bu algoritmalar teknik açıdan açıklanmıştır. Üçüncü bölümde önerilen yöntem anlatılmıştır. Genel yaklaşımla beraber önerilen algoritma detaylandırılmıştır. Sözde kod verilmiştir.

Dördüncü bölüm, veri setlerinin tanıtıldığı ve deneylerin yapılış şekline dair bilgi sunmaktadır. Ayrıca bu bölümde deneysel yöntem için bir de akış şeması mevcuttur. Beşinci bölümde ise önerilen yöntemin KKD veya OKKD üzerinde uygulanması ile elde edilen algoritmalar rakipleri ile sınıflandırma doğruluk oranları üzerinden karşılaştırılmıştır. Bölüm aynı zamanda parametre davranışlarının incelenmesi, ağırlık matrisleri, saçılım ve bant bilgisi, korelasyon matrisleri ve bu matrislerin anlamlılığı üzerinden karşılaştırmalı analiz içerir.

Son kısım ise sonuç bölümüdür. Bu kısımda çalışmanın önemi vurgulanmış ve bulguları değerlendirmiştir. Ayrıca gelecekte yapılabilecek çalışmalara dair öneriler sunulmuştur.

BİRİNCİ BÖLÜM

1. LİTERATÜRÜN İNCELENMESİ

BA yöntemleri, girdiden gereksiz verinin atılmasıyla beraber hesaplama süresi ve veri depolama açısından önemli avantajlar sunar (Pal ve Foody 2010, 2297-2307). Bu algoritmalar yüksek boyuta dair çizge topolojisini kaybetmeme amaçlı olarak lokal veya global geometrik ilişkiyi korurlar (Pless ve Souvenir 2009, 83-94; Zhang, Huang ve Wang 2010, 54-61; Van Der Maaten, Postma ve Van Den Herik 2009, 66-71). Yüz tanıma, medikal görüntü segmentasyonu ve obje tanıma gibi çeşitli alanlara uygulanabilirler (Pless ve Souvenir 2009, 83-94).

DAA ve TBA özellik çıkarmada oldukça yaygın kullanılan iki doğrusal BA algoritmasıdır (Fisher 1936, 179-188; Rodarmel ve Shan 2002, 115-122). Bununla beraber, bazı çalışmalarda MÖ yöntemlerinin doğrusal yöntemlere oranla daha iyi özellik çıkarımı sağladığı gösterilmiştir (Tenenbaum, De Silva ve Langford 2000, 2319-2323; Roweis ve Saul 2000, 2323-2326). Ayrıca, hiperspektral görüntülere daha kolay erişim sağlanabilmesi ve hesaplama teknolojisinin gelişmesi ile beraber bu alanda MÖ uygulamaları daha fazla yer bulmuştur (Lunga, Prasad, Crawford ve Ersoy 2013, 55-66). Ancak MÖ algoritmalarında yeni gelen veri ile birlikte önceden var olan verinin birleştirilmesi zorunluluğu sonucu oluşan girdinin öğrenme fazında kullanılması SVÖ problemini doğurmaktadır.

SVÖ problemi içeren algoritmalar hesaplama açısından karmaşıklık yarattığından hiperspektral görüntülerin sınıflandırılması, yüz tanıma, hedef tespiti, obje takibi ve tespiti görevleri için pratik değildir. Temelde doğrusal olmayan BA yöntemleri bu sorunla karşı karşıyadırlar (H. Qiao, P. Zhang, D. Wang ve B. Zhang 2012, 51-63). Bununla beraber, polinomsal dönüşümler, Nyström yöntemi, Kernel Hilbert uzayı ve sparse grid fonksiyonları kullanılarak doğrusal olmayan yöntemlerdeki SVÖ sorunu için genelleştirmeler üretilen çalışmalar mevcuttur (H. Qiao, P. Zhang, D. Wang ve B. Zhang 2012, 51-63; Bengio, Paiement, Vincent, Delalleau, Roux ve Oumet 2003, 177-184; Chen, Washinger ve Golland 2013, 292-303; Peherstorfer, Pflüger ve Bungartz 2011, 112-121). Doğrusal yöntemler SVÖ problemi için uygulanabilirlerdir.

Literatürde çeşitli MÖ algoritmaları mevcuttur. Laplacian Eigenmaps (LE) ve Lokal Doğrusal Gömüleme (LDG) iki doğrusal olmayan manifold öğrenme algoritmasıdır (Belkin ve Niyogi 2003, 1373-1396; De Ridder ve Duin 2002, 1-12). Ağırlık matrisi hesaplamasında LE, heat kernel fonksiyonunu kullanırken; LDG konveks optimizasyon uygulamaktadır. KKD ve KKG; LE ve LDG algoritmalarını sırasıyla doğrusallaştırmaktadır (He ve Niyogi 2004, 153-160; He, Cai, Yan ve Zhang 2005, 1208-1213). Doğrusallaştırma SVÖ sorunu için uygulanabilirlik kazandırmaktadır. OKKD ve OKKG yöntemleri ise KKD ve KKG algoritmalarına ortogonalite çerçevesinde kısıtlar getirmektedir (Cai, He, Han ve Zhang 2006, 3608-3614; Liu, Yin, Feng, Dong ve Wang 2007, 133). Dönüşüm matrisleri ortogonal olacak şekilde sınırlandırılmıştır (H. Qiao, P. Zhang, D. Wang ve B. Zhang 2012, 51-63). Literatürde bahsi geçen algoritmalar dışında LE ve LDG algoritmalarını genişletebilen Nyström ise kernel tabanlı bir yöntemdir (Zhang ve Kwok 2010, 1576-1587). Bu yöntemler ilgili çalışmada hiperspektral görüntüler üzerinde değerlendirilmiştir (Yılmaz ve Öztürk 2019, 381-386).

Geleneksel MÖ yöntemleri tamamen denetimsizdir. Başka ifadeyle sınıf bilgisi hesaplamada kullanılmamaktadır. Bununla beraber verinin geometrik yapısını korurken sınıf içi mesafeyi minimize etmek ve sınıflar arası mesafeyi maksimize etmek amacıyla denetimli algoritmalar da önerilmiştir. Denetimli algoritmalar doğrusal ya da doğrusal olmayacak biçimde uygulanabilirler. LE ve LDG algoritmalarında örnekler arası mesafeyi tekrar tanımlayan denetimli algoritmalar çalışmalarda mevcuttur (Raducanu ve Dornika 2012, 2432-2444; Chen ve Liu 2011, 29-48). Ayrıca kimi çalışmalarda daha iyi sınıf ayrımı yapabilme amaçlı KKD için bazı doğrusal gömüleme teknikleri gösterilmiştir (Yang, Sun ve Zhang 2011, 1649-1657; Zhang, Zhao ve Chow 2012, 97-111; Hua, Bai, Wang ve Liu 2012, 150-157). Benzer şekilde KKG algoritmasında komşuluk grafi oluşturma basamağında aynı amaç doğrultusunda özel bir yöntem geliştirilmiştir (Wen, Yan ve Lin 2014, 3710-3713). Bunlardan başka, sınıf ayrımsallığını arttıran bazı Fisher tabanlı doğrusal manifold öğrenme yöntemleri sunulmuştur (Sugiyama 2007, 1027-1061; Li, Liu, Zhao ve Zhang 2013, 1-7; Cui ve Fan 2012, 1471-1481; Wang ve Chen 2009, 429-436). Bunlarla beraber doğrusal olmayan denetimli BA algoritmalarının analizini içeren bir çalışma mevcuttur (Vural ve Guillemot 2017, 5741-5795). Aynı çalışmada denetimli

yaklaşımın sınıflar arasındaki ayrımsallığı daha belirgin hale getirerek daha iyi veri temsili yapabildiği belirtilmiştir (Vural ve Guillemot 2017, 5741-5795).

LDG algoritmasını denetimli hale getiren bir çalışmada yanlış komşuluk seçimlerini önlemek amacıyla veriler arasındaki mesafe optimize edilmiştir (De Ridder, Kouropteva, Okun, Pietikäinen ve Duin 2003, 333-341). Bu yapılırken aynı sınıfa ait olmayan iki veri arasındaki maksimum mesafe özel bir katsayı ile çarpılarak gerçek mesafeye eklenmektedir. Aynı sınıfa ait örnekler arasındaki mesafe hesabı ise orijinal LDG algoritmasındaki gibi yapılmaktadır. Bu duruma göre ayrıklık matrisi oluşturulur ve ağırlık matrisinin hesabı için konveks optimizasyon uygulanır. Bu çalışmada ise LE tabanlı bir yöntem önerilmiştir. LE tabanlı yöntemde konveks optimizasyon yerine özel fonksiyonlar devreye girmektedir. LE tabanlı denetimli bir yaklaşım ilgili çalışmada sunulmuştur (Raducanu ve Dornaika 2012, 2432-2444). Algoritma sınıf içi örnekler arası mesafeyi minimize, sınıflar arası mesafeyi ise maksimize ederek ayrımsallığı belirginleştirmeyi hedeflemektedir. Bunun için özel fonksiyonda ölçekleme parametresine yer vermektedirler. Bu parametrenin sabit kullanıldığı fonksiyon sonucu aynı ve farklı sınıflarda bir eşik değeri vasıtasıyla seçilerek ağırlık matrislerinin belirlenmesinde kullanılmaktadır. Daha sonra oluşturulan bu ağırlık matrisleri optimize edilmektedir. Tez çalışmasında önerilen yöntemde ise LE tabanlı bu teknikteki gibi iki farklı ağırlık matrisi tanımlanmamaktadır. Onun yerine tek bir ağırlık matrisi sınıflara özel değişken bir parametre üzerinden tanımlanmaktadır. Sınıf içi örneklere ait saçılım bilgisi kullanılmaktadır (Öztürk ve Yılmaz 2021, 9063). Bununla beraber hem LDG hem de LE için sunulan ilgili teknikler SVÖ sorunu için uygulanabilir değildir. LE yöntemini doğrusallaştırarak projeksiyon yapılabilmesine olanak sağlayan KKD ise SVÖ için uygulanabilir (He ve Niyogi 2004, 153-160). Bunu hesaplanan ağırlık matrisinden faydalanarak elde ettiği dönüşüm matrisi üzerinden yapmaktadır. Dönüşüm matrisinin test verisi ile çarpılması ile özellikler elde edilmektedir. Bu tez çalışmasında LE tabanlı denetimli yaklaşımın KKD ve OKKD üzerinde özgün bir şekilde uyarlanmasıyla birlikte SVÖ sorunu için uygulanabilir ve ayrıca özellik çıkarma kabiliyeti rakiplerine göre çok daha gelişmiş bir BA yöntemi sunulmaktadır (Öztürk ve Yılmaz 2021, 9063).

İKİNCİ BÖLÜM

2. BAZI ÖNEMLİ DOĞRUSAL MÖ YÖNTEMLERİ

Bu bölümde deneylerde de kullanılan SVÖ için uygulanabilir bazı önemli MÖ algoritmaları teknik açıdan açıklanmıştır.

2.1. KKD

Bu yöntemde komşuluklar kullanılarak veriler bir alt uzaya indirgenir. Lokal bir yöntemdir. LE için doğrusal projeksiyon sağlamaktadır ($y_i = a^T x_i$). KKD algoritmasını anlamak üzere verilen bazı ön tanımlar şu şekildedir: X ve Y 'nin sırasıyla yüksek boyutlu veriyi ve alt uzaya indirgenmiş veriyi temsil eden birer matris olduğu varsayılmıştır. İfadelerden a dönüşüm vektörünü, x_i ve y_i sırasıyla yüksek ve düşük boyutlu veri noktalarını göstermektedir. Veri sayısı, indirgenmemiş ve indirgenmiş boyutlar da sırasıyla m, n ve l olarak alınmıştır.

LPP algoritmasında ilk adım veriler arasındaki ilişkiyi ifade etmek için mesafe bazlı bir referans matris çıkarmaktır. Mesafe matrisi, Öklit ilişkisinden faydalanılarak Denklem 1'de gösterildiği şekilde çıkarılmaktadır.

$$d(x_i, x_j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{in} - x_{jn})^2} \quad (1)$$

Süreç k tane en yakın komşu belirlemek ile devam eder. Bir veri noktasına komşu olmayan diğer veriler 0 ile gösterilmektedir. Daha sonra 0 ile gösterilmeyen mevcut veriye heat kernel fonksiyonu uygulanmaktadır. Bu fonksiyon uygulandığında ağırlık matrisi elde edilecektir. Ağırlık matrisi Denklem 2'deki gibi oluşturulmaktadır.

$$W_{ij} = e^{-\frac{\|x_i - x_j\|^2}{t}} \quad (2)$$

Burada, t ve W sırasıyla heat kernel parametresi ve ağırlık matrisini ifade etmektedir. Ağırlık matrisi $m \times m$ boyutunda hesaplandıktan sonra Denklem 3 ile gösterilen maliyet fonksiyonu içinde kullanılarak fonksiyonun minimize edilmesi gereklidir.

$$\sum_{i,j}(y_i - y_j)^2 W_{ij} \quad (3)$$

Denklem 3, $y^T = a^T X$ varsayılarak basitleştirilir. Basitleştirme, bir dizi cebirsel işlemin seri uygulanması şeklinde yapılmaktadır:

$$\begin{aligned} & \sum_{i,j}(y_i - y_j)^2 W_{ij} \\ &= \sum_{i,j}(y_i^2 + y_j^2 - 2y_i y_j)^2 W_{ij} \\ &= 2 \sum_i y_i^2 \sum_j W_{ij} - 2 \sum_{i,j} y_i y_j W_{ij} \\ &= 2 \sum_i y_i^2 D_{ii} - 2 \sum_{i,j} y_i y_j W_{ij} = 2y^T D y - 2y^T W y \\ &= 2y^T L y = \frac{1}{2} (2y^T L y) \\ &= a^T X (D - W) X^T a = a^T X L X^T a \end{aligned}$$

Sadeleştirme, şartı ile beraber verilen ve Denklem 4 ile gösterilen minimizasyon problemine dönüşmektedir. İlgili denklem, şartı ile beraber verilmiştir. Bu denklemde D , Diyagonal matristir ve $D_{ii} = \sum_j W_{ji}$ şeklinde hesaplanmaktadır. L ise Laplacian matristir ve $D - W$ ye eşittir. Ayrıca a dönüşüm vektörünü temsil etmektedir. Algoritma süreci, genelleştirilmiş özdeğer çözümünü elde etme işlemi ile devam etmektedir. Genelleştirilmiş özdeğer çözümü Denklem 5'te verildiği gibidir.

$$\min \quad a^T X L X^T a \quad (4)$$

$$a^T X D X^T a = 1$$

$$X L X^T a_i = \lambda_i X D X^T a_i \quad (5)$$

Yüksek boyutlu veri hangi boyuta indirgenecekse o kadar sayıda a özvektörü alınmaktadır. Her a_i için karşılık gelen özdeğer ise λ_i ile gösterilmektedir. En başta bu sayı l olarak verilmiştir. Bu durumda en küçük özdeğerlere karşılık gelen

özvektörlerden sırasıyla l tanesi seçilerek dönüşüm matrisi oluşturulmalıdır. Dönüşüm matrisi A ile gösterilmektedir. A elde edildikten sonra gerçekleşecek olan en son adım projeksiyonu sağlayarak veriyi alt uzaya indirgeme adıdır. Projeksiyonu sağlayan bu denklem, Denklem 6 ile gösterilmiştir.

$$x_i \rightarrow y_i = A^T x_i \quad (6)$$

Yüksek boyutlu verinin, dönüşüm matrisinin ve alt uzaya indirgenmiş verinin boyutları sırasıyla $n \times m$, $n \times l$ ve $l \times m$ şeklindedir.

Denklem 6 doğrusal izdüşümü sağlayan genel bir denklem olup bu çalışmada adı geçen KKD, KKG, Ortogonal KKD ve Ortogonal KKG algoritmaları tarafından kullanılmaktadır.

2.2. KKG

KKG metodu lokal yapıya bağlı diğer bir manifold öğrenme yöntemidir. LDG yöntemine doğrusal projeksiyon sağlamaktadır ($y_i = a^T x_i$). Ön tanımlarda X ve Y nin sırasıyla yüksek boyutlu veriyi ve alt uzaya indirgenmiş veriyi temsil eden birer matris olduğu varsayılmıştır. Dönüşüm vektörü a ile gösterilmiştir. İfadelerden x_i ve y_i sırasıyla yüksek ve düşük boyutlu veri noktalarını göstermektedir. Veri sayısı, indirgenmemiş ve indirgenmiş boyutlar da sırasıyla m, n ve d olarak alınmıştır.

KKG algoritmasında, komşuluk matrisinin oluşturulması ilk adımdır. Bu matris ilgili veri noktalarına en yakın k noktayı gözetmekte ve k komşuluk dışında kalanlar için 0 değeri vermektedir. Bundan sonraki adım ise 0 olmayan veri bağlantılarına ait ağırlıkları hesaplamaktır. Bu hesap konveks optimizasyon yoluyla yapılmaktadır. Hesaplama, Denklem 7 ile verilen fonksiyonun altında belirtilmiş şartı da dikkate alınarak minimize edilmesi şeklinde gerçekleşmektedir. W ağırlık matrisidir.

$$\sum_i ||x_i - \sum_j W_{ij} x_j||^2 \quad (7)$$

$$\sum_j W_{ij} = 1$$

Ağırlık matrisi hesaplandıktan sonra bir diğer fonksiyon minimize edilmelidir. Minimize edilmesi gereken fonksiyon Denklem 8 ile gösterilmiştir. Bu denklemde ağırlık matrisinin korunması, y_i koordinatlarının optimize edilmesi hedeflenmektedir.

$$\sum_i (y_i - \sum_j W_{ij} y_j)^2 \quad (8)$$

Denklem 8, $y^T = a^T X$ varsayılarak basitleştirilir:

$$\begin{aligned} z_i &= y_i - \sum_j W_{ij} y_j \\ z &= y - Wy = (I - W)y \\ g(y) &= \sum_i (y_i - \sum_j W_{ij} y_j)^2 \\ &= \sum_j z_i^2 = z^T z \\ &= y^T (I - W)^T (I - W) y \\ &= a^T X (I - W)^T (I - W) X^T a \\ &= a^T X M X^T a \end{aligned}$$

Sadeleştirmede I birim matrisini; $(I - W)^T (I - W)$ matematiksel sonucu ise M değerini göstermektedir. Sadeleştirme sonunda Denklem 9 ile verilen fonksiyonun beraberindeki şart altında minimize edilmesi gereklidir. Problem, en son Denklem 10 ile gösterilen genelleştirilmiş özdeğer çözümünü elde etme işlemine dönüşmektedir.

$$\min \quad a^T X M X^T a \quad (9)$$

$$a^T X X^T a = 1$$

$$XX^T a_i = \lambda_i X X^T a_i \quad (10)$$

En küçük özdeğere (λ_i) karşılık gelen özvektörlerden (a_i) dönüşüm matrisi (A) oluşturulmaktadır. Özvektör sayısı d tane seçilmelidir. Daha sonra oluşturulan dönüşüm matrisi vasıtasıyla projeksiyon elde edilmektedir. Dönüşüm matrisi A olarak gösterilirse elde edilen indirgenmiş veri Denklem 6'dan faydalanılarak bulunmalıdır. Yüksek boyutlu verinin, dönüşüm matrisinin ve alt uzaya indirgenmiş verinin boyutları sırasıyla $n \times m$, $n \times d$ ve $d \times m$ şeklindedir.

2.3. OKKD ve OKKG

OKKD ve OKKG, KKD ve KKG yöntemlerine benzer şekilde uygulanmaktadır. Ön tanımlarda yüksek boyutlu veri X , dönüşüm vektörü a ile gösterilmiştir. İndirgenmiş boyut l 'dir. OKKD ve OKKG'nin KKD ve KKG yöntemlerinden farkı, Denklem 11'de verildiği gibi dönüşüm matrislerinin (A) ortogonal olmasıdır. I birim matrisini ifade etmektedir.

$$AA^T = I \quad (11)$$

Ortogonal KKD algoritmasının işleyişindeki adımlar şu şekilde verilmiştir:

Adım 1 – TBA projeksiyonu: Bu adımda verilerin TBA kullanarak alt uzaya projeksiyonu sağlanmaktadır. 0 olan özdeğerler atılmaktadır. TBA uygulanması esnasında oluşan dönüşüm matrisi A_{TBA} ile gösterilmektedir.

Adım 2 – Komşuluk grafiği: Komşuluk KKD yönteminde anlatıldığı gibi çıkarılmaktadır. Bir başka deyişle, bir veri noktasına en yakın k tane komşu belirlenmektedir. Komşu olmayanlar 0 ile gösterilmektedir.

Adım 3 – Ağırlıkları seçmek: Ağırlıklar KKD yöntemindeki gibi hesaplanmaktadır. Bu süreç LE'de de aynı şekilde uygulanmaktadır. Denklem 2' deki heat kernel fonksiyonu temel alınmaktadır.

Adım 4 – Ortogonal basis vektörlerin bulunması: Bu noktada hesaplanması gereken vektörler $a_1, a_2, \dots, a_k \dots$ şeklinde devam etmektedir. Vektörlerden a_1 , $(XDX^T)^{-1}XLX^T$ matrisinin en küçük özdeğerine karşılık gelen özvektörüdür. L ve D KKD algoritmasında tanımlandığı gibi kullanılmaktadır. Kalan özvektörler ise $M^{(k)}$ 'nin en küçük özdeğerine karşılık gelen özvektörleridir. Bu özvektörler Denklem 12-14'ün iteratif olarak çözülmesiyle bulunmaktadır. A dönüşüm matrisi, B ve M ise iteratif hesaplama esnasında elde edilen ara matrislerdir.

$$A^{(k-1)} = [a_1, a_2, \dots, a_{(k-1)}] \quad (12)$$

$$B^{(k-1)} = [A^{(k-1)}]^T (XDX^T)^{-1} A^{(k-1)} \quad (13)$$

$$M^{(k)} = \{I - (XDX^T)^{-1} A^{(k-1)} [B^{(k-1)}]^{-1} [A^{(k-1)}]^T\} (XDX^T)^{-1} XLX^T \quad (14)$$

Adım 5 – Gömüleme işlemi: Dönüşüm matrisi hesaplandıktan sonra bu matris A_{OKKD} olarak gösterilmektedir. $A_{OKKD} = [a_1, a_2, \dots, a_l]$ alınmaktadır. Yeni oluşan dönüşüm matrisi (A) Denklem 15 ile gösterilmektedir. Denklem 15'in Denklem 6 üzerinde kullanılmasıyla indirgeme gerçekleştirilmektedir. İndirgeme sonucunda X verisinin l boyutlu uzaya projeksiyonu sağlanmaktadır.

$$A = A_{TBA} A_{OKKD} \quad (15)$$

Ortogonal KKG algoritmasının çalışma şekli de benzer adımlarla uygulanmaktadır. Fakat bu noktada, KKD yerine KKG algoritmasının işleme koşulları geçerli olmaktadır:

Adım 1 – TBA projeksiyonu: Bu adımda verilerin TBA kullanarak alt uzaya projeksiyonu sağlanmaktadır. 0 değerli özdeğerler atılmaktadır. TBA'nın uygulanması esnasında oluşan dönüşüm matrisi A_{TBA} ile gösterilmektedir.

Adım 2 – Komşuluk grafiği: Komşuluk KKG yöntemindeki gibi çıkarılmaktadır. Bir başka deyişle, bir veri noktasına en yakın k tane komşu belirlenmektedir. Komşu olmayanlar 0 ile gösterilmektedir.

Adım 3 – Ağırlıkları seçmek: Ağırlıklar KKG yöntemindeki gibi hesaplanmaktadır. Bu süreç LDG’ de de aynı şekilde uygulanmaktadır. Konveks optimizasyon kullanılmaktadır.

Adım 4 – Ortogonal basis vektörlerin bulunması: Burada hesaplanması gereken vektörler $a_1, a_2, \dots, a_k \dots$ şeklinde devam etmektedir. Vektörlerden $a_1, (XX^T)^{-1}XMX^T$ matrisinin en küçük özdeğere karşılık gelen özvektördür. Kalan özvektörler ise $J^{(k)}$ ’nin en küçük özdeğere karşılık gelen özvektörleridir. Bu özvektörler Denklem 12, Denklem 16 ve 17’nin iteratif olarak çözülmesiyle bulunmaktadır. M , KKG yönteminde tanımlandığı şekildedir. A dönüşüm matrisi, B ve J ise iteratif hesaplama esnasında elde edilen ara matrislerdir.

$$B^{(k-1)} = [A^{(k-1)}]^T (XX^T)^{-1} A^{(k-1)} \quad (16)$$

$$J^{(k)} = \{I - (XX^T)^{-1} A^{(k-1)} [B^{(k-1)}]^{-1} [A^{(k-1)}]^T\} (XX^T)^{-1} XMX^T \quad (17)$$

Adım 5 – Gömüleme işlemi: Dönüşüm matrisi hesaplandıktan sonra bu matris A_{OKKG} olarak gösterilmektedir. $A_{OKKG} = [a_1, a_2, \dots, a_l]$ alınmaktadır. Yeni oluşan dönüşüm matrisi (A) Denklem 18 ile gösterilmektedir. Denklem 18’in Denklem 6 üzerinde uygulanmasıyla indirgeme gerçekleştirilmektedir. İndirgeme sonucunda X verisinin l boyutlu uzaya projeksiyonu sağlanmaktadır.

$$A = A_{TBA} A_{OKKG} \quad (18)$$

ÜÇÜNCÜ BÖLÜM

3. ÖNERİLEN YÖNTEM

Bu bölümde çalışmada önerilen metot anlatılmıştır. Önce yaklaşım açısından bilgi sunulmuş ardından algoritma detaylandırılmıştır.

3.1. Yaklaşım

LE algoritması lokal geometriyi korumayı amaçlayan bir algoritmadır. Yöntemde önce komşuluk matrisi çıkarılır daha sonra ise Denklem 2 yardımıyla ağırlık matrisi bulunur. Bu faz hem KKD hem de OKKD yöntemleri için aynı şekilde uygulanmaktadır.

LE algoritması denetimsizdir. Bir çalışmada denetimli bir yaklaşımla nasıl ele alındığı gösterilmiştir (Chao, Luo ve Ding 2019, 341-358). İlgili çalışmada belli bir eşik değeri üzerinden sınıf içi ve sınıflar arası komşuluklar tespit edilmektedir. Sınıf içi ve sınıflar arası ilişki için W_w ve W_b olarak iki farklı ağırlık matrisi hesaplanmaktadır. Bu aşamada heat kernel fonksiyonu daha önceden belirlenmiş sabit t parametresi ile kullanılmaktadır. Daha sonra ise alt uzayda özellikleri elde etmek üzere $\sum_{i,j}(y_i - y_j)^2 W_{b,ij}$ ve $\sum_{i,j}(y_i - y_j)^2 W_{w,ij}$ fonksiyonlarının sırasıyla maksimize ve minimize edilmesi amaçlanarak genelleştirilmiş özdeğer çözümü sağlanmaktadır.

Önerilen yöntemde Denklem 2 ile gösterilen heat kernel fonksiyonu paydada değişken bir parametre ile yeniden tanımlanmıştır (Öztürk ve Yılmaz 2021, 9063). Parametre değeri, sınıf bazında örneklerin saçılım bilgisi temeline dayalı olarak denetimli bir yaklaşımla hesaplanarak W , ağırlık matrisi bulunmaktadır. Optimizasyon tamamen W üzerinden yapılır. Bu da önerilen metodun iki tane değil sadece bir ağırlık matrisi üzerinden yapıldığı anlamı taşımaktadır. Bu metot hem KKD hem de OKKD için uygulanmıştır.

3.2. Önerilen Algoritma

Önerilen algoritmanın açıklanabilmesini kolaylaştırmak için bazı ön tanımlar yapılmalıdır. Bu noktada D , m değişkeninin eğitim veri sayısını gösterdiği $m \times m$

boyutunda bir mesafe matrisi; μ_c ise, $1, 2, \dots, n$ içerisindeki her bir c , yani sınıf için özel olarak hesaplanan katsayıyı ifade etmektedir. Bu katsayı Denklem 19 ve 20'nin ardışık olarak hesaplanmasıyla bulunmaktadır (Öztürk ve Yılmaz 2021, 9063).

$$S_i = \sqrt{\frac{1}{k_i-1} \sum_{j=1}^{j=k_i} (D(i, I_{ij}) - avg_i)^2} \quad (19)$$

$$\mu_c = \frac{1}{t_c} \sum_{j=1}^{j=t_c} [S_{I_{grouped,c}}]_j \quad (20)$$

Denklem 19, D üzerinde sadece sınıf içi örnekleri dikkate alarak i ile gösterilen her bir satır için standart sapma hesaplamaktadır. S_i çıkışı 1'den m değerine kadar değerler barındıran bir vektördür. Aynı denklemde, k_i ilgili satır için sınıf içi örnek sayısıdır. I_{ij} her bir satır için sınıf içi örneklerin indisini saklamaktadır. Burada maksimum j , k_i değerine bağlıdır. D matrisinin her bir satırında sınıf içi örneklerin ortalaması avg_i ile verilmektedir.

Denklem 20'de sınıf bazında değerler içeren μ_c hesaplanmaktadır. Burada S üzerinde her bir sınıf için geçerli indislere ait değerler gruplanmış ve $[S_{I_{grouped,c}}]$ ile gösterilmiştir. Bu değer bir liste veri yapısına benzemektedir. Dolayısıyla indisler $I_{grouped,c}$ üzerinde saklanmaktadır. Sınıflara ait toplam örnek sayıları ise t_c ile gösterilmektedir. Burada c sınıfı nitelemektedir.

Denklem 19 ve Denklem 20 ardışık olarak uygulandıktan sonra n tane farklı μ üretilmektedir. D matrisinin simetrik yapısından dolayı denklemlerde satır ve sütun yer değiştirebilmektedir. Sonunda elde edilen μ_c değerleri ağırlık matrisi W 'yi bulmak için gereken formülde kullanılmaktadır. Önerilen yöntemin KKD ve OKKD için uygulanması esnasında geçerli adımlar gösterilmiştir (Öztürk ve Yılmaz 2021, 9063):

- Komşuluk grafiği oluşturulmaktadır.
- K tane en yakın komşu olan örnekler için Denklem 21 uygulanmaktadır. Denklemde $t = 2.s^2$ olarak alınmaktadır. Parametre t ve s heat kernel parametreleridir. Mesafesi ölçülen iki veri noktası x_i ve x_j ile gösterilmektedir.

$$W_{ij} = \begin{cases} e^{-\frac{\|x_i - x_j\|^2}{t} \frac{1}{\mu_c p}}, & \text{eğer } c(x_i) = c(x_j) \\ e^{-\frac{\|x_i - x_j\|^2}{t}}, & \text{diğer} \end{cases} \quad (21)$$

- K en yakın komşu örnekler için yeni ağırlıklar Denklem 21 ile hesaplanmaktadır. Eğer iki örneğin sınıfı aynıysa ($c(x_i) = c(x_j)$) μ_c parametresinden faydalanılmaktadır. Formülün ilk bölümündeki p sabiti ise genel anlamda W ağırlık matrisini ölçeklemek içindir. Eğer örneklerin sınıfları aynı değilse heat kernel fonksiyonu üzerinde bir değişiklik yapılmadan uygulanmaktadır.
- Komşuluk grafiğinde bağlı olmayan örnekler için yani k en yakın komşuluk barındırmayan örnekler için ağırlık matrisindeki ilişki 0 olarak belirtilmektedir.
- Aynı sınıfa ait $W_{ij} = 0$ koşulunu sağlayan değerler Denklem 21'in ilk bölümündeki gibi güncellenmekte ve takiben W matrisinin ilgili satırında, k en yakın komşu örnekler dahilindeki sınıf dışı maksimum değer ise 0 yapılmaktadır.
- Genelleştirilmiş eigenvalue çözümü ise KKD ve OKKD algoritmalarında olduğu gibi uygulanmaktadır.

Adımları verilen uygulamanın temel sözde kodu Şekil 1 ile gösterilmiştir. Algoritmanın en son kısmı KKD ve OKKD algoritmalarında verilen genelleştirilmiş özdeğer çözümünün aynısıdır. Bu sebeple sözde kod üzerinde gösterilmemiştir.

Şekil 1'deki algoritmanın karmaşıklığı zamanda ve uzayda $O(m^2)$ olarak görülmektedir. Fakat algoritmanın çalışması için gereken sözde kodun başında tanımlanmış değişkenleri saklamak üzere fazladan hafıza gereksinimi mevcuttur.

Algoritma: Önerilen Yöntem

$D_{m \times m}$, mesafe matrisi; $K_{m \times m}$, komşuluk bilgisini içeren matris (komşudur, komşu değildir); $L_{m \times m}$, aynı sınıf dışı olup olmadığı bilgisini içeren matris (aynı sınıfta değildir ve aynı sınıftadır); $Y_{1 \times m}$, örneklerin sınıf bilgisini içeren vektör; $W_{m \times m}$, $J_{m \times m}$, $N_{c \times m}$, $S_{1 \times m}$ ve $\mu_{c \times 1}$, u , bir tamsayı; ve p , Denklem 21’de kullanılan float tipinde değişken, uygulama esnasında ihtiyaç duyulan sıfır matrisler ve değişkenlerdir:

c : Toplam sınıf sayısı ve numaralandırılması.

m : Toplam eğitim verisi sayısı.

u, p algoritma ihtiyacına uygun bağımsız değişkenler.

For $i = 1$ to m do

For $j = 1$ to m do

If ($Y(1,i) \neq Y(1,j)$)

$J(i,j) = D(i,j)$

end

end

$S(1,i) \leftarrow J_{m \times m}$ (sıfırlar dışında) her bir satır için standart sapma hesapla

For $i = 1$ to c do

For $j = 1$ to m do

If ($Y(1,j) = c$)

$N(c,i) = S(1,j)$

end

end

$\mu(c,1) \leftarrow N_{c \times m}$ (sıfırlar dışında) her bir satır için ortalama hesapla

For $i = 1$ to m do

For $j = 1$ to m do

If ($Y(1,i) = Y(1,j) \ \&\& \ K(i,j) = 1$)

$W(i,j) = \exp(-D(i,j)^2/2.s^2) \cdot \mu(Y(1,j),1).p$

Elseif ($Y(1,i) \neq Y(1,j) \ \&\& \ K(i,j) = 1$)

$W(i,j) = \exp(-D(i,j)^2/2.s^2)$

end

end

For $i = 1$ to m do

For $j = 1$ to m do

If ($Y(1,i) = Y(1,j) \ \&\& \ K(i,j) = 0$)

$u = \text{maksimum_sınıf_dışı_indis_bul}(W(i,:), L(i,:) = 1 \text{ üzerinden})$

$W(i,u) = 0$

$L(i,u) = 0$

$W(i,j) = \exp(-D(i,j)^2/2.s^2) \cdot \mu(Y(1,j),1).p$

end

end

Şekil 1. Önerilen Algoritmanın Sözde Kodu

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>

DÖRDÜNCÜ BÖLÜM

4. DENEYLER

Bu bölümde çalışma içerisinde deneylerde kullanılan veriler tanıtılmıştır. Verilerin nasıl kullanıldığı açıklanarak deneylerin yapılış şekilleri anlatılmıştır.

4.1. Kullanılan Veri Setleri

Çalışmada bir sentetik veri seti ile üç adet yüz veri seti ve iki tane de hiperspektral veri seti kullanılmıştır.

Çalışmada kullanılan sentetik veri seti '3d_clusters' olup açık bir kütüphane üzerinden elde edilebilmektedir (Laurens Van Der Maaten, Matlab Toolbox for Dimensionality Reduction, <https://lvdmaaten.github.io/drtoolbox/>, Erişim Tarihi: 20.02.2021). Kütüphane, sınıf bulutları oluşturmaya imkan vermektedir. Örneklere belirli oranlarda gürültü eklenebilmektedir.

Çalışma içerisinde deneylerde özellikle iki farklı araştırma alanı üzerine yoğunlaşmıştır. Bunlardan ilki yüz tanımadır. Bu alanda kullanılan temel veri setlerinden birisi ORL olarak adlandırılan yüz veri setidir. Bu veri seti Nisan 1992 ve Nisan 1994 tarihleri arasında *AT&T Laboratories Cambridge* tarafından üretilmiştir (Cambridge University, The Database of Faces, <https://cam-orl.co.uk/facedatabase.html>, Erişim Tarihi: 30.01.2020). Veri setinde 40 farklı kişiye ait 10'ar örnek bulunmaktadır. Bazı kişilere ait görüntüler farklı ışıklandırmalar; açık-kapalı gözler; gülen-normal ifade ve gözlüklü-gözlüksüz olarak örnekler barındırmaktadır (Samaria ve Harter 1994, 138-142). Arka plan karanlık ve homojen yapıdadır. ORL veri tabanından alınmış bazı örnekler Şekil 2 ile verilmiştir. Her bir görüntü 256'lık grayscale seviyesinde 92×112 çözünürlüğünde elde edilmiştir ve dosyasında .pgm uzantısı ile kaydedilmiştir. Sınıflar 1 ile 40 arasında numaralandırılmıştır.

İkinci yüz veri seti Yale veri setidir. Bu veri seti 15 kişiye ait 11'er tane yani toplamda 165 görüntü içermektedir (Belhumeur, Hespanha ve Kriegman, 1997). Görüntüler, merkezi, sağdan ve soldan ışık; gözlüklü-gözlüksüz; normal, üzgün,

uykulu, şaşırılmış ve gözü açık-kapalı şartlarında elde edilmiştir. Yale veri setinden bazı örnek görüntüler Şekil 3 ile gösterilmiştir.



Şekil 2. ORL Veri Setinden Bazı Örnek Görüntüler

Kaynak: Lee, E. J. (2013). Face Recognition Based on Improved Fuzzy RBF Neural Network for Smart Device. *Journal of Korea Multimedia Society*, 16(11), 1338-1347. <https://doi.org/10.9717/kmms.2013.16.11.1338>



Şekil 3. Yale Veri Setinden Bazı Örnek Görüntüler

Kaynak: Khalili Mobarakeh, A., Cabrera Carrillo, J. A., & Castillo Aguilar, J. J. (2019). Robust face recognition based on a new supervised kernel subspace learning method. *Sensors*, 19(7), 1643. <https://doi.org/10.3390/s19071643>

Deneylerde üçüncü olarak kullanılan diğer veri seti Yale veri setinin genişletilmiş bir versiyonu anlamına gelen ‘Extended Yale’ olarak bilinen veri setidir. Çalışmada kısaltılmış olarak E. Yale olarak ifade edilmiştir. Bu veri seti 38 farklı bireye ait 9’ar farklı poz 64 farklı ışıklandırma varyasyonu içermektedir (Georghiades, Belhumeur ve Kriegman 2001, 643-660). Veri setinden örnek görüntüler Şekil 4 üzerinde verilmiştir.



Şekil 4. E. Yale Veri Setinden Bazı Örnek Görüntüler


Kaynak: Zhao, J., Huang, Y., Luo, S., Tian, M., & Zou, Q. (2008, September). Face recognition with Neighboring Discriminant Analysis. In *2008 8th IEEE International Conference on Automatic Face & Gesture Recognition* (pp. 1-6). IEEE. 10.1109/AFGR.2008.4813320

Yale veri setleri için farklı çözünürlüklerde opsiyonlar bulunmaktadır. Bu çalışmada kullanılan Yale veri setlerine web üzerinde ilgili kaynaktan erişilmiştir (Deng Cai, Four Face Databases in Matlab Format, <http://www.cad.zju.edu.cn/home/dengcai/Data/FaceData.html>, Erişim Tarihi: 30.01.2020). İlgili kaynaktaki kırılmış versiyonlar kullanılmış olup çözünürlükleri Yale ve E. Yale veri setleri için sırasıyla 64×64 ve 32×32 'dir.

Çalışmada üzerine çalışılan diğer alan hiperspektral görüntüleme alanıdır. Hiperspektral görüntüleme alanı ile ilgili veriler son zamanlarda hızla artış göstermiştir. Hiperspektral görüntüleme çalışmasında kullanılan veri setleri Indian Pines ve Kennedy Space Center (KSC) verileridir (Grupo De Inteligencia

Computacional, Hyperspectral Remote Sensing Scenes, [http://www.ehu.es/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes), Eriřim Tarihi: 20.02.2021).

Indian Pines verisi 1992 yılında AVIRIS tarafından 20m uzamsal çözünürlükte elde edilmiştir. Çevrenin üçte ikisi tarımsal alan, geriye kalan kısımlar orman veya daimi bitki örtüsünden oluşmaktadır. Genellikle düzgün şekilli tarım arazileri içermektedir. Görüntüler 145×145 piksel çözünürlüğündedir. 0.4-2.5×10⁻⁶ m dalga boyunda 224 banttan oluşmaktadır. Su emilim etkisi kaldırıldıktan sonra 200 bant kalmaktadır. Kesin referansı toplam 16 sınıf 10249 veri içermektedir. Şekil 5 bu veri seti için örnek bir bant görüntüsü ve kesin referans bilgisine dair bir görsel sunmaktadır.




Şekil 5. (a) Indian Pines Verisinde Örnek Bant Üzerinden Alınan Görüntü, (b) Indian Pines Verisinin Kesin Referans Görseli.

Kaynak: Grupo De Inteligencia Computacional, Hyperspectral Remote Sensing Scenes, [http://www.ehu.es/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes), Eriřim Tarihi: 20.02.2021.

Kullanılan diğ er hiperspektral görüntüleme verisi KSC, AVIRIS tarafından 1996 yılında, Florida’da bulunan Kennedy Space Center üzerinden elde edilmiştir. Veri, 10 nm genişlik ve 400-2500 nm dalga boyu arasındaki 224 kanaldan oluşmakla beraber, su emilim etkisini ve düşük kalitede sinyal içeren bantları çıkardıktan sonra 176 kanal kalmaktadır. Görüntü 614×512 piksele, 18m uzamsal çözünürlüğe sahiptir

(Mu, Guo ve Liu 2020, 125). Çevreyi temsil eden 13 sınıf barındırmaktadır. KSC verisinin renkli bir görüntüsü ve kesin referansı Şekil 6 ile gösterilmiştir.



Şekil 6. (a) KSC Verisine Ait Renkli Görüntü, (b) KSC Görüntüsünden Elde Edilen Kesin Referans.

Kaynak: Mu, C., Guo, Z., & Liu, Y. (2020). A multi-scale and multi-level spectral-spatial feature fusion network for hyperspectral image classification. *Remote Sensing*, 12(1), 125. <https://doi.org/10.3390/rs12010125>

Deneylerde kullanılan yüz veri setlerinde sınıflara ait örnek sayıları homojen iken hiperspektral veri setlerinde yani Indian Pines ve KSC verilerinde örnek sayıları birbirinden farklıdır. Bazı sınıflarda ise oldukça düşük sayıda örnek vardır. Indian Pines ve KSC kesin referansına ait sınıflar ve sınıflar bazında ait örnek sayıları sırasıyla Tablo 1 ve Tablo 2 üzerinde gösterilmiştir.

Tablo 1 ve Tablo 2'ye bakıldığında Indian Pines ve KSC verilerinde uzaktan algılama ile görüntülenen bölgedeki çeşitlilik anlaşılabilmektedir. Tablo 1' e göre Indian Pines için örnek sayısının 50'nin altına düştüğü sınıfların var olduğu görülmektedir. Tablo 2 ise KSC için görüntülenen bölgedeki sınıf çeşitliliğini sunmaktadır. Bu tabloya göre sınıf bazındaki veri sayıları değişkenlik gösterse de Indian Pines içindeki sınıflar kadar düşük örnek sayısı içeren sınıf bulunmamaktadır. Sınıflara ait örnek sayıları Indian Pines ve KSC için sırasıyla 20-2455 ve 105-927 aralığındadır.

Tablo 1. Indian Pines Kesin Referansına ait Sınıflar ve Örnek Sayıları

Sınıf No	Sınıf İsmi	Örnek Sayısı
1	Yonca	46
2	Mısır – no till	1428
3	Mısır – min till	830
4	Mısır	237
5	Otlak	483
6	Çim ağaçları	730
7	Biçilmiş Mera	28
8	Sıralı Saman	478
9	Yulaf	20
10	Soya – no till	972
11	Soya – min till	2455
12	Soya	593
13	Buğday	205
14	Ormanlık	1265
15	Bina-Çim-Ağaç-Kütükler	386
16	Kaya-Çelik-Kuleler	93

Kaynak: Grupo De Inteligencia Computacional, Hyperspectral Remote Sensing Scenes, http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes, Erişim Tarihi: 20.02.2021

Tablo 2. KSC Kesin Referansına Ait Sınıflar ve Örnek Sayıları

Sınıf No	Sınıf İsmi	Örnek Sayısı
1	Bodur Ağaç	761
2	Söğüt Bataklık	243
3	Palmiye Tomurcuğu Yatağı	256
4	Palmiye-Meşe Tomurcuğu	252
5	Eğik Çam	161
6	Meşe/Geniş Yapraklı Yatağı	229
7	Odun Bataklığı	105
8	Graminoid Batakları	431
9	Spartina Batakları	520
10	Su Kamışı Batakları	404
11	Tuz Batakları	419
12	Çamurlu düzlükler	503
13	Su	927

Kaynak: Crawford, M. M., Ma, L., & Kim, W. (2011). Exploring nonlinear manifold learning for classification of hyperspectral data. In *Optical Remote Sensing* (pp. 207-234). Springer, Berlin, Heidelberg. 10.1007/978-3-642-14212-3_11

4.2. Deneysel Kurulumlar

Bu kısım deneylerin kapsamı, yapılış şekilleri; kullanılan verilerin öğrenme/test bakımından sayıları ve çözünürlükleri hakkında bilgi vermektedir.

4.2.1. Sentetik Veriler


Çalışmada önerilen metoda ait formüllerin özellik çıkarımında ne gibi etkiler gösterdiğinin ilk olarak gözlemlendiği kısımdır. Bu kısımda 6 farklı sınıfa ait toplam 500 adet üç boyutlu küme bulutları şeklinde veri üretilmiştir. Kütüphane bir önceki bölümde verilmiştir. İlgili kütüphane aynı zamanda örneklere belli oranlarda gürültü de eklenmesine olanak vermektedir. Çalışmada kullanılan sentetik veriler kütüphanedeki 'generate_data' fonksiyonu ile 0.9 oranında rastgele gürültü eklenerek oluşturulmuştur. Deneyler önerilen metot + KKD ve literatürdeki KKD üzerinde karşılaştırmalı olarak gerçekleştirilmiştir. Üç boyutlu veri iki boyuta indirgenmiştir.

4.2.2. Parametre Davranışları ve Sınıflandırma

Bundan sonraki kısımlarda bir azaltılmış boyut seçilmiş ve deneylerde sabitlenmiştir. Azaltılmış boyut, KKD algoritmasının tanıtıldığı yüz verileri ile deneyler içeren çalışmada çeşitli BA algoritmaları için 14 ve 33 şeklinde sunulmuştur (He ve Niyogi 2004, 153-160). Ayrıca, çeşitli MÖ algoritmaları sayesinde yüksek boyutlu veri belli aralıktaki azaltılmış boyuta indirgenerek sezgisel k ve s parametreleri ile Indian Pines ve KSC verileri üzerinde denenmiş Şekil 7 ile gösterilen sonuçlar elde edilmiştir (Yılmaz ve Öztürk 2019, 381-386). Çalışma genelinde k ve s parametreleri 'grid search' ile belirlenip hiperspektral veride eğitim veri oranı 0.1 iken; sadece bu kısımda yani, azaltılmış boyut araştırması kısmında k , komşuluk parametresi ve s , heat kernel parametresi sezgisel seçilip eğitim verisi oranı 0.2 alınmıştır.

Şekil 7'ye bakıldığında azaltılmış boyutun 20 olduğu noktalarda, her iki veride de sınıflandırma doğruluk oranlarının KKD, OKKD, KKG ve OKKG algoritmaları için yeterli doygunluğa ulaştığı görülmektedir. Çalışmada kullanılan yüz ve hiperspektral veriler üzerinde özellik çıkarımı amaçlı, alt uzayda standart bir boyut

belirlenirken anlatılanlar da göz önünde bulundurularak azaltılmış boyut sezgisel olarak 20 şeklinde seçilmiştir.



Şekil 7. (a) Indian Pines ve **(b)** KSC için Azaltılmış Boyut – Sınıflandırma Doğruluk Yüzdesi Grafikleri (OA: Ortalama Sınıflandırma Doğruluk Yüzdesi, d: Azaltılmış Boyut, LPP: KKD, OLPP: OKKD, NPE: KKG, ONPE: OKKG, NystromLE: LE Uzantısı, NystromLLE: LDG uzantısı)

Kaynak: Yılmaz, A., & Öztürk, Ü. (2019, June). An Analysis of Dimension Reduction Methods Applicable for Out of Sample Problem in Hyperspectral Images. In *2019 9th International Conference on Recent Advances in Space Technologies (RAST)* (pp. 381-386). IEEE. 10.1109/RAST.2019.8767826

Parametre deneyleri daha önce de bahsedilen ORL, Yale ve E. Yale yüz veri setleri üzerinde gerçekleştirilmiştir. Bu kısımda incelenen parametreler ilgili MÖ algoritmalarında komşuluğu temsil eden k , ve heat kernel parametresi, s parametreleridir. Parametreler için belli bir aralık seçilmiş, araştırma o aralıkta ‘grid search’ yaklaşımı ile yapılmıştır. Sonuçlar k - s -sınıflandırma doğruluk oranları bilgisini veren birer yüzey grafikleri olarak sunulmuştur. Bu kısım KKD ve önerilen yöntem + KKD yöntemlerine ilişkin deneyler içermektedir.

Sınıflandırma deneyleri hem yüz hem de hiperspektral verilerde, yani yukarıdaki verilere ilave olarak Indian Pines ve KSC verileri de dahil edilerek önerilen yöntem + KKD, önerilen yöntem + OKKD yöntemlerinin yanı sıra literatürde iyi

bilinen KKD, OKKD, KKG ve OKKG algoritmaları içerisinde kapsamlı bir şekilde yerine getirilmiştir.

Sınıflandırma doğruluk sonuçları deneysel verilerin öğrenme/test şeklinde birden fazla rastgele oluşturulduktan sonra deneylerin gerçekleştirilerek en iyi parametre sonuçlarının ortalamada değerlendirilmesi üzerine kurulmuştur.

4.2.3. İstatistiksel Çıkarımlar için Yapılan Deneyler

Çalışmada adı geçen istatistiksel değerlendirmeler önerilen yöntemin direk olarak yaptığı değişikliklerin izlenebildiği ağırlık matrisleri ve alt uzaydaki gömüler üzerinden elde edilen üç boyutlu saçılım grafikleri, bant bilgisi, korelasyon matrisleri ile korelasyondaki anlamlılığın ölçümüne dair matrisler üzerinde gerçekleştirilmiştir. Deneyler hem yüz hem de hiperspektral veriler üzerinde gerçekleştirilmiştir. Saçılım grafikleri üç boyutlu noktasal bilgi barındırmaktadırlar ve yüz verilerine aittirler. Bant bilgisi ise hiperspektral görüntüleme verisinden elde edilmektedir.

Çalışmada yapılan istatistiksel sonuçları elde etmek için yapılan deney stratejisi en iyi sınıflandırma doğruluk sonucunu veren algoritmayı önerilen yöntemin etkisini araştırmak için kullanmaktır. En iyi sonucu veren algoritma önerilen yöntem + KKD veya önerilen yöntem + OKKD olabilmektedir.

Çalışma, her veri seti dahilinde sınıf özelinde sınıflandırma başarı iyileştirmesi ve önerilen μ_c değerlerini iki boyutlu grafiklerle raporlama çalışması içermektedir. Sınıflandırma deneyleri vasıtasıyla istatistiksel bir görselleştirme sunulmuştur.

Yüz verilerine ait saçılım grafikleri alt uzayda 20 boyutun ilk üçünün görselleştirilmesi yapılmıştır. ORL, Yale ve E. Yale verileri için sırasıyla rastgele 7, 5 ve 6 sınıfa ait örnekler seçilerek özellikleri görselleştirilmiştir. Hiperspektral görüntüleme alanında yapılan bant analizi için ise zor ayırt edilebilen sınıflardan faydalanılmıştır. Indian Pines verisi için Sınıf 3 ve 12; KSC verisi için ise Sınıf 2-7-8-9 zor ayırt edilebilen sınıflar olarak raporlanmıştır (Crawford, Ma ve Kim 2011, 207-234). Bant 1 ve 2 üzerinde bu sınıflara ait örneklerin özellikleri incelenmiştir. Ayrıca Bant 11-12 deneysel olarak seçilerek üzerinde rastgele belirlenen farklı sınıfların ayırt edicilik özellikleri incelenmiştir.

Tüm istatistiksel deęerlendirmelere ait deneyler sınıflandırma deneylerinde optimal k ve s olarak belirlenmiş parametrelerin rastgele seçilen öğrenme/test verileri üzerinde çalıştırılmasıyla gerçekleştirilmiştir.

4.2.4. Verilerin Deneysel Seçimi

Deneylerin, bir sentetik veri seti dışında, tamamına yakını yüz ve hiperspektral görüntüler üzerinde gerçekleştirilmiştir. Her bir veri setinde öğrenme/test için kullanılan veri sayıları ve görüntü çözünürlükleri Tablo 3 ve Tablo 4 ile gösterilmiştir. Bu tablolara göre kullanılan yüz veri setlerinde eğitim verisi oranları ORL, Yale ve E. Yale için sırasıyla 0.50, 0.55 ve 0.20 iken; hiperspektral görüntülerde Indian Pines ve KSC için 0.10'dur.

Tablo 3. Yüz Verileri için Deneysel Özellikler

Deneysel Özellikler	Yüz Görüntüleri		
	ORL	Yale	E. Yale
Çözünürlük	92×112	64×64	32×32
Toplam Veri Sayısı	400	165	2414
Eğitim Veri Sayısı	200	90	491
Test Veri Sayısı	200	75	1923

Tablo 4. Hiperspektral Veriler için Deneysel Özellikler

Deneysel Özellikler	Hiperspektral Görüntüler	
	Indian Pines	KSC
Çözünürlük	145×145	614×512
Toplam Veri Sayısı	10249	5211
Eğitim Veri Sayısı	1031	528
Test Veri Sayısı	9218	4683

4.3. Deneyler için Akış Şeması

Deneylerde özellik çıkarımının kalitesi hem yüz hem de hiperspektral verilerde, sınıflandırılma doğruluk oranları ile ölçülmüştür. Parametre davranışlarının izlenmesine dair deneyler de aynı temeldedir. Bu deneyler önceden belirlenmiş şartlar altında standart bir akış uygulanarak gerçekleştirilmiştir. Deneylerde Şekil 8 ile gösterilen akış şeması uygulanmıştır (Öztürk ve Yılmaz 2021, 9063).

Şekil 8 ile gösterilen akış şemasına göre iki farklı veri eğitimi bulunmaktadır. Bunlar özellik çıkarımı esnasında dönüşüm matrisinin bulunması amacıyla yapılan eğitim ve azaltılmış boyutlar üzerinden sınıflandırma amacı ile yapılan eğitimlerdir. Bu akış şemasında makine öğrenmesinin iki farklı teorik konusunu deneysel maksatla kullanılmıştır.

Şekil 8’den de görüldüğü üzere deneyler öncelikle eğitim ve test verisinin belirlenmesiyle başlamaktadır. Daha sonra BA uygulanacak algoritma üzerinde k ve s parametreleri için sezgisel olarak araştırma sınırları ve atlama aralıkları belirlenmektedir. ‘Grid search’ uygulanmaktadır. Parametrelerden k deneylerde kullanılan tüm yöntemlerde varken s parametresi KKG ve OKKG için tanımlanmamaktadır.

Algoritma akış şemasında o an geçerli k ve s parametreleri ile eğitim verileri kullanılarak ağırlık matrisi hesaplanmakta, özdeğer çözümü sağlanmaktadır. Sonrasında da dönüşüm matrisi bulunmaktadır. Hesaplanan dönüşüm matrisi sayesinde eğitim ve test verileri için gereken özellikler boyut 20’ye düşürülerek çıkartılabilmektedir.


Eğitim ve test gömüleri elde edildikten sonra sınıflandırma devreye girmektedir. Bu noktada sınıflandırıcı olarak Destek Vektör Makineleri (DVM) seçilmiştir. Akış şemasında dönüşüm matrisi hesaplandıktan sonra önce eğitim verileri üzerinde DVM için en iyi parametre araştırması yapılmaktadır. DVM içerisinde Dairesel Baz Fonksiyonları (DBF), ceza parametresi, $C \in [2^{-4}, 2^8]$ ve çekirdek genişlik parametresi, $\gamma \in [2^{-4}, 2^4]$ ile beraber kullanılmıştır. Belirtilen aralıklarda 3’lü çapraz doğrulama ile birlikte ‘grid search’ uygulanmıştır.

Deney akışında bir sonraki adım, bulunan parametrelerin test gömülerinin tahmin edilmesi amacıyla kullanılması şeklindedir. Tahmin yapıldıktan sonra

sınıflandırma doğruluk sonucu kaydedilmekte ve k , s sınırları dahilinde algoritma devam etmektedir.

Şekil 8 ile gösterilen akış şeması rastgele seçilen bir eğitim/test veri kümesi üzerinde gerçekleşmektedir. Kırmızı dikdörtgen ile gösterilen kısım rastgele oluşturulmuş belli bir eğitim/test veri kümesine ait akıştır. Rastgele oluşturulan eğitim/test veri kümesi 5 farklı şekilde belirlenerek tekrarlanmaktadır. Böylelikle 5 farklı eğitim/test ikilisi üzerinden belli k - s aralıklarıyla kaydedilmiş sınıflandırma doğruluk oranları elde edilmektedir. Takiben her bir k - s ikilisi için ortalama alınarak sınıflandırma doğruluk sonuçlarına ulaşılmaktadır. Optimal k ve s parametre belirlenmesi için en iyi sınıflandırma doğruluk oranı aranmaktadır.

Genel itibariyle çapraz doğrulama parametre araştırması amacı için eğitim verisi üzerinde uygulanmakta iken test verisinde sadece tahminleme yapılmıştır. Test verisi daha önceden görülmeyen veridir. Test verisi üzerinden elde edilen sonuçlar, optimal k ve s seçimi için kullanılmıştır.



Şekil 8. Deneyler için Akış Şeması


BEŞİNCİ BÖLÜM

5. DENEY SONUÇLARI

Dördüncü bölüm sentetik veri, yüz verileri ve hiperspektral veriler üzerinde yapılan deneylerin sonuçları iki ve üç boyutlu grafiklerle gösterilmiştir. Dikkat çekici noktalar açıklanmıştır. Bölüm sonunda deney sonuçları ile ilgili analize yer verilmiştir.


5.1. Sentetik Veriler ile İlgili Sonuçlar

Üzerine belli oranda gürültü de eklenerek oluşturulan 6 sınıfa ait 500 adet sentetik veri Şekil 9 ile gösterilmiştir. Sonuçlar Şekil 10 ve 11 ile gösterilmiştir.




Şekil 9. ‘3d_clusters’ Sentetik Verisi (x, y ve z Özellikleri Temsil Eder)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>



Şekil 10. ‘3d_clusters’ Sentetik Verisi Üzerinden KKD ile Elde Edilen iki Boyutlu Gösterim (x ve y Özellikleri Temsil Eder)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>




Şekil 11. ‘3d_clusters’ Sentetik Verisi Üzerinden Önerilen Yöntem + KKD ile Elde Edilen iki Boyutlu Gösterim (x ve y Özellikleri Temsil Eder)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>


Şekil 10 ve 11; Şekil 9 ile gösterilen sentetik veri vasıtasıyla, önerilen yöntemin KKD üzerinde uygulanmadan ve uygulandıktan sonraki etkisini göstermektedir. Şekil 10'a bakıldığında mavi-yeşil ve macenta-siyan ile gösterilen sınıflara ait örneklerin kendi aralarında ayrılmamış olduğu görülmektedir. KKD algoritmasına önerilen yöntem uygulandıktan sonra alınan sonuçlar Şekil 11 ile verilmiş olup ilgili sınıf gruplarına ait örneklerin kendi aralarında daha belirgin şekilde ayrıştığı görülmektedir. Kırmızı ve sarı ile gösterilen sınıflara ait örneklerdeki ayrışma her iki durumda da belirgindir.

5.2. Parametre Davranışının İncelenmesi


Bu bölümde k , komşuluk parametresi ve s , heat kernel parametresi arasındaki davranış örnek yüz verileri kullanılarak incelenmiştir. Şekil 12-17 sırasıyla ORL, Yale ve E. Yale veri setlerine ait ikişer tane parametre davranışları-sınıflandırma doğruluk oranları hakkında bilgi veren yüzey grafikleri içermektedir. Grafikler ilgili veri setleri için sırasıyla KKD algoritmasının üzerinde önerilen algoritma uygulanmadan ve uygulandıktan sonraki değişimlerini göstermektedir.




Şekil 12. ORL Veri setinde KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği (k : Komşuluk Parametresi, s : Heat Kernel Parametresi, OA (%): Genel Sınıflandırma Doğruluk Yüzdesi, SVM: DVM, LPP: KKD)




Şekil 13. ORL Veri setinde Önerilen Yöntem + KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği (k: Komşuluk Parametresi, s: Heat Kernel Parametresi, OA (%): Genel Sınıflandırma Doğruluk Yüzdesi, SVM: DVM, LPP: KKD, Proposed: Önerilen Yöntem + KKD)




Şekil 14. Yale Veri setinde KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği (k: Komşuluk Parametresi, s: Heat Kernel Parametresi, OA (%): Genel Sınıflandırma Doğruluk Yüzdesi, SVM: DVM, LPP: KKD)



Şekil 15. Yale Veri setinde Önerilen Yöntem + KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği (k: Komşuluk Parametresi, s: Heat Kernel Parametresi, OA (%): Genel Sınıflandırma Doğruluk Yüzdesi, SVM: DVM, LPP: KKD, Proposed: Önerilen Yöntem + KKD)



Şekil 16. E. Yale Veri setinde KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği (k: Komşuluk Parametresi, s: Heat Kernel Parametresi, OA (%): Genel Sınıflandırma Doğruluk Yüzdesi, SVM: DVM, LPP: KKD)



Şekil 17. E. Yale Veri setinde Önerilen Yöntem + KKD Algoritmasının k - s - Sınıflandırma Doğruluğu Yüzey Grafiği (k : Komşuluk Parametresi, s : Heat Kernel Parametresi, OA (%): Genel Sınıflandırma Doğruluk Yüzdesi, SVM: DVM, LPP: KKD, Proposed: Önerilen Yöntem + KKD)

Şekil 12 ve 13'te önerilen yöntemin ORL veri seti üzerinden parametre davranışlarının değişimsel etkisi görülmektedir. Şekil 12'de k parametresinin sınıflandırma doğruluk yüzdesine herhangi bir etki etmediği alan oldukça fazladır. Bununla beraber, arama aralığının büyük bölümünde, Şekil 13, sınıflandırma doğruluk oranları baz alındığında, iniş çıkışların s parametresine bağlı olmadan k ile değişen keskin iniş çıkışların olduğu kararsız bir grafik sunmaktadır. Şekil 13 üzerindeki keskin iniş çıkışlı durumun $k \cong 40$ olana kadar devam ettiği görülmektedir. Şekil 14 ve 15 üzerinde Yale; Şekil 16 ve 17'de E. Yale veri seti üzerinden parametre davranışlarının değişimsel etkisi görülmektedir. Sınıflandırma başarımında değişimin olduğu bölgeler gözetildiğinde, değişimin Yale üzerindeki grafiklerde sınıflandırma doğruluk oranlarının hem k hem de s parametresine E. Yale veri setine göre daha bağımlı olduğu ve değişimlerin her iki parametre için de daha hassas olduğu gözlenmektedir.

Şekil 16 ve 17'de sınıflandırma doğruluk oranlarının s parametresindeki değişimle ani olarak düştüğü ya da yükseldiği görülmektedir. Şekil 16'da yüksek s

değerleri daha yüksek sınıflandırma doğruluk oranları verirken Şekil 17’de küçük s değerleri yüksek oranlar vermektedir. Bu iki şekilde de komşuluk parametre etkisinin s ’ye göre az olduğu görülmektedir.

5.3. Sınıflandırmaya ve İstatistiksel Deneylere İlişkin Sonuçlar

Bu kısımda sınıflandırma ve istatistiksel çıkarımlar yapma amaçlı gerçekleştirilen deney sonuçlarına yer verilmiştir. Öncelikle, sınıflandırma deneylerindeki sonuçlar verilmiştir. Ayrıca, sınıf bazında iyileştirmeler ve önerilen μ_c değerleri karşılaştırmalı olarak iki boyutlu grafiklerle sunulmuştur. Daha sonra sınıflandırma sonuçları ile ilişkili istatistiksel deneylere yer verilmiştir. Sonuçlar yüz ve hiperspektral veriler için ayrı ayrı açıklanmıştır.

5.3.1. Sınıflandırma Sonuçları

İlgili kısım sınıflandırmaya ilişkin sonuçlar içermektedir. Sınıf bazında iyileştirmeler ve önerilen katsayılar ayrıca iki boyutlu şekillerle verilmiştir.

5.3.1.1. Yüz Verileri için Sınıflandırma Sonuçları


ORL, Yale ve E. Yale veri setleri üzerinden alınan sınıflandırma sonuçları, Önerilen Yöntem + KKD, Önerilen Yöntem + OKKD, KKD, OKKD, KKG ve OKKG için standart sapmalar ve parametreleriyle beraber Tablo 5 üzerinde gösterilmiştir.

Tablo 5’te de görüldüğü gibi deneylerde kullanılan tüm Doğrusal MÖ yöntemleri gözetildiğinde yani genel anlamda en yüksek sınıflandırma başarımlar yüzdesi ORL veri setindedir. Bu üç veri seti için yalnızca var olan yöntemler dikkate alındığında ise en yüksek sınıflandırma başarımlar oranlarını veren algoritmalar ORL için OKKD; Yale ve E. Yale veri setleri için KKG algoritmalarıdır. Deneylerde kullanılan tüm Doğrusal MÖ algoritmaları dikkate alındığında ise en yüksek sınıflandırma sonucunu veren algoritmalar ORL için Önerilen Yöntem + OKKD; Yale ve E. Yale veri setleri için ise Önerilen Yöntem + KKD’dir. Bu algoritmalar Tablo 5 üzerinde kalınla işaretlenmiştir.


Tablo 5. Yüz Verilerinde Sınıflandırma Doğruluk Sonuçları (std: Standart Sapma, Önerilen Y.: Önerilen Yöntem)

Veri Seti	Doğrusal Yöntemi	MÖ Sınıflandırma Başarımı (%) $\pm$ std	Parametreler
ORL	KKD	94.8 $\pm$ 1.40	k = 5, s = 830
	KKG	94.7 $\pm$ 1.94	k = 22
	OKKD	94.9 $\pm$ 1.77	k = 13, s = 1300
	OKKG	93.8 $\pm$ 1.02	k = 33
	Önerilen Y. + KKD	95.0 $\pm$ 2.07	k = 55, s = 1470, p = 10 ⁻³
	Önerilen Y. + OKKD	96.1 $\pm$ 0.97	k = 30, s = 1300, p = 10⁻³
Yale	KKD	77.9 $\pm$ 3.92	k = 3, s = 1950
	KKG	78.1 $\pm$ 3.92	k = 33
	OKKD	74.1 $\pm$ 3.22	k = 12, s = 3800
	OKKG	76.8 $\pm$ 2.62	k = 44
	Önerilen Y. + KKD	85.6 $\pm$ 3.71	k = 90, s = 1150, p = 10⁻⁵
	Önerilen Y. + OKKD	75.2 $\pm$ 2.74	k = 6, s = 1800, p = 10 ⁻⁵
E. Yale	KKD	72.0 $\pm$ 0.68	k = 48, s = 600
	KKG	72.8 $\pm$ 1.08	k = 219
	OKKD	69.1 $\pm$ 1.50	k = 15, s = 1250
	OKKG	69.5 $\pm$ 1.04	k = 298
	Önerilen Y. + KKD	79.9 $\pm$ 1.15	k = 78, s = 250, p = 10⁻³
	Önerilen Y. + OKKD	68.4 $\pm$ 1.42	k = 12, s = 1100, p = 10 ⁻³


Kullanılan tüm yüz veri setlerinde önerilen yöntemin etkisiyle birlikte sınıf bazında sınıflandırma doğruluk sonuçlarındaki değişimin ve önerilen μ_c katsayılarının gözlenebildiği grafikler ORL, Yale ve E. Yale için Şekil 18-20 ile gösterilmiştir. Şekil 18’de iyileşmenin 0 olduğu noktalarda birçok sınıf olduğu görülmektedir. Bu durum, ilgili veri setinin sınıflarının büyük bölümünde zaten yüzde 100 başarı sağlanması sebebiyle oluşmuştur. ORL, Yale ve E. Yale kümülatif düşünüldüğünde toplam 93 sınıftan sadece 11 tanesinde önerilen yöntem sınıflandırma doğruluk oranlarında küçük düşüslere sebep olmuştur. Bunlardan 10 tanesi %5’ten daha az bir düşüş miktarıdır. İyileşme gerçekleşen sınıflarda ise oranlar %20’leri dahi bulabilmektedir. Genel anlamda μ_c katsayıları ile iyileşme oranları arasında belirgin bir korelasyon bulunmamaktadır.



Şekil 18. ORL Veri setinde Sınıf Bazında İyileşmeler- μ_c Grafiği (enhancement (%):
İyileşme Yüzdesi, coeff: μ_c Katsayısı)



Şekil 19. Yale Veri setinde Sınıf Bazında İyileşmeler- μ_c Grafiği (enhancement (%):
İyileşme Yüzdesi, coeff: μ_c Katsayısı)



Şekil 20. E. Yale Veri setinde Sınıf Bazında İyileşmeler- μ_c Grafiği (enhancement (%): İyileşme Yüzdesi, coeff: μ_c Katsayısı)

5.3.1.2. Hiperspektral Veriler için Sınıflandırma Sonuçları

Indian Pines ve KSC veri setleri üzerinden alınan sınıflandırma sonuçları, Önerilen Yöntem + KKD, Önerilen Yöntem + OKKD, KKD, OKKD, KKG ve OKKG için standart sapmalar ve parametreleriyle beraber Tablo 6 üzerinde gösterilmiştir.


Tablo 6'a da görüldüğü gibi deneylerde kullanılan tüm Doğrusal MÖ yöntemleri gözetildiğinde yani genel anlamda en yüksek sınıflandırma başarımları KSC veri setindedir. İki veri seti içerisinde yalnızca var olan yöntemler dikkate alındığında ise en yüksek sınıflandırma başarımlarını veren algoritmalar Indian Pines için OKKD; KSC için KKG algoritmalarıdır. Kullanılan hiperspektral veri setlerinde önerilen yöntemin etkisiyle birlikte sınıf bazında sınıflandırma doğruluk sonuçlarındaki değişimin ve önerilen μ_c katsayılarının gözlemlendiği grafikler Indian Pines ve KSC için Şekil 21 ve 22 ile gösterilmiştir. Indian Pines ve KSC kümülatif düşünüldüğünde toplam 29 sınıftan 26'sinde sınıflandırma doğruluk oranları önerilen yöntemin uygulanması ile iyileşmiştir. Bir tanesi ise değişmemiştir. Burada dikkat edilmesi gereken bir diğer nokta Şekil 22' de μ_c değerinin sıfır gibi

gözüktüğü sınıflardır. Bu sınıflar özelindeki μ_c değerleri aslında sıfır değil sıfıra yakın başka değerlerdir. Bu durum ilgili sınıflara ait örneklerdeki bant bilgisinin kendi içerisinde yüksek benzerlikte olmasından kaynaklanmaktadır.

Tablo 6. Hiperspektral Verilerde Sınıflandırma Doğruluk Sonuçları (std: Standart Sapma, Önerilen Y.: Önerilen Yöntem)

Veri Seti	Doğrusal Yöntemi	MÖ	Sınıflandırma Başarımı (%) $\pm$ std	Parametreler
Indian Pines	KKD		69.2 ± 1.25	$k = 50, s = 1600$
	KKG		73.2 ± 0.25	$k = 70$
	OKKD		76.6 ± 0.72	$k = 90, s = 800$
	OKKG		74.7 ± 0.67	$k = 40$
	Önerilen Y. + KKD		78.2 ± 0.77	$k = 110, s = 400, p = 10^{-4}$
	Önerilen Y. + OKKD		75.2 ± 1.25	$k = 90, s = 1000, p = 10^{-4}$
KSC	KKD		82.9 ± 2.05	$k = 2, s = 19500$
	KKG		90.0 ± 0.82	$k = 32$
	OKKD		87.4 ± 2.10	$k = 18, s = 36000$
	OKKG		87.0 ± 1.00	$k = 60$
	Önerilen Y. + KKD		85.0 ± 0.87	$k = 50, s = 19500, p = 10^{-6}$
	Önerilen Y. + OKKD		91.4 ± 0.83	$k = 20, s = 20000, p = 10^{-6}$


Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>



Şekil 21. Indian Pines Veri Setinde Sınıf Bazında İyileşmeler- μ_c Grafiği

(enhancement (%): İyileşme Yüzdesi, coeff: μ_c Katsayısı)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>



Şekil 22. KSC Veri Setinde Sınıf Bazında İyileşmeler- μ_c Grafiği (enhancement (%):

İyileşme Yüzdesi, coeff: μ_c Katsayısı)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>


5.3.2. İstatistiksel Analiz için Sonuçlar

Bu bölüm yüz verileri ve hiperspektral veriler için ağırlık matrisleri, yüz verileri özelinde özelliklerin saçılım grafikleri, hiperspektral verilerde bant bilgisine ait grafikler, korelasyon matrisleri ve anlamlılıklarına dair deney sonuçları içermektedir.


5.3.2.1. Yüz Verileri için İstatistiksel Sonuçlar

ORL, Yale ve E. Yale için çıkarılan ağırlık matrisleri Şekil 23-25 üzerinde verilmiştir. Önerilen yöntemin etkisi ORL için OKKD; Yale ve E. Yale için KKD üzerinde araştırılmıştır.


Şekil 23-25' bakıldığında önerilen yöntemin ilgili algoritmaya uygulanmasıyla beraber sınıf içi örnekler ait değerler, diğer deyişle aynı sınıfa ait örneklerin değerleri artmıştır. Bu örnekler diyagonal çevresindedir. Bu noktalardaki artışa dair en bariz belirginlik ORL veri setinde gözükmemektedir.



Şekil 23. ORL Veri Seti için Ağırlık Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD




Şekil 24. Yale Veri Seti için Ağırlık Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD




Şekil 25. E. Yale Veri Seti için Ağırlık Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD

Yüz verilerinde gerçekleştirilen diğer gözlem 20 boyuta indirgenmiş düşük boyutu verinin ilk üç özelliğinin görselleştirilmesi olmuştur. Buradan elde edilen sonuçlar Şekil 26-31 üzerinde gösterilmiştir.


İlgili şekillerde rastgele seçilen sınıflarda, kendi sınıfına ait örnekler önerilen yöntemin etkisi ile beraber daha ayırt edilebilir bir duruma gelmiştir. Bu durum tüm yüz veri setleri için geçerli olmakla beraber sınıflar arası mesafe de dikkate alındığında en belirgin durum Şekil 28 ve 29 ile gösterilen Yale veri setinde görülmektedir. Bu veri setinde önerilen yöntemin etkisi sonrası oluşan sınıflar arası mesafe diğer veri setlerindeki örneklere göre daha fazladır.




Şekil 26. ORL Veri Seti için OKKD üzerinde Üç Boyutlu Saçılım Grafiği (x, y, z Özellikleri Temsil Eder)




Şekil 27. ORL Veri Seti için Önerilen Yöntem + OKKD üzerinde Üç Boyutlu Saçılım Grafiği (x, y, z Özellikleri Temsil Eder)




Şekil 28. Yale Veri Seti için KKD üzerinde Üç Boyutlu Saçılım Grafiği (x, y, z Özellikleri Temsil Eder)



Şekil 29. Yale Veri Seti için Önerilen Yöntem + KKD üzerinde Üç Boyutlu Saçılım Grafiği (x, y, z Özellikleri Temsil Eder)



Şekil 30. E. Yale Veri Seti için KKD üzerinde Üç Boyutlu Saçılım Grafiği (x, y, z Özellikleri Temsil Eder)




Şekil 31. E. Yale Veri Seti için Önerilen Yöntem + KKD üzerinde Üç Boyutlu Saçılım Grafiği (x, y, z Özellikleri Temsil Eder)

Yüz verilerinde önerilen yöntem etkisiyle örnekler arasında oluşan korelasyon değişiminin incelendiği korelasyon matrislerinin görselleştirilmesi Şekil 32-34 üzerinde verilmiştir. Şekiller sırasıyla ORL, Yale ve E. Yale veri setlerine aittir.


Şekil 32-34'e bakıldığında kullanılan tüm yüz veri setlerinde genel anlamda örnekler arası korelasyonda genel bir artış görülmektedir. Ancak diyagonal çevresinde, bir başka deyişle sınıf içi örneklerin olduğu kısımlarda önerilen yöntemin etkisi ile meydana gelen artış sınıf dışı örneklerle göre daha bariz gözlenmektedir. Bu artış en belirgin Yale veri setinde gözlemlenirken, ORL'de belirginlik nispeten düşüktür.

Yale ve E. Yale için korelasyon matrisindeki değerlerin anlamlılığını ölçmek amacıyla elde edilen p-değerleri ise görselleştirilerek Şekil 35 ve 36 ile verilmiştir. Daha küçük p değerleri o örnekte korelasyonun daha anlamlı olduğu anlamı taşımaktadır. Deneylerde ORL veri seti ile de anlamlılık testlerine dair çalışmalar yapılmış ancak elde edilen karmaşık matris görselleri bilgi çıkarımı yapmaya olanak sağlamadığından çalışmaya eklenmemiştir.


Şekil 35 ve 36'ya bakıldığında hem Yale hem de E. Yale veri setlerinde önerilen yöntemin etkisiyle birlikte sınıf içi örneklerde yani diyagonal çevresindeki p-değerleri belirgin şekilde azalmıştır.




Şekil 32. ORL Veri Seti için Korelasyon Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD




Şekil 33. Yale Veri Seti için Korelasyon Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD



Şekil 34. E. Yale Veri Seti için Korelasyon Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD



Şekil 35. Yale Veri Seti için p-Değerleri Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD




Şekil 36. E. Yale Veri Seti için p-Değerleri Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD

5.3.2.2. Hiperspektral Veriler için İstatistiksel Sonuçlar


Indian Pines ve KSC için çıkarılan ağırlık matrisleri Şekil 37 ve 38 üzerinde verilmiştir. Önerilen yöntemin etkisi Indian Pines için KKD; KSC için OKKD üzerinde araştırılmıştır.

Şekil 37 ve 38 ‘e bakıldığında, Indian Pines ve KSC veri seti üzerinden alınan sonuçlarda diyagonal çevresinde yani sınıf içi örneklerin ağırlık matrisi değerlerinde bir artış söz konusu iken aynı zamanda sınıf dışı örneklerin değerlerinde ise bir azalma görülmektedir. Değerlerdeki artış, KKD ya da OKKD için başlangıçta oluşturulan komşuluk grafiğinde zaten bağlı örnekler arasındaki değerlerin artışı ya da sonradan algoritmanın iki sınıf içi örneği bağlayarak 0’ın yeni değer ile güncellemesi şeklinde olduğu gözlemlenmektedir.



Şekil 37. Indian Pines Veri Seti için Ağırlık Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>




Şekil 38. KSC Veri Seti için Ağırlık Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>

Hiperspektral verilerde gerçekleştirilen diğer çalışma 20 boyuta indirgenmiş düşük boyutlu veri üzerinde yapılan bant bilgisi çıkarımına ait deneylerdir. Bu deneyler hem var olan algoritmanın üzerinde önerilen yöntemin uygulandıktan sonraki hem de uygulanmadan önceki şekliyle gerçekleştirilmiştir.


Şekil 39 ve 40, Indian Pines ve KSC veri setleri için, ilk iki bantın, Bant 1-2'nin, 'zor sınıflar' ile belirtilmiş sınıflara ait örnekler üzerinde sağlayabildiği bilgiyi sunmaktadır. Bant deneylerinde ikinci kısımda Bant 11-12'nin rastgele seçilen sınıflar üzerindeki etkisi gösterilmektedir. Bant 11 ve 12 deneysel seçilmiştir. Sonuçlar Indian Pines ve KSC için Şekil 41 ve 42 ile gösterilmiştir. Indian Pines için KKD, KSC için ise OKKD dikkate alınmıştır.

Şekil 39'da Indian Pines veri seti için önerilen yöntemin etkisiyle beraber ilk iki bantta 'zor sınıflar' olarak belirlenen iki sınıfa ait örneklerde ayırt ediciliğin arttığı gözlemlenmektedir. Şekil 40'ta KSC veri seti için önerilen yöntemin etkisi özellikle seçilen rastgele sınıflardan kırmızı ve yeşil daire ile gösterilenler üzerinde açıkça görülmektedir. Bu sınıfların ayırt ediciliği artmıştır. Şekil 41 ve 42'de ise hem Indian Pines hem de KSC veri setinde Bant 11 ve 12'nin rastgele seçilen sınıflara ait örnekler için sağladığı ayırt edicilik bilgisinin daha iyi hale geldiği görülmektedir.




Şekil 39. Indian Pines Veri Setinde ‘Zor Sınıflar’ için Bant 1-2 Bilgisi (a) KKD, (b) Önerilen Yöntem + KKD (band 1: 1. Bant, band 2: 2. Bant)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>




Şekil 40. KSC Veri Setinde ‘Zor Sınıflar’ için Bant 1-2 Bilgisi (a) OKKD, (b) Önerilen Yöntem + OKKD (band 1: 1. Bant, band 2: 2. Bant)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>



Şekil 41. Indian Pines Veri Setinde Rastgele Seçilen Sınıflar için Bant 11-12 Bilgisi
(a) KKD, (b) Önerilen Yöntem + KKD (band 11: 11. Bant, band 12: 12. Bant)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>




Şekil 42. KSC Veri Setinde Rastgele Seçilen Sınıflar için Bant 11-12 Bilgisi (a)
OKKD, (b) Önerilen Yöntem + OKKD (band 11: 11. Bant, band 12: 12. Bant)

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>

Hiperspektral veriler önerilen yöntem etkisiyle örnekler arasında oluşan korelasyon değişiminin incelendiği korelasyon matrislerinin görselleştirilmesi Şekil 43 ve 44 üzerinde verilmiştir. Şekiller sırasıyla Indian Pines ve KSC veri setlerine aittir.


Şekil 43 ve 44'e bakıldığında her iki veri setinde de önerilen yöntemin etkisinin örnekler arasında genel bir korelasyon azalmasına yol açtığı gözlenmektedir. Sınıf içi örnekler için korelasyonlarda yani diyagonal çevresindeki değerlerde bir değişiklik gözlenmezken azalmaların en çok sınıf dışı örnekler arasında olduğu görülmektedir. Bununla beraber, Şekil 44'te KSC verisi üzerinden OKKD algoritması ile alınan sonuçta tüm matriste yaygın yüksek korelasyon değerleri görülmektedir.

Indian Pines ve KSC için korelasyon matrisindeki değerlerin anlamlılığını ölçmek amacıyla elde edilen p-değerleri görselleştirilerek Şekil 45 ve 46 ile verilmiştir. Daha küçük p değerleri o örnekte korelasyonun daha anlamlı olduğu anlamı taşımaktadır. Şekil 45 ve 46'da her iki veri seti için de önerilen yöntemin etkisiyle birlikte diyagonal çevresi dışındaki değerlerde yani sınıf dışı p-değerlerinde artış olduğu gözlemlenmektedir.




Şekil 43. Indian Pines Veri Seti için Korelasyon Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>




Şekil 44. KSC Veri Seti için Korelasyon Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>



Şekil 45. Indian Pines Veri Seti için p-Değerleri Matrisleri (a) KKD, (b) Önerilen Yöntem + KKD

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>



Şekil 46. KSC Veri Seti için p-Değerleri Matrisleri (a) OKKD, (b) Önerilen Yöntem + OKKD

Kaynak: Öztürk, Ü., & Yılmaz, A. (2021). An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images. *Applied Sciences*, 11(19), 9063. <https://doi.org/10.3390/app11199063>

5.4. Deney Sonuçlarının Analizi

Önerilen yöntemin etkisi en başta sentetik verilerle açıkça gösterilmiştir. Rastgele üzerine gürültü eklenerek üretilen 6 sınıftan oluşan veri kümelerini önerilen yöntem KKD'ye göre daha iyi ayırmıştır. Özellikle KKD ile iyi ayırt edilemeyen ikili sınıf çiftine ait örneklerde, mavi-yeşil, siyan-macenta, birbiri üzerine binme etkisi önerilen yöntemin uygulanması ile birlikte azalmıştır.

Sentetik verilerle yapılan çalışmadan sonra deneylere gerçek veriler ile devam edilmiştir. Yüz verilerinde KKD temelli gerçekleştirilen parametre araştırmasına göre komşuluk parametresi, k ve heat kernel parametresi s 'nin sınıflandırma başarımını etkilediği alanlar verilere göre farklılık göstermektedir. Üç yüz veri setinde de yapılan deneyler çerçevesinde önerilen yöntemin uygulanması ile daha iyi sınıflandırma başarımlarına daha büyük k seçimleri ile ulaşılabildiği görülmektedir. ORL veri setinde önerilen yöntem k parametresinde sınıflandırma başarımı açısından belli bir noktaya kadar keskin değişimlere sebep olmaktadır. Bu durum sezgisel parametre seçimini zorlaştırmaktadır. Parametre k ve s 'nin sınıflandırma başarımını etkilediği

bölgeler dikkate alındığında Yale veri setinde değişimin E. Yale veri setine göre daha hassas olduğu görülmektedir.

Önerilen yöntemin etkisiyle birlikte hem yüz hem de hiperspektral verilerde sınıflandırma başarımı artmıştır. Yüz verilerinde deneyler çerçevesinde var olan doğrusal MÖ yöntemleri arasında en iyi sonucu veren algoritma dikkate alındığında sınıflandırma doğruluk oranlarında sağlanan ilerleme ORL, Yale ve E. Yale için sırasıyla %1.2, %7.5 ve %7.1'dir. Yüz verilerinde en yüksek oran Yale veri setindedir. Yüz verilerindeki sınıflarda birçoğunda sınıflandırma başarımı artmıştır. Hiperspektral verilerde deneyler çerçevesinde var olan doğrusal MÖ yöntemleri arasında en iyi sonucu veren algoritma dikkate alındığında sınıflandırma doğruluk oranlarında sağlanan ilerleme Indian Pines ve KSC için sırasıyla %1.6 ve %1.4'tür. Hiperspektral verilerde toplam 29 sınıftan yalnızca 2 tanesinde düşüş görülmüştür. Hem yüz hem de hiperspektral veriler için önerilen katsayılar ve ilerleme oranları arasında belirgin bir korelasyon görülmemiştir.

Hem yüz hem de hiperspektral veriler üzerinden elde edilen ağırlık matrislerinde sınıf içi örneklerde bir değer artışı şeklinde belirginleşme mevcuttur. Bu durum daha iyi sınıflandırma sonuçları alınabileceği yönünde bir belirti gibi gözükmektedir. Fakat ağırlık matrisi hesabı algoritmanın işleyişinde bir orta adım olduğu için ve ağırlık matrisleri direk gömüler üzerinden alınan sonuçlar olmadığı için her zaman daha iyi sınıflandırma sonuçlarının çıkacağı garanti edilememektedir.

Yüz verilerinde saçılım matrislerine ve hiperspektral verilerde bant bilgisine ait grafikler indirgenmiş veri üzerinden elde edilmiştir. Özelliklerin geometrik konumunu görselleştirirler. Önerilen yöntem kullanılan yüz verilerinin tümünde belirgin rastgele seçilen sınıflar için bir ayırt edicilik sağlamıştır. Sınıflar arası mesafe dikkate alındığında en belirgin sınıfsal ayırt edicilik Yale veri setindedir. Bu bağlamda, yüz veri setleri arasında sınıflandırma doğruluk oranlarında en fazla ilerlemenin %7.5 ile aynı şekilde Yale veri setinde olması tutarlı gözükmektedir. Önerilen yöntemin hiperspektral verilerde 'zor sınıflara' ait Bant 1 ve 2'nin sağladığı bilgiyi daha iyi seviyeye getirdiği görülmektedir. Belli bantlar belli sınıflar için ayırt edici olabilmektedir. Bu bağlamda Bant 11 ve 12'nin hiçbir bilgi sağlayamadığı bazı sınıflara önerilen yöntemin uygulanmasıyla ciddi bir sınıfsal ayırt edicilik

kazandırılması değerli bir çıkarımdır. Bu durum her iki hiperspektral veride de görülmektedir.

Sınıf içi ve sınıf dışı örnekler arasındaki korelasyon gözetildiğinde sınıflandırma doğruluk başarımına katkı verebilecek bilginin kalitesine yönelik çıkarımlar yapılabilmektedir. Durum yüz veri setleri açısından incelendiğinde önerilen yöntem diyagonal çevresinde, yani sınıf içi örneklerde sınıf dışı örneklere göre bariz bir korelasyon belirginliği sağlamıştır. Bu durum sınıf ayırt ediciliği açısından önemli bilgi sağlamaktadır. Ayrıca yüz verileri için elde edilen p-değerleri matrisinde diyagonal çevresindeki değer düşüşünün korelasyon anlamlılığının da arttırdığını göstermektedir. Hiperspektral veriler üzerinden elde edilen korelasyon matrislerinde ise önerilen yöntem diyagonal yakınları dışındaki değerlerde yani sınıf dışı örneklerde belirgin bir değer düşüşü sağlamıştır. Hiperspektral veriler için elde edilen p-değerleri matrisinde sınıf dışı örnekler için elde edilen değerlerde artışlar görülmektedir. Bu durum sınıf dışı örnekler için geçerli korelasyonda anlamsız ilişkinin oluştuğunu göstermekte ve denetimli öğrenmeyi desteklemektedir.

SONUÇ

BA yöntemleri yüksek boyutlu veriyi daha düşük boyutlara indirgeyerek algoritmaların hızlı çalışabilmesini sağlarken verinin depolanması konusunda da önemli avantajlar sunmaktadırlar. Eğer ilgili BA algoritması SVÖ için uygulanabilir değilse yüz tanıma ve hiperspektral görüntüleme gibi çok yüksek boyutlu veriler içerebilen uygulama alanlarında pratik çözüm sunulması ve hızlı sonuç alınması zorlaşmaktadır.

MÖ, BA amaçlı bir araştırma alanıdır. MÖ algoritmaları temelde SVÖ sorununu çözebilen doğrusal bir yapı barındırmaz ancak TBA ve DAA algoritmalarına göre daha başarılı özellik çıkarma kabiliyeti çalışmalarla gösterilmiştir. Bununla beraber SVÖ sorunu için uygulanabilir çeşitli MÖ yöntemleri daha sonra önerilmiştir. Önerilen bu algoritmalarından KKD, OKKD, KKG ve OKKG literatürde geniş bir yer bulmaktadır. Bu çalışmada doğrusal MÖ tabanlı ve KKD, OKKD, KKG ve OKKG yöntemlerinden daha başarılı özellik öğrenme kabiliyeti olan bir yöntem ortaya konmuştur. Yöntemin etkinliği yüz tanıma ve hiperspektral görüntüleme gibi iki önemli alanda beş farklı veri seti üzerinde üstün sınıflandırma doğruluk performansları ile gösterilmiştir. Ayrıca önerilen yöntemin ayırt edilebilirliği ağırlık matrisleri üzerinde gösterilmiştir. Bununla beraber, yüz görüntülerinden elde edilen özelliklere ait saçılım ve hiperspektral görüntülerden elde edilen bant grafiklerinde önerilen yöntemin sınıflandırmaya katkı sağlayabilecek bilgiyi geliştirdiği açıkça görülmüştür. Yüz görüntülerinde sınıf içi örneklerle ait korelasyon artışları ve korelasyon anlamlılığının artması; hiperspektral görüntülerde ise sınıf dışı örneklerle ait korelasyondaki bariz düşüşler ve korelasyon anlamlılıklarındaki düşüşler denetimli yaklaşımı olumlu anlamda destekleyen önemli birer bulgudur. Tüm istatistiksel sonuçlar birlikte değerlendirildiğinde elde edilen sınıflandırma sonuçlarının bir tesadüf olmadığı kanıtlanmıştır. Bu noktada önerilen yöntemin SVÖ sorunu için uygulanabilirliği ve başarılı özellik öğrenme kabiliyeti birlikte değerlendirildiğinde ilgili yöntemin yüksek boyutlu verilerde sınıflandırma görevi için önemli bir çözüm sunduğu açıkça görülmektedir. Ayrıca önerilen yöntemin etkinliği hem yüz tanıma hem de hiperspektral görüntüleme alanında gösterilmiştir.

Önerilen yöntem sadece öklit mesafe tabanlı geliştirmiş olup farklı mesafe kuralları kullanılmamıştır. Sınıflandırıcı olarak yalnızca DVM kullanılmıştır. Önerilen yöntemin farklı mesafe metrikleri ile ve ileri düzey sınıflandırıcılarla birlikte kullanılarak performansın daha da gelişip gelişmediğinin incelenmesi ileri çalışmalar için önerilmektedir. Bununla birlikte çalışmada kullanılan yüz verileri yapısal verilerdir. Kişilerden farklı zamanlarda rastgele elde edilen yüz görüntüleri üzerinde özellik çıkarma kabiliyetinin ve sınıflandırma başarısının değerlendirilmesi önerilmektedir.



KAYNAKÇA

- Belhumeur, P. N., Hespanha, J. P., & Kriegman, D. J. **Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection**, *IEEE Transactions on pattern analysis and machine intelligence*, 19(7), 1997, 711-720.
- Belkin, M., & Niyogi, P. **Laplacian Eigenmaps for Dimensionality Reduction and Data Representation**, *Neural computation*, 15(6), 2003, 1373-1396.
- Bengio, Y., Paiement, J. F., Vincent, P., Delalleau, O., Roux, N., & Ouimet, M. **Out-of-Sample Extensions for LLE, Isomap, MDS, Eigenmaps, and Spectral Clustering**, *Advances in neural information processing systems*, 16, 2003, 177-184.
- Cai, D., **Four Face Databases in Matlab Format**, <http://www.cad.zju.edu.cn/home/dengcai/Data/FaceData.html>, Erişim Tarihi: 30.01.2020
- Cai, D., He, X., Han, J., & Zhang, H. J. **Orthogonal Laplacianfaces for Face Recognition**, *IEEE transactions on image processing*, 15(11), 2006, 3608-3614.
- Cambridge University, **The Database of Faces**, <https://cam-orl.co.uk/facedatabase.html>, Erişim Tarihi: 30.01.2020.
- Chao, G., Luo, Y., & Ding, W. **Recent Advances in Supervised Dimension Reduction: A Survey**, *Machine learning and knowledge extraction*, 1(1), 2019, 341-358.
- Chen, G. H., Wachinger, C., & Golland, P. (2013, June), **Sparse Projections of Medical Images onto Manifolds**, *International Conference on Information Processing in Medical Imaging*, 2013, 292-303.
- Chen, J., & Liu, Y. **Locally Linear Embedding: A Survey**, *Artificial Intelligence Review*, 36(1), 2011, 29-48.

- Crawford, M. M., Ma, L., & Kim, W. **Exploring Nonlinear Manifold Learning for Classification of Hyperspectral Data**, In *Optical Remote Sensing*, 2011, 207-234.
- Cui, Y., & Fan, L. **A Novel Supervised Dimensionality Reduction Algorithm: Graph-Based Fisher Analysis**, *Pattern Recognition*, 45(4), 2012, 1471-1481.
- De Ridder, D., Kouropteva, O., Okun, O., Pietikäinen, M., & Duin, R. P. (2003, June), **Supervised locally linear embedding**, In *Artificial Neural Networks and Neural Information Processing—ICANN/ICONIP*, Springer, 2003, 333-341.
- De Ridder, D., & Duin, R. P. **Locally Linear Embedding for Classification**, *Pattern Recognition Group, Dept. of Imaging Science & Technology, Delft University of Technology, Delft, The Netherlands, Tech. Rep. PH-2002-01*, 2002, 1-12.
- Fisher, R. A. **The Use of Multiple Measures in Taxonomic Problems**, *Ann. Eugenics*, 7, 1936, 179-188.
- Georghiades, A. S., Belhumeur, P. N., & Kriegman, D. J. **From Few to Many: Illumination Cone Models for Face Recognition Under Variable Lighting and Pose**, *IEEE transactions on pattern analysis and machine intelligence*, 23(6), 2001, 643-660.
- Grupo De Inteligencia Computacional, **Hyperspectral Remote Sensing Scenes**, [http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes), Erişim Tarihi: 20.02.2021.
- He, X., Cai, D., Yan, S., & Zhang, H. J. (2005, October), **Neighborhood Preserving Embedding**, *Tenth IEEE International Conference on Computer Vision (ICCV'05)*, IEEE, 2005, 1208-1213.
- He, X., & Niyogi, P. **Locality Preserving Projections**, In *Advances in neural information processing systems*, 16, 2004, 153-160.
- Hua, Q., Bai, L., Wang, X., & Liu, Y. **Local Similarity and Diversity Preserving Discriminant Projection for Face and Handwriting Digits Recognition**. *Neurocomputing*, 86, 2012, 150-157.

- Khalili Mobarakeh, A., Cabrera Carrillo, J. A., & Castillo Aguilar, J. J. **Robust Face Recognition Based On A New Supervised Kernel Subspace Learning Method**, *Sensors*, 19(7), 2019, 1643.
- Lee, E. J. **Face Recognition Based on Improved Fuzzy RBF Neural Network for Smart Device**, *Journal of Korea Multimedia Society*, 16(11), 2013, 1338-1347.
- Li, B., Liu, J., Zhao, Z. Q., & Zhang, W. S. (2013, August), **Locally Linear Representation Fisher Criterion**, *The 2013 International Joint Conference on Neural Networks (IJCNN)*, IEEE, 2013, 1-7.
- Liu, X., Yin, J., Feng, Z., Dong, J., & Wang, L. (2007, September), **Orthogonal Neighborhood Preserving Embedding for Face Recognition**. *2007 IEEE International Conference on Image Processing*, 2007, I-133.
- Lunga, D., Prasad, S., Crawford, M. M., & Ersoy, O. **Manifold-Learning-Based Feature Extraction for Classification of Hyperspectral Data: A Review of Advances in Manifold Learning**, *IEEE Signal Processing Magazine*, 31(1), 2013, 55-66.
- Mu, C., Guo, Z., & Liu, Y. **A Multi-Scale and Multi-Level Spectral-Spatial Feature Fusion Network for Hyperspectral Image Classification**, *Remote Sensing*, 12(1), 2020, 125.
- Öztürk, Ü., & Yılmaz, A. **An Optimization Technique for Linear Manifold Learning-Based Dimensionality Reduction: Evaluations on Hyperspectral Images**, *Applied Sciences*, 11(19), 2021, 9063.
- Pal, M., & Foody, G. M. **Feature Selection for Classification of Hyperspectral Data by SVM**, *IEEE Transactions on Geoscience and Remote Sensing*, 48(5), 2010, 2297-2307.
- Peherstorfer, B., Pflüger, D., & Bungartz, H. J. (2011, December), **A Sparse-Grid-Based Out-of-Sample Extension for Dimensionality Reduction and Clustering with Laplacian Eigenmaps**, *Australasian Joint Conference on Artificial Intelligence*, Springer, 2011, 112-121.

- Pless, R., & Souvenir, R. **A Survey of Manifold Learning for Images**, *IPSN Transactions on Computer Vision and Applications*, 1, 2009, 83-94.
- Qiao, H., Zhang, P., Wang, D., & Zhang, B. **An Explicit Nonlinear Mapping for Manifold Learning**, *IEEE transactions on cybernetics*, 43(1), 2012, 51-63.
- Raducanu, B., & Dornaika, F. **A Supervised Non-Linear Dimensionality Reduction Approach for Manifold Learning**, *Pattern Recognition*, 45(6), 2012, 2432-2444.
- Rodarmel, C., & Shan, J. **Principal Component Analysis for Hyperspectral Image Classification**, *Surveying and Land Information Science*, 62(2), 2002, 115-122.
- Roweis, S. T., & Saul, L. K. **Nonlinear Dimensionality Reduction by Locally Linear Embedding**, *Science*, 290(5500), 2000, 2323-2326.
- Samaria, F. S., & Harter, A. C. (1994, December), **Parameterisation of A Stochastic Model for Human Face Identification**, *Proceedings of 1994 IEEE workshop on applications of computer vision*, IEEE, 1994, 138-142.
- Sugiyama, M. **Dimensionality Reduction of Multimodal Labeled Data by Local Fisher Discriminant Analysis**, *Journal of machine learning research*, 8, 2007, 1027-1061.
- Tenenbaum, J. B., De Silva, V., & Langford, J. C. **A Global Geometric Framework for Nonlinear Dimensionality Reduction**, *Science*, 290(5500), 2000, 2319-2323.
- Van Der Maaten, L., **Matlab Toolbox for Dimensionality Reduction**, <https://lvdmaaten.github.io/drtoolbox/>, Erişim Tarihi: 20.02.2021.
- Van Der Maaten, L., Postma, E., & Van den Herik, J. **Dimensionality Reduction: A Comparative**, *J Mach Learn Res*, 10(13), 2009, 66-71.
- Vural, E., & Guillemot, C. **A Study of The Classification of Low-Dimensional Data with Supervised Manifold Learning**, *The Journal of Machine Learning Research*, 18(1), 2017, 5741-5795.

- Wang, R., & Chen, X. (2009, June), **Manifold Discriminant Analysis**, *2009 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 2009, 429-436.
- Wen, J., Yan, W., & Lin, W. (2014, July). **Supervised Linear Manifold Learning Feature Extraction for Hyperspectral Image Classification**, *2014 IEEE Geoscience and Remote Sensing Symposium*, IEEE, 2014, 3710-3713.
- Yang, W., Sun, C., & Zhang, L. **A Multi-Manifold Discriminant Analysis Method for Image Feature Extraction**, *Pattern Recognition*, 44(8), 2011, 1649-1657.
- Yılmaz, A., & Öztürk, Ü. (2019, June), **An Analysis of Dimension Reduction Methods Applicable for Out of Sample Problem in Hyperspectral Images**, *9th International Conference on Recent Advances in Space Technologies (RAST)*, IEEE, 2019, 381-386.
- Zhang, J., Huang, H., & Wang, J. **Manifold Learning for Visualizing and Analyzing High-Dimensional Data**, *IEEE Intelligent Systems*, (4), 2010, 54-61.
- Zhang, K., & Kwok, J. T. **Clustered Nyström Method for Large Scale Manifold Learning and Dimension Reduction**, *IEEE Transactions on Neural Networks*, 21(10), 2010, 1576-1587.
- Zhang, Z., Zhao, M., & Chow, T. W. **Marginal Semi-Supervised Sub-Manifold Projections with Informative Constraints for Dimensionality Reduction and Recognition**, *Neural Networks*, 36, 2012, 97-111.
- Zhao, J., Huang, Y., Luo, S., Tian, M., & Zou, Q. (2008, September), **Face Recognition with Neighboring Discriminant Analysis**. *8th IEEE International Conference on Automatic Face & Gesture Recognition*, IEEE, 2008, 1-6.

